

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

Gerenciamento através de Redes Neurais Artificiais das atividades de produção de reprodutoras pesadas e do frango de corte, de um incubatório e de um abatedouro avícola.

Dissertação de mestrado

Augusto Spohr

Porto Alegre

2011

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

Gerenciamento através de Redes Neurais Artificiais das atividades de produção de reprodutoras pesadas e do frango de corte, de um incubatório e de um abatedouro avícola.

Autor: Augusto Spohr

Dissertação apresentada como requisito para a obtenção do grau de Mestre em Ciências Veterinárias na Área de Sanidade Avícola do Programa de Pós-graduação em Ciências Veterinárias da UFRGS.

Orientador: Prof. Dr. Carlos Tadeu Pippi Salle

PORTO ALEGRE

2011

S762g Spohr, Augusto

Gerenciamento através de redes neurais artificiais das atividades de produção de reprodutoras pesadas de frango de corte, de um incubatório e de um abatedouro avícola. / Augusto Spohr; Carlos Tadeu Pippi Salle, orient.– Porto Alegre : UFRGS, 2011.

59 f. ; il. – Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, Faculdade de Veterinária, Programa de Pós-graduação em Ciências Veterinárias, Porto Alegre, RS-BR, 2011.

1. Avicultura 2. Redes neurais artificiais 3. Frango de corte 4. Produção avícola I. Salle, Carlos Tadeu Pippi, Orient. II. Título.

CDD 619.602605

Catálogo na fonte: Biblioteca da Faculdade de Veterinária da UFRGS

Augusto Spohr

“GERENCIAMENTO ATRAVÉS DE REDES NEURAIIS ARTIFICIAIS DAS ATIVIDADES DE PRODUÇÃO DE REPRODUTORAS PESADAS E DO FRANGO DE CORTE, DE UM INCUBATÓRIO E DE UM ABATEDOURO AVÍCOLA.”

Aprovada em 29 ABR 2011

APROVADA POR:

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

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

Prof. Dr. Felipe de Oliveira Salle
Membro da Comissão

Prof. Dr. Adriano da Silva Guahyba
Membro da Comissão

AGRADECIMENTOS

Agradeço a Deus por me conceder força e determinação para conquistar mais um objetivo de minha vida.

Ao Prof. Dr. Carlos Tadeu Pippi Salle, pela confiança, pela amizade, entusiasmo, incentivo e apoio, fatores determinantes no desenvolvimento deste trabalho.

Aos meus pais, José Arcádio Spohr e Teresinha Heinen Spohr, maiores incentivadores da minha educação.

A minha namorada Raquel Koch, obrigado pelo apoio, força e constantes conselhos.

As minhas tias, Dalva e Nair e primo Afonso pelo apoio nesta jornada.

Ao Prof. Dr. Hamilton Luis de Souza Moraes, pela orientação, conselhos e atenção.

Em especial ao grande incentivador e amigo Ricardo dos Santos, que acreditou e também confiou em meu potencial, abrindo essa oportunidade para meu aperfeiçoamento profissional.

A SADIA S.A., empresa que incentivou e acreditou no meu trabalho.

Ao Mauro Henrique Rizzi, que soube sempre compreender as dificuldades e foi um impulsionador durante o período de mestrado. Agradeço muito pelo apoio e incentivo.

Aos colegas Diego, Daniel e Cíntia que auxiliaram em todas as atividades que envolveram o experimento desde o início até a conclusão que muito se empenharam para o bom andamento do Projeto.

A todos os colegas de trabalho das granjas de matrizes e incubatório .

Aos colegas Thales Furian, Lucas Brunelli de Moraes, Marco Aurélio, Silvio Luis da Silveira Rocha, Karen Borges, Harvey Machado, Artur Cony, Diana Gioto, Felipe de Oliveira Salle, Marta Gava, Juliana Dal Molin, Elizar Camiloti pelo companheirismo, incentivo e pela amizade.

A todos os colegas, estagiários e funcionários do CDPA.

Ao Cristiano Emanuelli e Rui Perety , pelo auxílio e amizade.

A todas as outras pessoas, que não foram menos importantes e que de alguma forma colaboraram para a concretização desse trabalho.

RESUMO

Este estudo utilizou uma série histórica de dados de quatro etapas de uma produção avícola: reprodutoras pesadas, um incubatório, produção de frangos de corte e um abatedouro de frangos de corte pertencente a uma integração avícola do Rio Grande do Sul, no período de junho de 2009 a janeiro de 2010. As linhagens utilizadas foram COBB, ROSS e AVIAN. A diferença entre as médias das variáveis dos dados iniciais e a estatística descritiva foram calculadas com o programa computacional SigmaStat® Statistical Software para Windows 2.03.

Foram analisados dados de 27 produtores de matrizes de frango de corte, um incubatório, 147 produtores de frango de corte e um abatedouro onde continham registro de: origem do nascedouro no incubatório, origem da incubadura no incubatório, quantificação da contaminação por *Salmonella sp.*, *Aspergillus sp.*, *Escherichia Coli*, *Pseudomonas sp.* nos nascedouros, número de aviários por incubadura, ovo de cama/ninho, percentual de linhagem, ovo trincado, minutos de incubação, minutos de nascedouro, horas de estoque, eclosão total, eclosão vendável, ovos incubáveis, aproveitamento de ovos, idade da matriz, perda de peso de ovo, peso de pinto, peso de ovo, contaminação na transferência, tipo de pinto, fertilidade, tipo de máquina, produtor, extensionista, peso do frango de primeira semana, peso do frango de segunda semana, peso do frango de terceira semana, peso do frango de quarta semana, peso do frango de quinta semana, mortalidade do frango na primeira semana, mortalidade do frango na segunda semana, mortalidade do frango na terceira semana, mortalidade do frango na quarta semana, mortalidade do frango na quinta semana, linhagem, condenação total, condenação parcial. As redes neurais foram construídas através do programa computacional NeuroShell®Predictor e NeuroShell®Classifier, desenvolvido pela Ward Systems Group. O programa identificou as variáveis escolhidas como “entradas” para o cálculo do modelo preditivo e variável de “saída” aquela a ser predita.

Na primeira parte foram apresentados o treinamento das redes neurais artificiais onde foram utilizadas 50% das linhas de registro de junho de 2009 a janeiro de 2010, utilizou-se todas as variáveis de entrada que antecedem as seguintes variáveis de saída para cada rede: eclosão total, eclosão vendável, fertilidade, mortalidade de 1 semana, mortalidade de 5 semanas, perda de peso de ovo, peso de 5 semanas, tipo de pinto, condenação parcial e condenação total.

A segunda parte destinou-se à validação dos modelos, onde se utilizou os outros 50% das linhas de registro com todas as variáveis de entrada que antecedem as mesmas variáveis de saída.

Pode-se concluir que as redes neurais artificiais foram capazes de explicar os fenômenos envolvidos entre as quatro etapas da cadeia avícola, matrizes de frango de corte, incubatório, produção de frangos de corte e abatedouro. Esta técnica demonstra cientificamente que se podem criar critérios objetivos, onde estes se tornam uma importante ferramenta nas decisões que serão tomadas pelos gestores destes importantes setores da cadeia avícola.

Palavras-chave: redes neurais artificiais, reprodutoras pesadas, frango de corte, incubatório, abatedouro.

ABSTRACT

This study used a historic series of four stages of poultry production: breeders, hatchery, production of broilers and broiler chicken slaughterhouse owned by a poultry integration of Rio Grande do Sul in the period from June 2009 to January 2010. The strains used were COBB, ROSS and AVIAN. The difference between the averages of the initial data and descriptive statistics were calculated with the computer program SigmaStat ® Statistical Software for Windows 2.03.

We analyzed data from 27 breeders, 1 hatchery, 147 broiler producers and a slaughterhouse where contained the records of: origin of the hatcher in the hatchery, the origin of incubator in the hatchery, and quantification of Salmonella sp., Aspergillus sp., E. coli, Pseudomonas sp. contamination in hatcher, number of poultry per incubator, egg floor / nest, percentage of lineage, cracked egg, minutes of incubation, the birthplace of minutes, hours in inventory, total hatch, hatching salable, hatching eggs, usable eggs, breeder age, egg weight loss, chick weight, egg weight, contamination in the transfer, type of chick, fertility, machine type, producer, extension workers, the chicken weight of the first week, chicken weight of the second week, chicken weight of the third week, chicken weight of the fourth week, chicken weight of the fifth week, mortality of the chicken in the first week, mortality of chickens in the second week, mortality of the chicken in the third week, mortality of the chicken in the fourth week, mortality of the chicken in the fifth week, lineage, total condemnation, partial condemnation. The neural networks have been built through the computer program NeuroShell Predictor ® and NeuroShell®Classifier, developed by Ward Systems Group. The program identified the variables selected entries as “inputs” for the calculation of the predictive model and the variable “output” those to be predicted.

In the first part were presented the training of artificial neural networks were used 50% of the lines of record from June 2009 to January 2010, was used all the input variables that precedes the following output variables for each network: total hatching , salable hatch, fertility,

mortality of one week, mortality of five week , egg weight loss, weight of five weeks, type c partial-condemnation and total condemnation.

The second part was intended to validate the models, where were used the other 50% of the records lines with all input variables s that precedes the same output variables.

It can be concluded that artificial neural networks were able to explain the phenomena involved between the four stages of poultry production, breeders, hatchery, broiler production and slaughterhouse. This technique proves scientifically that we can create objective criteria, and this methodology become an important tool in making decisions taken by managers of these important sectors of the poultry chain.

Key-words: artificial neural network, arrays of broilers, hatchery, broilers, slaughterhouse

LISTA DE TABELAS

Tabela 1 -	Características dos modelos de rede neural gerados na fase de treinamento, para os distintos parâmetros de produção (saídas).....	26
Tabela 2 -	Características do modelo de rede neural para predição da saída Eclosão total.....	27
Tabela 3-	Importâncias relativas (contribuições) das variáveis de entrada para a saída Eclosão total.....	27
Tabela 4 -	Validação do modelo de rede neural para a predição da Eclosão total pelos 1095 lotes.....	28
Tabela 5 -	Características do modelo de redes neurais para predição da saída Eclosão vendável	29
Tabela 6 -	Importâncias relativas (contribuições) das variáveis de entrada para a saída Eclosão Vendável.....	30
Tabela 7 -	Validação do modelo de rede neural para a predição da Eclosão vendável pelos 1095 lotes.....	31
Tabela 8 -	Características do modelo de rede neural para predição da saída Fertilidade	32
Tabela 9 -	Importâncias relativas (contribuições) das variáveis de entrada para a saída Fertilidade	32

Tabela10-	Validação do modelo de rede neural para a predição da fertilidade pelos 1.095 lotes.....	33
Tabela11-	Características do modelo de rede neural para predição da saída mortalidade de 1 semana	34
Tabela12-	Importâncias relativas (contribuições) das variáveis de entrada para a saída Mortalidade de 1 semana.....	35
Tabela13-	Validação do modelo de rede neural para a predição da Mortalidade de 1 semana pelos 1095 lotes	36
Tabela14-	Características do modelo de rede neural para predição da saída mortalidade de 5 semanas	37
Tabela15-	Importâncias relativas (contribuições) das variáveis de entrada para a saída Mortalidade de 5 semanas	37
Tabela16-	Validação do modelo de rede neural para a predição da Mortalidade de 5 semanas pelos 1095 lotes	38
Tabela17-	Características do modelo de rede neural para predição da saída Perda de peso do ovo	39
Tabela18-	Importâncias relativas (contribuições) das variáveis de entrada para a saída Perda de peso do ovo	40
Tabela19-	Validação do modelo de rede neural para a predição da Perda de peso do ovo pelos 1095 lotes.....	41

Tabela20-	Características do modelo de rede neural para predição da saída Peso de 5 semanas	42
Tabela21-	Importâncias relativas (contribuições) das variáveis de entrada para a saída peso de 5 semanas	42
Tabela22-	Validação do modelo de rede neural para a predição Peso de 5 semanas pelos 1095 lotes	43
Tabela23-	Características do modelo de rede neural para predição da saída Condenação parcial	44
Tabela24-	Importâncias relativas (contribuições) das variáveis de entrada para a saída Condenação parcial	45
Tabela25-	Validação do modelo de rede neural para a predição Condenação parcial pelos 1095 lotes	46
Tabela26-	Características do modelo de rede neural para predição da saída Condenação total	47
Tabela27-	Importâncias relativas (contribuições) das variáveis de entrada para a saída Condenação total	47
Tabela28-	Validação do modelo de rede neural para a predição Condenação total pelos 1095 lotes	48
Tabela29-	Tabela de Contingência da validação da rede neural artificial para saída Tipo de pinto.....	49
Tabela30-	Importâncias relativas (contribuições) das variáveis de entrada para a saída Tipo de pinto.....	50

LISTA DE FIGURAS

Figura 1-	Exemplo esquemático da arquitetura de rede neural	24
Figura 2-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Eclosão total.....	28
Figura 3-	Valores reais (X) <i>versus</i> valores preditos (Y) da eclosão total para os 2191 lotes.....	29
Figura 4-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Eclosão vendável.....	30
Figura 5-	Valores reais (X) <i>versus</i> valores preditos (Y) da eclosão vendável para os 2191 lotes.....	31
Figura 6-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Fertilidade	33
Figura 7-	Valores reais (X) <i>versus</i> valores preditos (Y) da Fertilidade para os 2191 lotes.....	34
Figura 8-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Mortalidade de 1 semana	35
Figura 9-	Valores reais (X) <i>versus</i> valores preditos (Y) da Mortalidade de 1 semana para os 2191 lotes.....	36
Figura10-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Mortalidade de 5 semanas.....	38
Figura11-	Valores reais (X) <i>versus</i> valores preditos (Y) da Mortalidade de 5 semanas para os 2191 lotes	39
Figura12-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Perda de peso do ovo	40
Figura13-	Valores reais (X) <i>versus</i> valores preditos (Y) da Perda de peso do ovo para os 2191 lotes	41

Figura14-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Peso de 5 semanas	43
Figura15-	Valores reais (X) <i>versus</i> valores preditos (Y) do Peso de 5 semanas para os 2191 lotes.....	44
Figura16-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Condenação parcial.....	45
Figura17-	Valores reais (X) <i>versus</i> valores preditos (Y) da Condenação parcial para os 2191 lotes.....	46
Figura18-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Condenação total	48
Figura19-	Valores reais (X) <i>versus</i> valores preditos (Y) da Condenação total para os 2191 lotes.....	49
Figura20-	Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Tipo de pinto	50

SUMÁRIO

1	INTRODUÇÃO.....	14
2	REVISÃO BIBLIOGRÁFICA.....	17
3	MATERIAL E MÉTODOS.....	21
3.1	Dados de registro	21
3.2	Análise estatística dos dados	22
3.3	Redes Neurais Artificiais	23
4	RESULTADOS	26
5	DISCUSSÃO	51
6	CONCLUSÕES	55
	REFERÊNCIAS BIBLIOGRÁFICAS	56

1. INTRODUÇÃO

A indústria avícola no Brasil tem evoluído nestes anos com muita rapidez, apresentando muitos avanços, novas tecnologias e tendências dirigidas aos cuidados das aves, buscando sempre a valorização do produto que atende milhares de famílias.

A carne de frango é a única carne que teve aceitação em todo mundo no decorrer da história. Não há objeções culturais ou religiosas ao consumo de aves em qualquer parte do mundo, sendo que o mesmo não ocorre com a carne suína, bovina e eqüina. (SOARES, 2002)

Segundo a Associação Brasileira dos Produtores e Exportadores de Frango (ABEF, 2009) entre janeiro a junho de 2010 as exportações de carne de frango totalizaram 1,805 milhão de toneladas no período, o que representou uma ligeira queda de 0,12% em relação ao mesmo período de 2009. A receita cambial foi de US\$ 3,111 bilhões, com crescimento de 15% na mesma comparação. Embora mantendo praticamente estabilidade durante o período, o incremento nos recursos provenientes das exportações é resultado de um processo contínuo de recuperação de preços. Devido a uma política cambial pouco favorável ao comércio internacional de frango brasileiro no semestre anterior de julho a dezembro de 2009, houve pouco incremento na receita dos embarques, com 0,51% de aumento e com um decréscimo de 1,21% no volume exportado.

O primeiro trimestre de 2010 delineou a retomada no desempenho do setor avícola, porém as operações, tanto no mercado interno, quanto no externo ainda estão em ritmo cadenciado. Iniciado o ano de 2010, com a retomada das operações de comercialização no mercado interno e exportação, adequadas aos sinais de reação da economia mundial, a avicultura estabeleceu parcialmente aumento na produção. Ainda com sinais de retomada outro fator que está afetando as exportações é a desvalorização do dólar. Assim, com o quadro atual, o setor continua em alerta e buscando alternativas de manter a competitividade, inclusive contando com o Governo Federal para uma iniciativa de desoneração fiscal.

O setor Avícola do Rio Grande do Sul participa com uma fatia considerável no meio sócio econômico do estado. Quase 1 milhão de empregos diretos e atividades indiretas que o setor gera, merecem atenção especial por parte dos governantes e instituições que fomentam o agronegócio. É de extrema importância que medidas de amparo sejam adotadas, com base na

manutenção de atividades que geram milhares de empregos à dezenas de anos e também podem garantir um futuro estável ao produtor e para todo o complexo agroindustrial.

A Associação Gaúcha de Avicultura (ASGAV, 2010) informa que o estado está em terceiro lugar no ranking das exportações, em volume e receita, o Rio Grande do Sul teve nos primeiros seis meses de 2010, equiparado a igual período de 2009, um crescimento de 0,01% nos volumes, com 377,9 mil toneladas, e de 14,68% na receita, somando US\$ 621,3 milhões, na mesma comparação.

A maioria das empresas avícolas que disputam mercados exigentes no mundo inteiro e que empregam um grande número de trabalhadores, usando equipamentos de última geração, ainda, freqüentemente, tomam decisões apoiadas em critérios meramente subjetivos. Assim sendo, a análise dos dados é feita de forma empírica, ou seja, que se guia só pela experiência de seus funcionários, traduzindo em seus erros e acertos.

A avicultura cresceu e os conhecimentos foram acumulados e os registros arquivados primeiramente em escritos de papel. Hoje, os dados gerados pelas empresas são guardados e bem protegidos por meios magnéticos.

A manutenção das empresas avícolas no mercado mundial depende da constante tomada de decisões acertadas. Estas decisões quando tomadas de forma inadequada ou sem critérios podem levar a diagnósticos incorretos e sem fundamentos. O gerenciamento através de redes neurais dos fenômenos que envolvem as atividades das granjas de matrizes de frango de corte, do incubatório, das granjas de frango de corte e abatedouro é uma alternativa importante a ser considerada, visto que pode auxiliar na redução dos custos de produção e na diminuição de riscos sanitários aos plantéis avícolas.

As redes neurais vieram para ficar, elas constituem um assunto novo e ao mesmo tempo velho de pesquisa. Como todo assunto velho trata-se de assunto maduro com muitos anos de pesquisa apoiando os conhecimentos atuais. Como novo campo, serve de pólo de atração para profissionais de vários domínios distintos se transformando em assunto interdisciplinar e sendo estudado há alguns anos na área de avicultura.

Em 2001, no Centro de Diagnóstico e Pesquisa em Patologia Aviária (CDPA) da Faculdade de Veterinária da Universidade Federal do Rio Grande do Sul (UFRGS), foi iniciada uma linha de pesquisa em que se buscava traduzir certos episódios da avicultura em modelos matemáticos. Os modelos explicavam a resposta imunológica de reprodutoras e os danos causados pela

micotoxinas nos frangos de corte. Também foi realizada uma tese de doutorado que demonstrou ser possível explicar os parâmetros de desempenho de reprodutoras pesadas através de redes neurais.

Reali (2004) demonstrou em uma dissertação de mestrado que a utilização de redes neurais artificiais eram capazes de explicar os fenômenos que ocorrem na criação de frango de corte. Salle (2005) explicou os fenômenos ocorridos em um incubatório de uma empresa avícola através de redes neurais artificiais.

Esta dissertação tem como objetivo explicar os fenômenos que ocorrem em matrizes de frango de corte, um incubatório, produção de frangos de corte e um abatedouro com a utilização de redes neurais, permitindo simular e prever resultados obtidos.

2. REVISÃO BIBLIOGRÁFICA

Antes da década de 30, a avicultura resumia-se basicamente em multiplicação de pintos de um dia de forma não profissional, com índices muito baixos de produtividade, tecnologia informal e passada de pai para filho sem nenhuma visão de negócio. (GUSTIN, 2003)

A avicultura teve seu início como atividade industrial no Brasil na década de 60, com a importação dos primeiros lotes de matrizes de linhagens híbridas dos Estados Unidos. (MENDES; PAZ; MOREIRA, 2005)

Segundo Branco (2005), empresas que desejam o sucesso em um mercado tão competitivo, devem diminuir seus riscos com um plano estratégico bem definido.

Outros grandes profissionais da área de planejamento estratégico afirmam que sucesso passado não garante o sucesso presente; que sucesso presente não garante o sucesso futuro e que o sucesso da empresa depende do relacionamento com o ambiente. (PAGNONCELLI, 2001)

Neste contexto, de dinamismo e um ótimo planejamento estratégico das empresas para evitar futuros riscos a produção avícola, se faz o uso de uma importante ferramenta que é a utilização de redes neurais artificiais para o gerenciamento de vários setores da cadeia avícola.

A inteligência do ser humano é a mais avançada dentro do universo das criaturas e o local dessa inteligência dentro do corpo humano é o cérebro. As entidades básicas são os neurônios, interconectados em redes o que permite a troca de informação entre eles, criando a inteligência biológica. Uma ambição óbvia que surge desses fatos é a tentativa de copiar a estrutura e o funcionamento do cérebro em um ambiente técnico. Isso significa que a pesquisa tenta entender o funcionamento da inteligência residente nos neurônios e mapeá-la para uma estrutura artificial, por exemplo, uma combinação de hardware e software, assim transformando as redes neurais biológicas em redes neurais artificiais.

Segundo Fausett (1994), uma rede neural artificial (RNA) tem duas facetas elementares: a arquitetura e o algoritmo de aprendizagem. Essa divisão surge naturalmente pelo paradigma como a rede é treinada. Ao contrário de um computador com arquitetura de von Neumann que é programado, a rede é treinada por exemplos de treino. O conhecimento sobre o problema em consideração está guardado dentro dos exemplos que têm que estar obrigatoriamente disponíveis. O algoritmo de aprendizagem generaliza esses dados e memorizam o conhecimento dentro dos

parâmetros adaptáveis da rede, os pesos. Assim, o construtor de um sistema baseado em RNA tem dois graus de liberdade, a definição sobre o tipo de rede para resolver o problema em consideração e o algoritmo para treinar a rede, e para adaptar os pesos da rede. A composição da rede é feita pelos neurônios. Normalmente o tipo de processamento de um único neurônio é a combinação linear das entradas com os pesos seguidos pela passagem da combinação linear por uma função de ativação. A natureza do problema a ser resolvido normalmente define restrições em relação aos tipos de redes e algoritmos de aprendizagem possíveis. Neste texto distinguem-se redes com propagação do fluxo de informação para frente, redes recorrentes (com realimentação das saídas para as entradas) e redes competitivas. Em relação aos algoritmos de adaptação, vai se distinguir entre aprendizagem supervisionada e aprendizagem não-supervisionada.

Os primeiros conceitos de máquinas baseadas no comportamento das células nervosas biológicas surgiram no início da década de 40 (MINSKY e PAPERT, 1988).

Um ponto marcante na história das redes neurais artificiais foi a apresentação de um modelo de um neurônio artificial por McCulloch and Pitts, (1943). As atividades nessa linha de pesquisa culminaram na concepção do *perceptron* por (Rosenblatt, 1958) e em um modelo parecido, o *adaline* por Widrow and Hoff, (1960). O *perceptron* é capaz de classificar entre classes que são linearmente separáveis, e também usados para reconhecer, por exemplo, caracteres. Essa aplicação foi realizada em uma máquina chamada MARK I PERCEPTRON e causou uma grande euforia certamente exagerada em relação a imaginação das capacidades de futuros robôs inteligentes. A característica importante do *perceptron* foi a apresentação de um algoritmo de aprendizagem capaz de adaptar os pesos internos do neurônio de maneira que seja capaz de resolver o problema de classificação linear, em caso da separabilidade linear das classes.

Segundo, Astion e Wilding (1992), Roush *et al* (1996), Xin (1999), a rede neural artificial é um conjunto de unidades processadoras (ou módulos) 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.

À medida que o aprendizado ocorre, o erro entre a saída e a saída desejada diminui. Então, o conhecimento, o qual a rede aprende, está codificado nos pesos das conexões entre neurônios. As redes aprendem a calcular uma saída corretamente a partir de um padrão de entrada, mas dificilmente revelam, sob qualquer forma compreensível, o que levou a tais julgamentos (FORSSTRÖM & DALTON, 1995).

Cheng e Titterington (1994) descrevem que a utilização das redes neurais serve para classificar e reconhecer padrões; reconhecer e gerar fala; aperfeiçoar processos químicos; prever índices financeiros, tais como câmbio de moedas; reconhecer alvos e minas militares; localizar a origem de pontos no radar; identificar células cancerosas; reconhecer anormalidades cromossômicas; detectar alterações cardíacas; prever trajetórias de re-entrada de naves espaciais; reconhecer automaticamente caracteres escritos a mão; entre outros. O' Sullivan (1999) e Estock (1999) citam que as redes neurais são utilizadas em cartões de créditos em bancos para se evitar fraudes em certas operações.

As redes neurais são muito utilizadas na medicina humana. O câncer de próstata tem seu diagnóstico preventivo, ou precoce, apoiado nesta tecnologia (LOCH *et al.*, 2000; HAN *et al.*, 2001; ZIADA *et al.*, 2001). Também foram empregadas para estabelecer o prognóstico para cinco anos do carcinoma do cólon (SNOW *et al.* 2001). As redes são usadas para relacionar marcadores fenotípicos específicos com genes e estado fisiológico em pacientes com este tipo de doença (BICCIATO *et al.* 2003).

Em medicina veterinária, as redes neurais são utilizadas em inspeção sanitária nos abatedouros avícolas. Resume-se na análise de imagens das carcaças, gerando através das redes critérios de aceitação ou de rejeição (PARK *et al.*, 1998; PARK e CHEN, 2001; CHAO *et al.*, 2002).

Foram utilizadas redes neurais artificiais em trabalhos com *E. coli*, onde estes tratam essencialmente de bases de identificação genética de promotores de DNA (O'Neill, 1992; Demeler & Zhou, 1991; Kanaya *et al.*, 2001), expressão bioquímica (Hajmeer & Basheer, 2002), predições de mutagenicidade, hepatotoxicidade e teratogenicidade (Mosier *et al.*, 2003), entre outras.

Manteuffel & Schön (2002) criaram um sistema que, por meio dos coeficientes de predição linear, aliados a uma rede neural artificial, foi capaz de reconhecer vocalizações relacionadas ao estresse em ambiente com ruído com pequeno erro de reconhecimento (<5%). Chedad *et al.* (2001) implementaram um algoritmo baseado em redes neurais probabilísticas para detectar tosse em suínos, diferenciando-se entre outros ruídos de fundo, alcançando altos níveis de detecção (91,9%).

Robey *et al.* (2009), desenvolveram um programa computacional, onde este maximiza o retorno econômico com a melhora da conversão alimentar de acordo com o peso vivo, a idade ao abate e ao rendimento de carcaça em frangos de corte.

Ivey (1999), baseado em modelos matemáticos, descreve um programa computacional, que gerencia toda a operacionalização da alimentação dos animais, incluindo a formulação da ração e entrega nas granjas, levando em conta o número de aves da propriedade.

Salle *et al.* (1998c, 1998d e 1999c) desenvolveram modelos matemáticos simplificados, usando idade e títulos de anticorpos, para avaliar a resposta imunológica de reprodutoras a doença de Newcastle, bronquite infecciosa e doença infecciosa bursal. Os autores concluíram que podem se criados modelos matemáticos para cada granja, oferecendo uma interpretação objetiva dos resultados sorológicos da resposta imune, provocada pela vacina contra o vírus destas enfermidades.

Roush *et al.* (1996) e Roush *et al.* (1997) descrevem que os resultados de uma predição probabilística de ascite em frangos de corte, com redes neurais, podem ser úteis na escolha e no desenvolvimento de linhagens de frangos de corte que não tenham propensão à ascite.

Trabalhos utilizando-se as redes neurais artificiais no gerenciamento de reprodutoras pesadas foram realizados no CDPA-UFRGS (GUAHYBA, 2001; SALLE, 2001; SALLE, 2003). Com os resultados destes trabalhos foi possível demonstrar e explicar os parâmetros de desempenho das aves, através da utilização das redes neurais artificiais.

Realí (2004), em sua dissertação validou os modelos de redes neurais através das predições e das respectivas comprovações dos valores reais obtidos, em centenas de lotes de frango de corte produzidos durante os anos de 2001 e 2002.

A indústria avícola vem passando por diversas modificações, sendo este setor, dentre outros setores agropecuários, o de maior dinamismo e crescimento. Estas mudanças acabam fazendo com que a avicultura absorva este aporte tecnológico citado acima, convertendo num dos sistemas mais lucrativos da produção animal.

3. MATERIAL E MÉTODOS

3.1 Dados de Registros

O estudo correspondeu a séries históricas de dados de matrizes de frango de corte, de um incubatório, de produção de frangos de corte e de um abatedouro de uma integração avícola do Rio Grande do Sul, durante os meses de julho de 2009 a janeiro de 2010.

A origem dos ovos foram de Matrizes da mesma empresa, entre 29 e 68 semanas de idade. Os pintos oriundos deste lotes foram vacinados por via subcutânea para Bronquite, Bouba Suave e Marek no primeiro dia de vida conforme indicações do fabricante.

Foi usado um total de 28 incubadoras, totalizando 4 milhões de nascimentos de pintos por mês que foram fornecidos a 147 propriedades. Ao final do teste somou-se á um total de 21 milhões de aves avaliadas.

A empresa participante do experimento forneceu um banco de dados com informações de vários lotes. Cada lote apresentará os seguintes itens:

- origem do nascedouro no incubatório;
- origem da incubadora no incubatório;
- quantificação da contaminação por *Salmonella sp.* nos nascedouros;
- quantificação da contaminação por *Aspergillus sp.* nos nascedouros;
- quantificação da contaminação por *E. coli* nos nascedouros;
- quantificação da contaminação por *Pseudomonas sp.* nos nascedouros;
- número de aviários por incubadora;
- ovo de cama/ninho;
- percentual de linhagem;
- ovo trincado;
- minutos de incubação;
- minutos de nascedouro;
- horas de estoque;
- eclosão total;
- eclosão vendável;

- ovos incubáveis;
- aproveitamento de ovos;
- idade da matriz;
- perda de peso de ovo;
- peso de pinto;
- peso de ovo;
- contaminação na transferência;
- tipo de pinto;
- fertilidade;
- tipo de máquina;
- produtor;
- extensionista;
- peso do frango de primeira semana;
- peso do frango de segunda semana;
- peso do frango de terceira semana;
- peso do frango de quarta semana;
- peso do frango de quinta semana;
- mortalidade do frango na primeira semana;
- mortalidade do frango na segunda semana;
- mortalidade do frango na terceira semana;
- mortalidade do frango na quarta semana;
- mortalidade do frango na quinta semana;
- linhagem;
- condenação total;
- condenação parcial.

3.2 Dados de Amostras

Para determinar os níveis de contaminação nas nascedouras, foram realizadas coletas com swabs de palito nos locais pré-definidos. Para as mostras de piso foram realizados swabs de propé para pesquisa de *Salmonella sp.*, *E. coli*, *Pseudomonas sp.* e *Aspegillus sp.*.

Para realizar tal procedimento, os swabs de palito foram embebidos em solução salina 0,85%, onde estes foram passados em uma área de 10 cm², também foram aplicados os swabs com pressão, numa inclinação, descrevendo primeiro, movimentos da esquerda para direita e depois de cima para baixo. Os swabs foram girados continuamente para que toda a superfície do algodão entrasse em contato com a superfície. Os swabs não foram segurados na região próxima ao algodão e a parte manuseada da haste foi quebrada na borda interna do tubo, antes de mergulhar o material amostrado.

Para preparação da amostra foram agitados os swabs amostrados em 2mL de solução salina 0,85%. Para a pesquisa de fungos retirou-se 0,1mL e após foi passado para uma placa de Agar Saboraud. As placas foram incubadas a 30° Celsius por 72 horas. Para realização da leitura das placas foram contadas todas as colônias de fungos e multiplicado por 20 vezes, o resultado descrito foi por ponto de coleta. Na pesquisa de bactérias retirou-se 0,1mL e estes foram passados em Agar Nutriente para contagem total, incubou-se a 37° Celsius por 18 a 24 horas, após foram contados os números de colônias, o resultado foi multiplicado por 20 vezes. Inoculou-se 1mL para 9mL de salina peptonada e incubou-se por 18 a 24 horas a 37° Celsius para o isolamento de *Salmonella sp.*.

3.3 Análise Estatística

A estatística descritiva e as diferenças entre as médias dos dados foram calculadas através do programa computacional SigmaStat® Statistical Software para Windows 2.03.

3.4 Redes Neurais Artificiais

Neste trabalho, o termo “entrada” identifica as variáveis escolhidas para o cálculo do modelo preditivo e a palavra “saída” a variável a ser predita. Foram utilizados o programa computacional NeuroShell®Predictor e NeuroShell®Classifier para a construção das redes neurais artificiais, desenvolvido pela Ward Systems Group.

Conforme a Figura 1 a arquitetura aplicada na construção é singular e foi desenvolvida para que ela “aprenda” rapidamente e não necessite de um conjunto de dados de teste para melhorar sua habilidade para generalizar, ou seja, dar respostas razoáveis para dados que ela nunca tenha visto anteriormente.

A rede iniciou encontrando relações lineares entre as entradas e a saída. Foram atribuídos pesos às ligações entre os neurônios de entrada e saída. Depois que esta relação é encontrada, outros neurônios são adicionados à camada oculta para que relações não lineares possam ser identificadas. Os valores de entrada na primeira camada foram multiplicados pelos pesos e passados para a segunda, que é oculta. Os neurônios da camada oculta ativam ou produzem saídas que são baseados na soma dos valores pesados que passaram por ela. A camada oculta transmite os valores para a camada de saída da mesma forma e os valores desejados são obtidos.

A rede aprende ajustando os pesos das interconexões entre as camadas. As respostas que a rede está produzindo são repetidamente comparadas com as respostas corretas e, em cada vez, os pesos das conexões são ligeiramente ajustados na direção da resposta certa. São adicionados tantos neurônios ocultos quanto forem necessários, até o máximo de 150, para retratar as características do banco de dados. Se o problema pode ser aprendido, é desenvolvido um conjunto estável de pesos que irão produzir boas respostas para as decisões ou previsões da amostra. O poder real das redes neurais fica evidente quando uma rede treinada pode produzir bons resultados mesmo para dados que ela nunca tenha “visto”antes.




Figura 1. Exemplo esquemático da arquitetura de rede neural.

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. O R^2 foi calculado através da fórmula $R^2=1-(SSE/SS_{yy})$, onde $SSE = \sum (\text{valor real} - \text{valor predito})^2$ e $SS_{yy} = \sum (\text{valor real} - \text{média dos valores})^2$. O QME foi calculado como sendo a média dos valores reais menos os valores preditos, elevados a potência 2 [QME = média (valores reais – preditos) ²].

Para o treinamento das redes foram usados 1.096 bancos de dados ou linhas, outras 1.095 serviram como testes para a validação das predições.

4. RESULTADOS

A rede criada para explicar os fenômenos envolvidos com a variável de saída eclosão total com 3 variáveis de entrada *Aspergillus sp.*, *E. Coli*, e *Pseudomonas sp.* apresentou $R^2 = 0,043492$, Erro médio de 5,73801 e correlação = -0,039124, não foi encontrada nenhuma relação.

A Tabela 1 contém os modelos escolhidos para explicar os diferentes parâmetros das quatro etapas do ciclo de produção na cadeia avícola no período de junho de 2009 a janeiro de 2010 de uma empresa avícola do sul do Brasil. Os resultados demonstram que as redes neurais artificiais geradas foram bem ajustadas e apresentaram R^2 elevado. Enfatizando-se que o R^2 perfeito é 1 e um coeficiente muito bom está próximo de 1.

Tabela 1 – Características dos modelos de rede neural gerados na fase de treinamento, para os distintos parâmetros de produção (saída).

Parâmetro de produção (saída)	Entradas	Erro médio	QME	R^2
Eclosão total	24	0,738097	3,073653	0,94389
Eclosão vendável	24	0,71703	3,182114	0,942297
Fertilidade	13	0,710964	1,357278	0,9118381
Mortalidade de 1 semana	27	0,011102	0,005509	0,983311
Mortalidade de 5 semanas	27	0,004802	0,00081	0,999477
Perda de peso de ovo	23	0,15471	0,120876	0,649822
Peso de 5 semanas	27	1,401392	88,69815	0,993415
Condenação parcial	37	0,004731	0,002959	0,997112
Condenação total	37	0,001617	0,000486	0,995538

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

A Tabela 2 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação Múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 2 - Características do modelo de rede neural para predição da saída Eclosão total.

Estatística da predição	Valores
R ²	0,94389
Erro médio	0,738097
Correlação	0,971761
QME	3,073653
RQME	1,753184

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

A Tabela 3 e a Figura 2 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída eclosão total.

Tabela 3 - Importância relativa (contribuições) das variáveis de entrada para a saída Eclosão total.

Entrada	Importância relativa
Peso de pintos em gramas	0,096
Média mês idade da matriz	0,096
<i>Aspergillus sp.</i>	0,086
Tipo de máquina	0,086
Origem do nascedouro	0,084
Minutos de incubação	0,082




Figura 2 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Eclosão total.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 4.

Tabela 4 - validação do modelo de redes neurais para a predição da Eclosão total pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,894194
Erro médio	0,963802
Correlação	0,94605
QME	5,928693
RQME	2,434891

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

Na Figura 3 é apresentada uma visão conjunta da totalidade dos lotes validados para Eclosão total.




Figura 3 – Valores reais (X) *versus* valores preditos (Y) da eclosão total para os 2191 lotes.

A Tabela 5 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 5 - Características do modelo de rede neural para predição da saída Eclosão vendável.

Estatística da predição	Valores
R^2	0,942297
Erro médio	0,71703
Correlação	0,97097
QME	3,182114
RQME	1,783848

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

A Tabela 6 e a Figura 4 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída eclosão total.

Tabela 6 - Importância relativa (contribuições) das variáveis de entrada para a saída Eclosão vendável.

Entrada	Importância relativa
Contaminação na transferência	0,092
Peso de pinto em gramas	0,086
Número de aviários por nascedouro	0,084
Minutos de nascedouro	0,083
Média mês idade da matriz	0,083
Minutos de incubação	0,082




Figura 4 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Eclosão vendável.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 7.

Tabela 7 - Validação do modelo de redes neurais para a predição da Eclosão vendável pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,90697
Erro médio	0,91396
Correlação	0,952996
QME	5,31747
RQME	2,305964

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

Na Figura 5 é apresentada uma visão conjunta da totalidade dos lotes validados para Eclosão vendável.

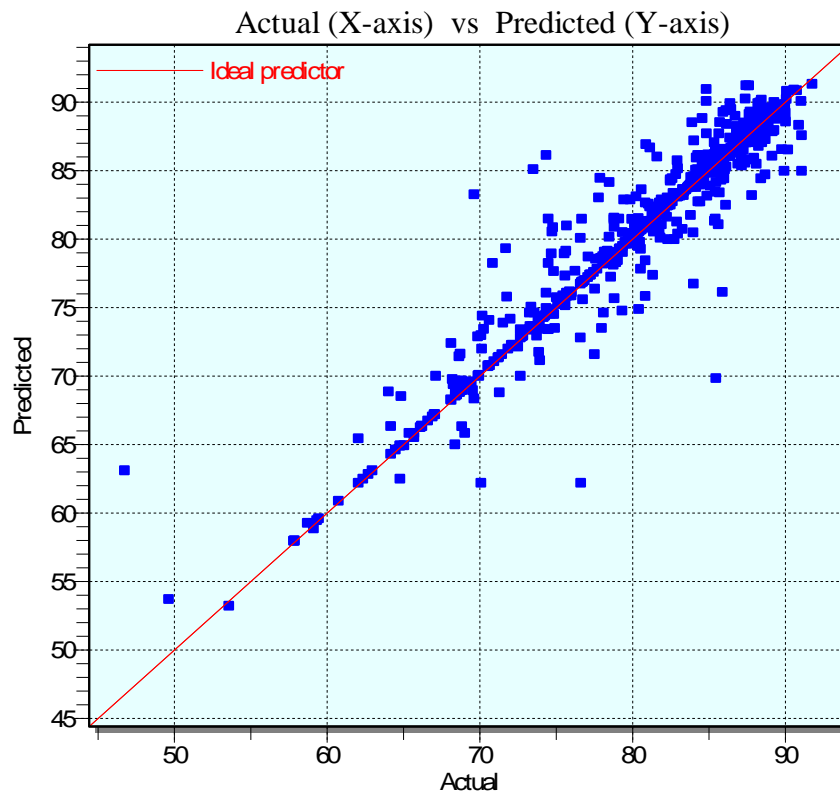


Figura 5 – Valores reais (X) versus valores preditos (Y) da eclosão vendável para os 2191 lotes.

A Tabela 8 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 8 - Características do modelo de rede neural para predição da saída Fertilidade.

Estatística da predição	Valores
R^2	0,918381
Erro médio	0,710964
Correlação	0,958508
QME	1,3157
RQME	1,147052

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

A Tabela 9 e a Figura 6 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Fertilidade.

Tabela 9 - Importância relativa (contribuições) das variáveis de entrada para a saída Fertilidade.

Entrada	Importância relativa
Origem do aviário	0,438
Média mês idade da matriz	0,438
<i>Aspergillus sp.</i>	0,055
Minutos de incubação	0,040
% de linhagem	0,017
Trincado	0,007

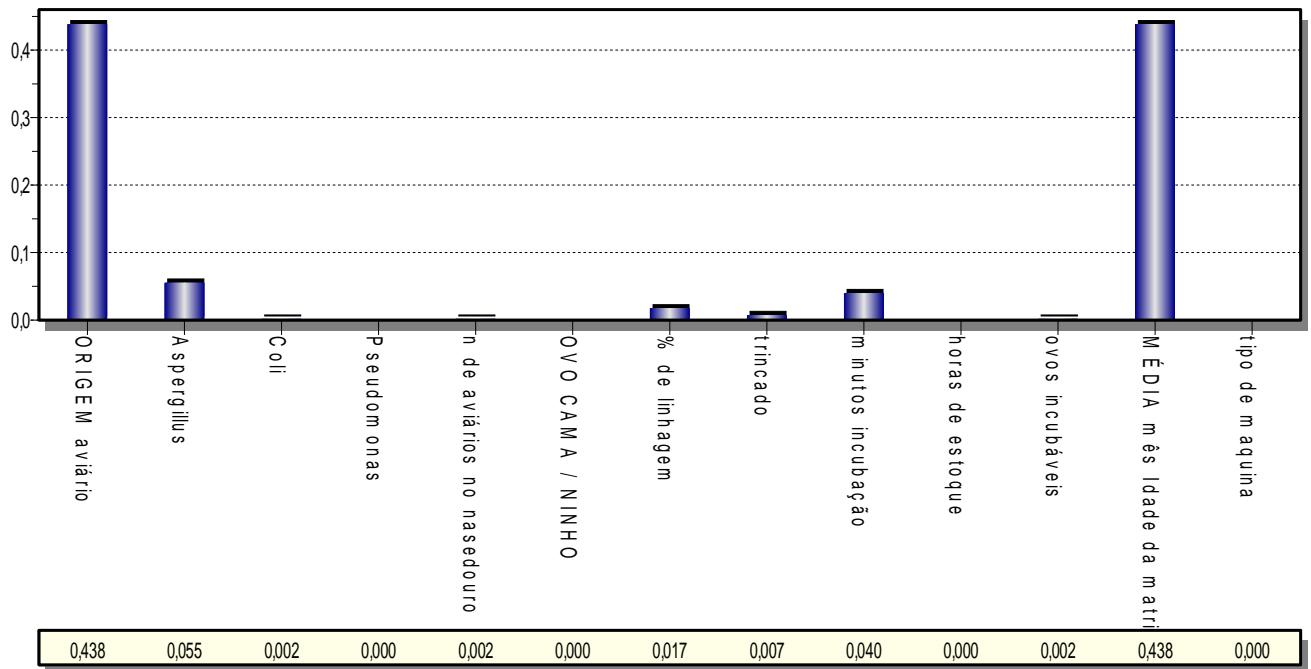


Figura 6 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Fertilidade.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 10.

Tabela 10 - validação do modelo de redes neurais para a predição da fertilidade pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,913129
Erro médio	0,755201
Correlação	0,956725
QME	1,420947
RQME	1,192035

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

Na Figura 7 é apresentada uma visão conjunta da totalidade dos lotes validados para Fertilidade.




Figura 7 – Valores reais (X) *versus* valores preditos (Y) da Fertilidade para os 2191 lotes.

A Tabela 11 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 11 - Características do modelo de rede neural para predição da saída mortalidade de 1 semana.

Estatística da predição	Valores
R^2	0,983311
Erro médio	0,011102
Correlação	0,99165
QME	0,005509
RQME	0,074222

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

A Tabela 12 e a Figura 8 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Mortalidade de 1 semana.

Tabela 12 - Importância relativa (contribuições) das variáveis de entrada para a saída Mortalidade de 1 semana.

Entrada	Importância relativa
Extencionista	0,153
Peso de 1 semana em gramas	0,151
Produtor	0,144
Sexo	0,109
Minutos de nascedouro	0,106
Minutos de incubação	0,090




Figura 8 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Mortalidade de 1 semana.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 13.

Tabela 13 - validação do modelo de redes neurais para a predição da Mortalidade de 1 semana pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,924788
Erro médio	0,019772
Correlação	0,964298
QME	0,023466
RQME	0,153188

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

Na Figura 9 é apresentada uma visão conjunta da totalidade dos lotes validados para Mortalidade de 1 semana.




Figura 9 – Valores reais (X) *versus* valores preditos (Y) da Mortalidade de 1 semana para os 2191 lotes.

A Tabela 14 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 14 - Características do modelo de rede neural para predição da saída mortalidade de 5 semanas.

Estatística da predição	Valores
R^2	0,999477
Erro médio	0,004802
Correlação	0,999742
QME	0,00081
RQME	0,02467

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

A Tabela 15 e a Figura 10 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Mortalidade de 5 semanas.

Tabela 15 - Importância relativa (contribuições) das variáveis de entrada para a saída Mortalidade de 5 semanas.

Entrada	Importância relativa
Extensionista	0,131
Sexo	0,131
Peso de 1 semana em gramas	0,127
Produtor	0,111
Contaminação na transferência	0,083
Ovo cama/ninho	0,079




Figura 10 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Mortalidade de 5 semana.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 16.

Tabela 16 - validação do modelo de redes neurais para a predição da Mortalidade de 5 semanas pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,999477
Erro médio	0,004802
Correlação	0,999742
QME	0,00081
RQME	0,028467

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

Na Figura 11 é apresentada uma visão conjunta da totalidade dos lotes validados para Mortalidade de 5 semanas.

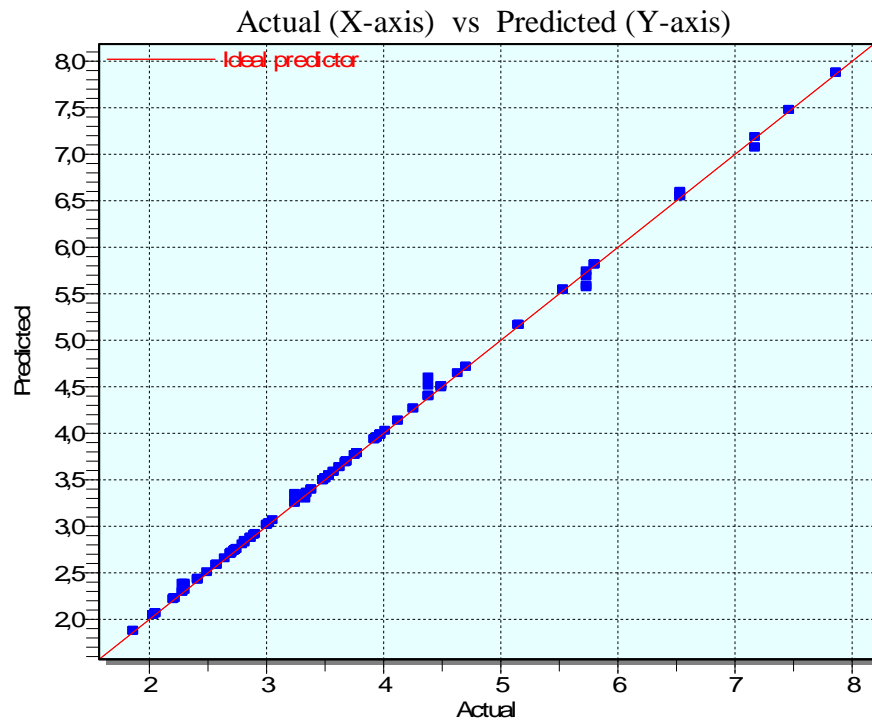


Figura 11 – Valores reais (X) *versus* valores preditos (Y) da Mortalidade de 5 semanas para os 2191 lotes.

A Tabela 17 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 17 - Características do modelo de rede neural para predição da saída Perda de peso do ovo.

Estatística da predição	Valores
R^2	0,649822
Erro médio	0,15471
Correlação	0,819544
QME	0,120876
RQME	0,347672

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

A Tabela 18 e a Figura 12 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Perda de peso do ovo.

Tabela 18 - Importância relativa (contribuições) das variáveis de entrada para a saída Perda de peso do ovo.

Entrada	Importância relativa
Origem do aviário	0,122
Peso de pintos em gramas	0,121
Minutos de nascedouro	0,109
Média mês idade da matriz	0,109
Peso de ovo em gramas	0,101
Contaminação na transferência	0,090




Figura 12 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Perda de peso do ovo.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 19.

Tabela 19 - validação do modelo de redes neurais para a predição da Perda de peso do ovo pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,560644
Erro médio	0,178553
Correlação	0,774043
QME	0,155397
RQME	0,394205

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

Na Figura 13 é apresentada uma visão conjunta da totalidade dos lotes validados para Perda de peso do ovo.

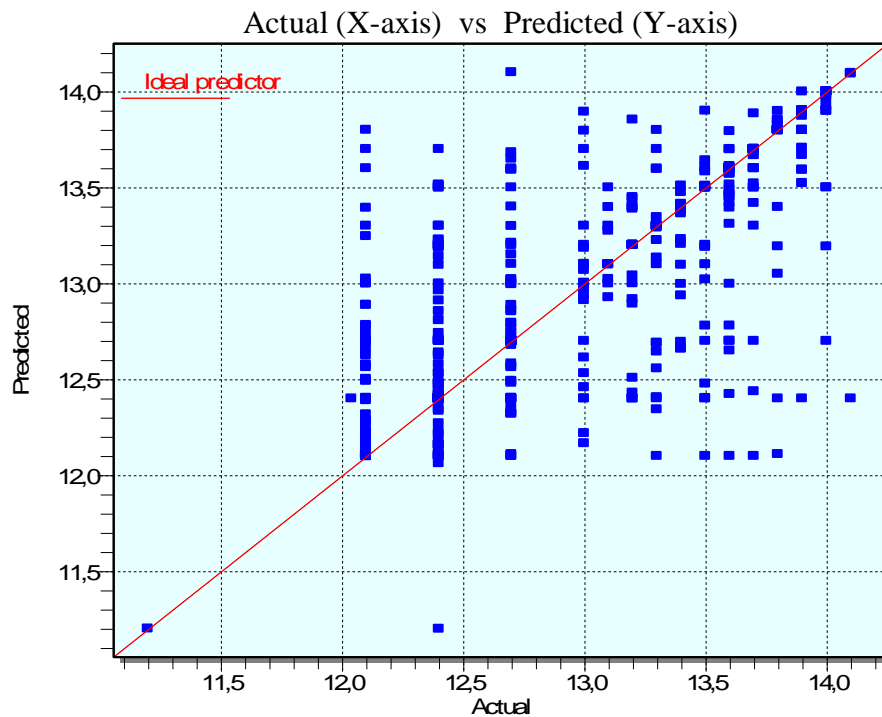


Figura 13 – Valores reais (X) *versus* valores preditos (Y) da Perda de peso do ovo para os 2191 lotes.

A Tabela 20 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R²) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 20 - Características do modelo de rede neural para predição da saída Peso de 5 semanas.

Estatística da predição	Valores
R ²	0,993415
Erro médio	1,401392
Correlação	0,996712
QME	88,69815
RQME	9,41797

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

A Tabela 21 e a Figura 14 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Peso de 5 semanas.

Tabela 21 - Importância relativa (contribuições) das variáveis de entrada para a saída peso de 5 semanas.

Entrada	Importância relativa
Produtor	0,154
Peso de 1 semana	0,154
Extensionista	0,152
Minutos de nascedouro	0,106
Ovo cama/ninho	0,099
Minutos de incubação	0,073




Figura 14 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Peso de 5 semanas.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 22.

Tabela 22 - Validação do modelo de redes neurais para a predição Peso de 5 semanas pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,971527
Erro médio	4,434234
Correlação	0,986405
QME	382,2787
RQME	19,55195

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

Na Figura 15 é apresentada uma visão conjunta da totalidade dos lotes validados para Peso de 5 semanas.

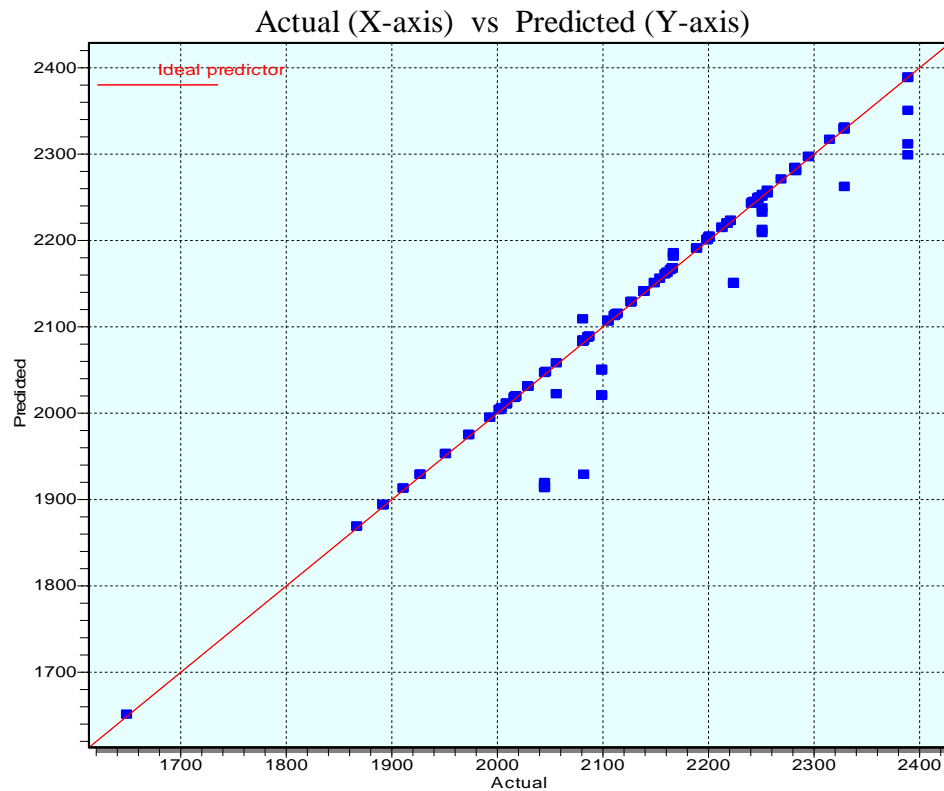


Figura 15 – Valores reais (X) *versus* valores preditos (Y) Peso de 5 semanas para os 2191 lotes.

A Tabela 23 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 23 - Características do modelo de rede neural para predição da saída Condenação parcial.

Estatística da predição	Valores
R^2	0,997112
Erro médio	0,004731
Correlação	0,998556
QME	0,002959
RQME	0,054397

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

A Tabela 24 e a Figura 16 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Condenação parcial.

Tabela 24 - Importância relativa (contribuições) das variáveis de entrada para a saída Condenação parcial.

Entrada	Importância relativa
Peso de 4 semanas	0,076
Sexo	0,076
Mortalidade de 5 semanas	0,074
Peso de 2 semanas	0,074
Mortalidade de 2 semanas	0,071
Mortalidade de 4 semanas	0,065




Figura 16 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Condenação parcial.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 25.

Tabela 25 - Validação do modelo de redes neurais para a predição Condenação parcial pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,98068
Erro médio	0,012488
Correlação	0,990372
QME	0,019819
RQME	0,140782

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

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

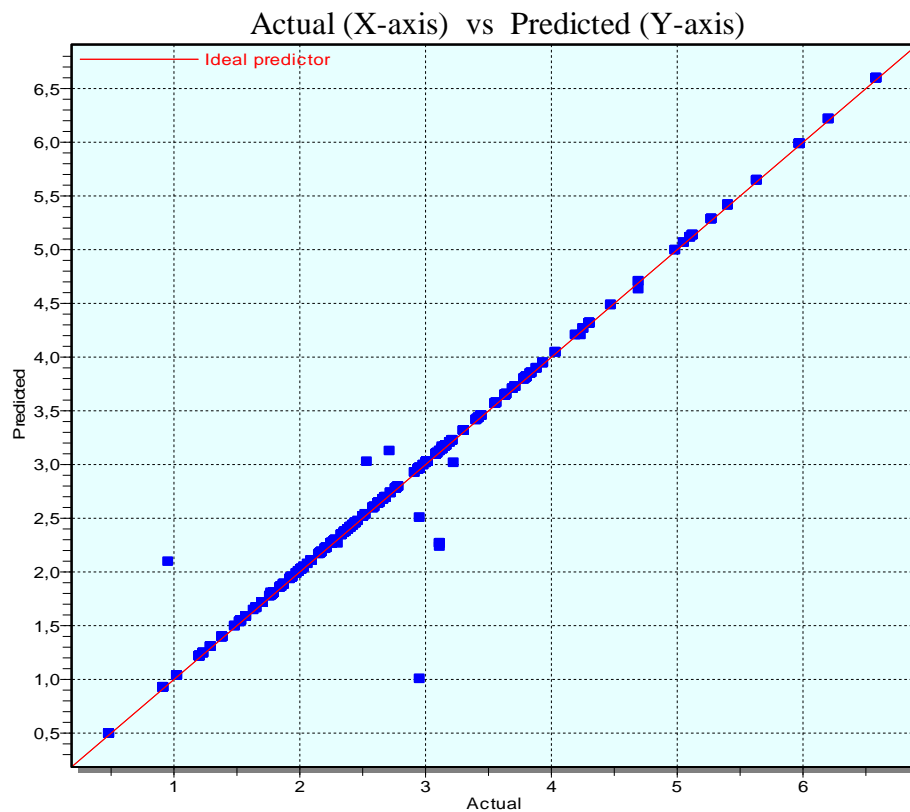


Figura 17 – Valores reais (X) versus valores preditos (Y) Condenação parcial para os 2191 lotes.

A Tabela 26 apresenta as características da rede neural quando aplicada a 1.096 lotes. Nota-se que há uma predição muito boa sustentada por um Coeficiente de Determinação múltipla (R^2) e Correlação elevados e por Quadrado Médio do Erro (QME) e Erro médio reduzidos.

Tabela 26 - Características do modelo de rede neural para predição da saída Condenação total.

Estatística da predição	Valores
R^2	0,995538
Erro médio	0,001617
Correlação	0,997766
QME	0,000486
RQME	0,022042

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

A Tabela 27 e a Figura 18 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Condenação total.

Tabela 27 - Importância relativa (contribuições) das variáveis de entrada para a saída Condenação total.

Entrada	Importância relativa
Peso de 5 semanas	0,065
Peso de 4 semanas	0,063
Mortalidade de 5 semanas	0,062
Mortalidade de 4 semanas	0,060
Mortalidade de 3 semanas	0,060
Minutos de incubação	0,056




Figura 18 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Condenação total.

Foram utilizados 1095 lotes para validar o modelo acima. Por ocasião da aplicação da rede as predições obtidas revelaram as estatísticas da Tabela 28.

Tabela 28 - Validação do modelo de redes neurais para a predição Condenação total pelos 1095 lotes.

Estatística da predição	Valores
R ²	0,98891
Erro médio	0,003824
Correlação	0,994455
QME	0,001201
RQME	0,034656

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

Na Figura 19 é apresentada uma visão conjunta da totalidade dos lotes validados para Condenação total.

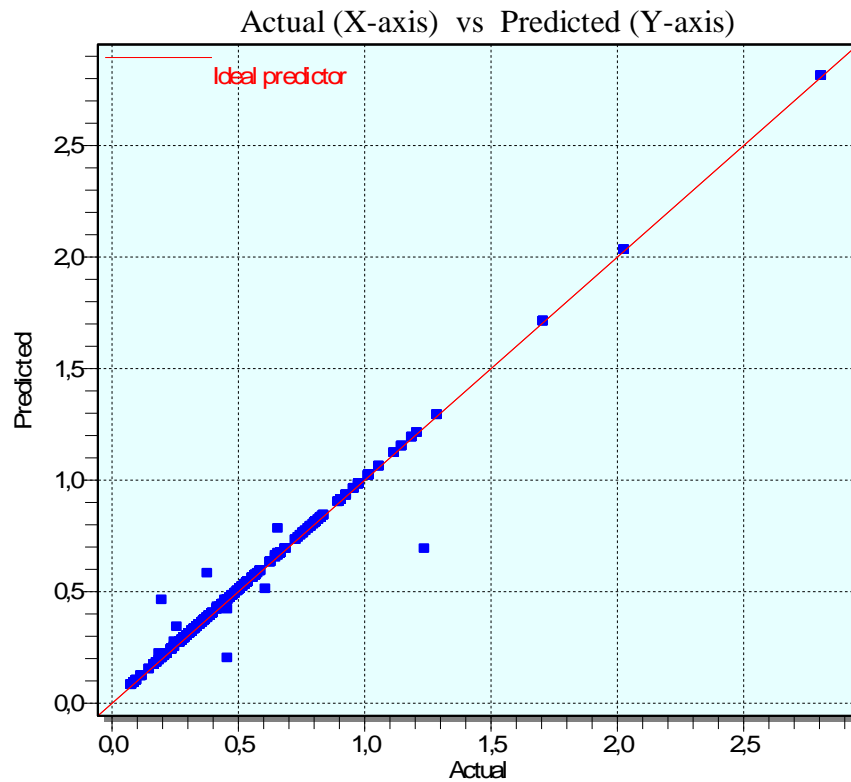


Figura 19 – Valores reais (X) *versus* valores preditos (Y) Condenação total para os 2191 lotes.

No caso da rede neural com saída para a variável tipo de pinto, a classificação correta das amostras na fase de treinamento foi de 94,84% e na validação obteve-se 92,69%. Os detalhes desta rede estão apresentados na Tabela 29. Entretanto, a especificidade das 3 categorias de tipo de pinto foi superior a 92%. A sensibilidade obteve números acima de 89% para as 3 categorias.

Tabela 29. Tabela de Contingência da validação da rede neural artificial para saída Tipo de pinto.

Classificação	Predição			Total
	Tipo 1	Tipo 2	Tipo 3	
Tipo 1	539*	38	1	578
Tipo 2	36	332*	3	371
Tipo 3	0	2	143*	145
Total (N)	575	372	147	1094
Sensibilidade (%) #	93,74%	89,25%	97,28%	
Epecificidade (%) ##	92,49%	94,6%	99,79%	

N número de amostras; * Número de amostras classificadas corretamente; # Positivo verdadeiro; ## Negativo verdadeiro

A Tabela 30 e a Figura 20 expressam as contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Tipo de pinto.

Tabela 30 - Importância relativa (contribuições) das variáveis de entrada para a saída Tipo de pinto.

Entrada	Importância relativa
Contaminação na transferência	0,141
Peso de ovo em gramas	0,134
Perda de peso em gramas	0,126
Origem aviário	0,119
Peso de pintos em gramas	0,107
Horas de estoque	0,077




Figura 20 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para saída Tipo de pinto.

5. DISCUSSÃO

O presente trabalho teve como objetivo principal demonstrar que as redes neurais artificiais foram capazes de explicar os fenômenos envolvidos entre as quatro etapas da cadeia avícola, reprodutoras pesadas, incubatório, produção de frangos de corte e abatedouro. Assim, o objetivo que motivou a realização deste trabalho foi plenamente atingido.

Dados gerados anteriormente por pesquisadores do CDPA já haviam demonstrado que esta metodologia pode ser utilizada para o gerenciamento de vários setores na produção da cadeia avícola. (Guahyba, 2001; Salle *et al.*, 2001; Salle *et al.*, 2003) demonstraram que esta metodologia pode ser utilizada para o gerenciamento de reprodutoras pesadas. No frango de corte (Reali, 2004), no incubatório (Salle, 2005) e no matadouro-frigorífico (Pinto, 2006). Na literatura consultada não foram encontradas publicações que utilizassem as redes neurais em quatro etapas da cadeia avícola, para que se pudessem comparar resultados. Isto ocorre pelo fato da maioria das empresas não possuírem um banco de dados interligados, ou seja, os dados são registrados de forma distinta, por setor e não podem ser analisados como um todo.

É sabido que as redes neurais necessitam de um grande número de registros para construir modelos precisos. Os dados fornecidos pela empresa foram bastante homogêneos e extremamente precisos. Foram utilizadas 2.191 linhas de dados referentes ao fechamento dos lotes, onde foi possível utilizar 1.096 linhas de dados para o treinamento de dez redes neurais que explicam e predizem as saídas de eclosão total, eclosão vendável, fertilidade, mortalidade de 1 semana, mortalidade de 5 semanas, perda de peso de ovo, peso de 5 semanas, condenação parcial, condenação total e tipo de pinto. Após testadas as importâncias relativas de entrada para a construção do modelo e o R^2 , o erro médio e o QME eram indicadores de um bom ajuste.

Os experimentos relatados com reprodutoras pesadas, frango de corte e incubatório, estabeleceram as importâncias relativas, ou contribuições de cada uma das variáveis de entrada para saída escolhida.

A rede criada para explicar os fenômenos envolvidos com a variável de saída eclosão total com 3 variáveis de entrada *Aspergillus sp.*, *E. coli*, e *Pseudomonas sp.*, não apresentou nenhuma relação, ou seja, esta prática somente vai refletir na verificação da higienização da máquina a ser utilizada no processo.

Na Tabela 1, pode-se verificar que as redes neurais geradas foram bem ajustadas e apresentam R^2 elevado. Sendo as variáveis de saída Mortalidade de 5 semanas, Condenação parcial e Condenação total com R^2 0,999477, 0,997112, 0,995538, respectivamente e que está muito próximo do máximo que é 1. Também é informado na mesma tabela, o número de variáveis de entrada utilizado para os distintos parâmetros de produção (saída) na fase de treinamento. Este número total de entradas descritos na tabela é elevado em comparação aos já mencionados em outros trabalhos. Esta é uma mudança importante em relação aos outros trabalhos com o gerenciamento através de redes neurais em avicultura, pois antes eram escolhidas as variáveis de entrada conforme o grau de importância. Este trabalho utilizou variáveis de entrada em maior número porque todas correspondiam aos fenômenos ocorridos antes de ocorrer a variável de saída. As variáveis de saída Condenação parcial e Condenação total possuíam 37 variáveis de entrada cada uma, ou seja, as variáveis de entrada correspondiam aos fenômenos envolvidos das matrizes de frango de corte, ao incubatório e ao frango de corte da mesma empresa.

O modelo treinado para Ecloração total está muito bem ajustado com valor $R^2=0,94389$, $QME=3,073653$ e Erro médio= 0,738097, conforme Tabela 2 e Figura 2. Pode ser verificado que as variáveis de entrada que mais contribuem para predição da Ecloração total são as "Média mês idade da matriz", "Peso de pintos em gramas", "Tipo de máquina", "Origem do nascedouro", "Minutos de incubação". Para predizer a Ecloração total e todas as outras redes do trabalho foi aplicado 1.095 linhas de dados. A Tabela 4 e a Figura 3 demonstram a precisão do modelo ao ser validado.

Da mesma forma o modelo treinado para Ecloração vendável está muito bem ajustado. Neste caso, as variáveis de entrada que mais contribuem para predição da Ecloração vendável conforme Tabela 6 e Figura 4 são "Contaminação na transferência", "Peso de pinto em gramas", "Número de aviários por nascedouro", "Minutos de nascedouro", "Média mês idade da matriz". A Tabela 7 e a figura 5 demonstram a precisão do modelo Ecloração vendável ao ser validado.

Com a variável Fertilidade foi possível a geração de um modelo que apresentou um excelente ajuste na fase de treinamento (Tabela 8). Na Tabela 9 e Figura 6 pode ser observado que as duas maiores participações relativas foram "Origem do aviário" e "Média mês idade da matriz", suas importâncias relativas somadas alcançam, aproximadamente, os 97,6%. A Tabela 10 e a Figura 7 demonstram a precisão do modelo Fertilidade ao ser validado.

O treinamento da rede neural para a variável de saída Mortalidade de 1 semana apresentou estatísticas excelentes e pode ser observada na Tabela 11. O R^2 da rede também é alto, seguido de QME e de Erro médio baixos. Pode ser observado na Tabela 12 e Figura 8 as importâncias relativas das contribuições atribuídas às variáveis de entrada "Extensionista", "Peso de 1 semana em gramas", "Produtor", "Sexo", "Minutos de nascedouro", "Minutos de incubação". As características da rede na validação estão na Tabela 13 e Figura 9, onde foram observados indicadores estatísticos que são próprios de um modelo ajustado com alta precisão nas predições efetuadas.

O exemplo de rede neural para variável de saída Mortalidade de 5 semanas seguiu a mesma trajetória dos modelos anteriores. Com $R^2= 0,999477$, acompanhado de QME e de Erro médio reduzidos, apresentou estatísticas excelentes. A importância relativa "Extensionista" das variáveis de entrada para saída Mortalidade de 5 semanas é a mais alta com a variável "Sexo" (Tabela 15 e Figura 10). Das dez redes neurais formadas no trabalho, a variável de entrada "Extensionista" é citada duas vezes como a importância relativa com o valor mais alto.

Quando avaliamos a rede neural para variável Perda de peso do ovo, esta não apresentou estatísticas tão boas como as outras redes presentes no trabalho, com $R^2=0,649822$, $QME=0,120876$ e Erro médio= $0,15471$ (Tabela 17). As principais importâncias relativas das variáveis de entrada para a saída Perda de peso do ovo são "Origem do aviário", "Peso de pintos em gramas", "Minutos de nascedouro", "Média mês idade da matriz", "Peso de ovo em gramas", "Contaminação na transferência", conforme Tabela 18 e Figura 12. Na Tabela 19 e Figura 13 foram observados indicadores estatísticos com não tão alta precisão nas predições efetuadas em comparação as outras redes presentes no trabalho.

O modelo treinado para Peso de 5 semanas foi muito bem ajustado com valor $R^2=0,993415$, $QME=88,69815$ e Erro médio= $1,401392$, conforme Tabela 20. Pode ser verificado que as variáveis de entrada que mais contribuem para predição da Peso de 5 semanas são as "Peso de 1 semana", "Produtor", "Extensionista", "Minutos de nascedouro", "Ovo cama/ninho", "Minutos de incubação" (Tabela 21 e Figura 14). Para predizer a Peso de 5 semanas a Tabela 22 e a Figura 15 demonstram a precisão do modelo ao ser validado.

A rede criada para explicar os fenômenos envolvidos com a variável de saída condenação parcial está expressa na Tabela 23. O modelo é preciso com valor $R^2=0,995553$, $QME=0,000486$ e Erro médio= $0,001617$. As variáveis de entrada que mais contribuem para predição da

Condenação parcial são as "Peso de 4 semanas", "Sexo", "Mortalidade de 5 semanas", "Peso de 2 semanas", "Mortalidade de 2 semanas", "Mortalidade de 4 semanas" (Tabela 24 e Figura 16). As características da rede na validação estão na Tabela 25 e Figura 17, onde foram observados indicadores estatísticos que são próprios de um modelo ajustado com alta precisão nas predições efetuadas.

Da mesma forma o modelo treinado para Condenação total está muito bem ajustado. Neste caso, as variáveis de entrada que mais contribuem para predição da Condenação total conforme Tabela 27 e Figura 18 são as "Peso de 5 semanas", "Peso de 4 semanas", "Mortalidade de 5 semanas", "Mortalidade de 4 semanas", "Mortalidade de 3 semanas", "Minutos de incubação" A Tabela 28 e a figura 17 demonstram a precisão do modelo Condenação total ao ser validado.

A rede neural com saída para a variável tipo de pinto, obteve 94,84% de classificação correta das amostras na fase de treinamento e 92,69% na fase de validação. A Tabela 29 demonstra uma especificidade alta para as 3 categorias de tipo de pinto, superior a 92% e a sensibilidade com números acima de 89% para as 3 categorias, indicando modelos estatísticos bem ajustados.

Ao serem analisados os resultados contidos no trabalho, apesar das variações ocorridas na rede neural criada para explicar os fenômenos envolvidos com a variável de saída Perda peso do ovo, as redes foram capazes de predizer os dados futuros com excelente confiabilidade. Também com exceção desta mesma rede, não houve diferença significativa entre as médias das predições e as médias dos valores reais dos modelos estudados. Na validação dos dados para as 1.095 linhas de dados nas redes neurais apresentadas, com exceção na rede neural criada para explicar os fenômenos envolvidos com a variável de saída Perda peso do ovo, as predições e os valores reais estão próximos.

6. CONCLUSÕES

1 - Não houve relação na rede com as variáveis de entrada *Aspergillus sp.*, *Pseudomonas sp.* e *E. coli* e com a variável de saída eclosão total.

2 - As redes neurais artificiais foram capazes de explicar os fenômenos envolvidos com a produção de reprodutoras pesadas e do frango de corte, de um incubatório e de um abatedouro avícola.

3 - A técnica apresentada permite obter critérios objetivos, gerados cientificamente, que servirão de suporte para tomadas de decisões dos responsáveis destes setores avícolas. Também estes poderão realizar simulações e medir a contribuição de cada variável no fenômeno em estudo.

REFERÊNCIAS

ASGAV (Associação Gaúcha de Avicultura). **Avicultura Brasileira**. Disponível na internet: www.asgav.com.br. Acesso em 10 de dezembro de 2010.

ABEF. Associação Brasileira dos Produtores e Exportadores de Frango,: **Relatório Anual 2008**. Disponível na internet:www.abef.com.br/Relatorios_Anuais.asp. Acesso em: 26/07/2009.

ASTION, M. L.; WILDING, P. The application of back propagation neural networks to problems in pathology and laboratory medicine. **Arch Pathol Lab Med**. V. 116, p.995-1001,1992.

BICCIATO, S.; PANDIN, M.; DIDONE, G.; DI BELLO, C. Pattern identification and classification in gene expression data using an auto associative neural network model. **Biotechnol Bioeng**. v.81, n.5,p.594-606, 2003.

BRANCO, J. A. D. Gerenciamento de Produção. In: MACARI, M.; MENDES, A. A. **Manejo de Matrizes de Corte**. Campinas: Facta, 2005. p. 369-396.

CHAO, K.; CHEN, Y. R.; HRUSCHKA, W.R.; GWODZ, F.B. On-line inspection of poultry carcasses by a dual-camera system. **Journal of Food Engineering**. V.51, p.185-192, 2002.

CHEDAD, A.; MOSHOU, D.; AERTS, J.M.; HIRTUM, A. Van; RAMON, H.; BERCKMANS, D. Recognition system for pig cough based on probabilistic Neural Networks. **Journal of Agricultural Research, Bristol**, v.79, n.4, p.449-57, 2001.

CHENG, B., TITERINGTON, D. M. Neural Networks; a review from a statistical perspective. **Statistical Science**. V.9, n.1, p.2-54,1994.

DEMELER, B.; Zhou, G. W. **Neural network optimization for *E. coli* promoter prediction**. Nucleic Acids Res. v.19, n.7, p.1593-1599, 1991.

ESTOCK, K. Nifty neural networks. **Independent Banker**. V.49, n.11, p.21-23,1999.

FAUSETT, L., **Fundamentals of Neural Networks: Architectures, Algorithms, and Applications**, Englewood Cliffs, NJ: Prentice Hall, 1994.

FORSSTRÖM, J.J.; DALTON, K.J. Artificial neural networks for decision support in clinical medicine. **Annals of Medicine**. V.27, n.5, p.509-517,1995.

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

GUSTIN, P. C. Gerenciamento Administrativo e Controle de Qualidade de Incubatório. In: MACARI, M.; GONZALE, E. **Manejo da Incubação**. Campinas: Facta, 2003. p. 471-498.

HAJMEER, M.; Basheer, I. **A probabilistic neural network approach for modeling and classification of bacterial growth/no-growth data**. J. Microbiol. Methods. v.51, n.2, p.217-226, 2002.

HAN, M.; SNOW, P. B.; BRANDT, J. M.; PARTIN, A.W. Evaluon of artificial neural networks for the predicton of pathologic stage in prostate carcinoma. **Cancer**. V.91, n.8 Suppl,p. 1661-1666, 2001.

IVEY, F. Desenvolvimento e aplicação de modelos de crescimento para frangos de corte. **Anais do I simpósio Internacional ACAV – Embrapa sobre Nutrição de Aves**. P.22-35,1999.

KANAYA, S.; Kinouchi, M.; Abe, T.; Kudo, Y.; Yamada, Y.; Nishi, T.; Mori, H.; Ikemura, T. **Analysis of codon usage diversity of bacterial genes with a self-organizing map (SOM): characterization of horizontally transferred genes with emphasis on the E. coli O157 genome**. Gene. v.276, n.1-2, p.89-99, 2001.

LOCH, T.; LEUSCHNEIDER, I.; GENBERG, C.; WEICHERT-JACOBSEN, K.; KUPPERS, F.; RETZ, M.; LEHMANN, J.; YFANTIS,.; EVANS, M.; TSAREV, V.; STOCKLE, M. Improvement of transrectal ultrasound. Artificial neural network analysis (ANNA) in detection and staging of prostatic carcinoma. **Urologe A**. v. 39, p.341-347,2000.

MANTEUFFEL, G.; SCHÖN, P.C. Measuring pig welfare by automatic monitoring of stress calls. **Agrartechnische Berichte, Bornim**, v.29, n.1, p.110-18, 2002.

MC CULLOCH, W. S., and PITTS, W., “A logical calculus of the ideas immanent in nervous activity,” **Bulletin of Mathematical Biophysics**, vol. 5, pp. 115-133, 1943, Reprinted in [Anderson and Rosenfeld, 1988]

MENDES. A. A.; PAZ. I. C. L. A.; MOREIRA. J. Produção e Características das Linhagens para Corte. In: MACARI, M.; MENDES, A. A. **Manejo de Matrizes de Corte**. Campinas: Facta, 2005. p. 1-10.

MINSKY, M. L. e PAPERT, S. A. Perceptrons: an introduction to computational geometry. 3. ed. Massachusetts: M.I.T. Press, 1988.

MOSIER, P. D.; Jurs, P. C.; Custer, L. L.; Durham, S. K.; Pearl, G. M. **Predicting the genotoxicity of thiophene derivatives from molecular structure**. Chem. Res. Toxicol. v.16, n.6, p.721-732, 2003

O'NEILL, M. C. **Escherichia coli promoters: neural networks develop distinct descriptions in learning to search for promoters of different spacing classes**. Nucleic Acids Res. v.20, n.13, p.3471-3477, 1992.

- O' SULLIVAN, O. Who's that knocking on my portal? **USBanker**. V.109, n.11, p.49-52, 1999.
- PARK, B.; CHEN, Y. R.; NGUYEN, M. Multi-spectral image analysis using neural network algorithm for inspection of poultry carcasses. **J. agric. Engng. Res.** v.69, p.351-363,1998.
- PAGNONCELLI. D. V. P. **Construindo estratégias para vencer**. Editora Campus Ltda, 6ª Edição / 2001.
- PARK, B.; CHEN, Y. R.; Matrix texture features of multi-spectral images on poultry carcasses. **J. agric. Engng. Res.** v.78, p.127-139, 2001.
- PINTO, P., R. **Dissertação de mestrado**. Uso de redes neurais artificiais no gerenciamento de matadouros-frigoríficos de aves e suínos no sul do Brasil., 2006. – UFRGS, 2006.
- REALI, Egídio Henrique. **Dissertação de Mestrado**: Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento da Produção de Frangos de Corte. Porto Alegre: UFRGS, Faculdade de Veterinária, PPGCV, 127 p., 2004.
- ROBEY, W.; GASPERONI, G.; HARLOW, H. The IGM® as a tool for modeling broiler growth and variation. Disponível em <http://www.novusint.com/nups/0495.htm>. Acesso em 15-07-2009.
- ROSENBLATT, F., "The perceptron: A probabilistic model for information storage and organization in the brain," **Psychological Review**, vol. 65, pp. 386-408, 1958.
- ROUSH, W. B. ; KIRBY, Y. K.; 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.; KIRBY, Y. K.; WIDEMAN JR., R. F. Probabilistic neural network prediction of ascites in broilers based on minimally invasive physiological factors. **Poult. Sci.** v.76, n.11, p.1513-1516,1997.
- SALLE, C. T. P.; SOARES, R.C.B.; CÉ, M.C.; MORAES, H.L.S. ; NASCIMENTO, V.P.;GUAHYBA, A.S. Immune response assessment in turkey breeders vaccinated against Newcastle disease using mathematical models. **Abstract of the 48th Western Poultry Disease Conference**. Vancouver – Canada, p. 129-129, 1999c.
- SALLE, C. T. P.; SOARES, R.C.B.; CÉ, M.C.; GUAHYBA, A.S.; MORAES, H.L.S.; NASCIMENTO, V.P.Immune response assessment in turkey breeder (*Meleagris gallopavo*) under Newcastle vaccine virus by mathematical models. **Abstracts of the IV Asia-Pacific Poultry Health Conference**. Melbourne – Austrália, p. 148-148, 1998c.
- SALLE, C. T. P.; SOARES, R.C.B.; CÉ, M.C.; SILVA, A.B.; MORAES, H.L.S.; NASCIMENTO, V.P.; GUAHYBA, A.S. Modelos matemáticos para avaliar a resposta imune de aves à doença de Newcastle. **A Hora Veterinária**. v. 102, p.41-44, 1998d.
- SALLE, C. T. P.; GUAHYBA, A. S.;WALD, V. B.; SILVA, A. B.; SALLE, F. O.; FALLAVENA, L. C. B. Uso de Redes Neurais Artificiais para Estimular Parâmetros de Produção

de Galinhas Reprodutoras Pesadas em Recria. **Revista Brasileira de Ciência Avícola**. V.3, p.257-264, 2001.

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

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

SNOW, P. B.; KERR, D. J.; BRANDT, J.M.; RODVOLD, D.M. Neural network and regression predicts of 5-year survival after colon carcinoma treatment. **Cancer**. V.91, n.8 Suppl, p1673-1678, 2001.

SOARES, J.; BENNITEZ, L.B.; TERRA, N.N. Análise de pontos críticos no abate de frangos através da utilização de indicadores microbiológicos. **Higiene Alimentar**, v.15, n.95, p.53-61, Abril 2002.

WIDROW, B. and M. E. HOFF, "Adaptive switching circuits," in **1960 WESCON Convention Record**, New York, 1960.

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

ZIADA, A. M.; LISLE, T. C.; SNOW, P.B.; LEVINE, R. F.; MILLER, G.; CRAWFORD, E.D. impact of different variables on the outcome of patients with clinically confined prostate carcinoma: prediction of pathologic stage and biochemical failure using an artificial neural network. **Cancer**. V.91, n.8 Suppl, p. 1653-1660, 2001.