

**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 DO INCUBATÓRIO DE UMA
EMPRESA AVÍCOLA DO SUL DO BRASIL**

**Felipe de Oliveira Salle.
Dissertação apresentada como requisito
para obtenção do grau de Mestre em
Ciências Veterinárias na área de
Medicina Veterinária Preventiva,
especialidade Sanidade Avícola.
Orientador: Carlos Tadeu Pippi Salle.
Co-orientador: Hamilton Luiz de Souza
Moraes**

**Porto Alegre
2005**

DEDICATÓRIA

Ao meu pai Carlos Tadeu Pippi Salle e a minha mãe Rita Helena de Oliveira Salle, pelo apoio e pela cumplicidade carinhosa que sempre nos manteve unidos, dedico a vocês esta dissertação por sempre acreditarem e lutarem ao meu lado, realizando críticas e ensinamentos que usei não somente durante estes dois anos de mestrado, mas em toda a minha educação. Puderam me proporcionar todas as oportunidades para assim ser, o filho que sou, e enfim poder crescer cada vez mais como pessoa nesse nosso mundo de hoje.

AGRADECIMENTOS

Ao meu amigo, pai, coordenador, orientador, e porque não dizer: professor nestes longos 30 anos da minha existência, Carlos Tadeu Pippi Salle. Obrigado por ser assim como você é. Agradeço igualmente ao meu co-orientador, e mais do que isso, ao meu amigo Hamilton Luiz de Souza Moraes pelos ensinamentos e pelo apoio nos meus obstáculos iniciais dentro da área da avicultura e fora dela. E por fim, agradeço ao meu segundo pai, que durante quase toda a minha vida tratou-me como um filho, e continua ao meu lado hoje, mesmo que espiritualmente, Ari Bernardes da Silva, meus sinceros agradecimentos.

SUMÁRIO

	p.
RESUMO	005
ABSTRACT	006
1 INTRODUÇÃO	007
2 REVISÃO BIBLIOGRÁFICA	010
3 MATERIAL E MÉTODO	021
3.1 Dados de registro	021
3.2 Análise estatística dos dados	021
3.3 Redes neurais artificiais	021
4 RESULTADOS	025
4.1 Classificação por linhagem	025
4.2 Redes neurais construídas com as informações obtidas com o fechamento dos lotes	029
4.3 Validação dos modelos de redes neurais	069
5 DISCUSSÃO	064
6 CONCLUSÃO	068
REFERÊNCIAS	069
APÊNDICE A – Pintos aproveitados em 1999	072
APÊNDICE B – Pintos nascidos em 1999	077
APÊNDICE C – Pintos refugo em 1999	080

RESUMO

O estudo foi feito através de séries históricas de dados de um incubatório pertencente a uma integração avícola do Rio Grande do Sul, durante os anos de 1999 a 2003, com os quais foram feitas análises do tipo observacional analítico e transversal. Primeiramente usou-se os registros de 5 linhagens de frangos utilizadas pela empresa no transcorrer do período de 23 de fevereiro de 1995 a 25 de janeiro de 2002. As linhagens foram identificadas da seguinte forma: COBB, HIGH YIELD, MPK, ROSS308, e X.

Esses 81 lotes analisados foram estudados através dos seus respectivos registros que continham: o número inicial de fêmeas, número inicial de machos, ração total/cabeça, ração/cabeça/inicial/recria, ração/cabeça/inicial/postura, ovos postos, ração p/ovo posto, pintos nascidos, percentagem viabilidade postura fêmea, percentagem viabilidade postura machos. O método aqui proposto provou ser capaz de classificar as linhagens a partir das entradas escolhidas. Na linhagem que apresentava uma grande quantidade de amostras a classificação foi muito precisa. Nas demais, com menor número de dados, a classificação foi efetuada, e, como era de se esperar, os resultados foram menos consistentes. Com o mesmo banco de dados dos lotes fechados, realizou-se a segunda etapa da dissertação. Nela, procedeu-se o treinamento das redes neurais artificiais onde foram utilizadas as seguintes variáveis de saída: ovos incubáveis, percentagem de ovos incubáveis, ovos incubados, percentagem de ovos incubados, pintos nascidos e pintos aproveitáveis. Os resultados apresentaram R^2 oscilando entre 0,93 e 0,99 e o erro médio e o quadrado médio do erro ajustados, demonstrando a utilidade das redes para explicar as variáveis de saída.

Na terceira e última etapa da dissertação, destinada à validação dos modelos, foram usados quatro arquivos distintos denominados da seguinte forma: INPESO (3.110 linhas de registros de pesos dos reprodutores), ININFO (56.018 linhas de registros com as informações diárias do ocorrido nas granjas de reprodução até o incubatório), INOVOS (35.000 linhas de registros com informações sobre os ovos processados), INNASC: 43.828 linhas de registros com informações sobre os nascimentos. O modelo gerado para o ano de 1999 foi capaz de prever corretamente os resultados deste mesmo ano e dos anos de 2000, 2001, 2002 e 2003. O mesmo procedimento foi repetido criando modelo com os registros do ano em questão e validando-o com os registros dos anos subsequentes. Em todas as ocasiões foram obtidos bons resultados traduzidos por um alto valor no R^2 .

Concluindo, os fenômenos próprios do incubatório puderam ser explicados através das redes neurais artificiais. A técnica, seguindo a mesma tendência das dissertações que anteriormente já haviam demonstrado que esta metodologia pode ser utilizada para o gerenciamento de reprodutoras pesadas e de frangos de corte, pode realizar simulações, previsões e medir a contribuição de cada variável no fenômeno observado, tornando-se uma poderosa ferramenta para o gerenciamento do incubatório e num suporte cientificamente alicerçado para a tomada de decisão.

ABSTRACT

The present study was made through historical series of data of a hatchery unit belonging to a poultry integration of Rio Grande do Sul, from 1999 to 2003, with which two types of analyses were made: analytic and traverse observacional. Firstly it was taken the registrations of five lineages of chickens used by the company between 23rd of February, 1995 and 25th of January, 2002. The lineages were identified in the following way: COBB, HIGH YIELD, MPK, ROSS308, and X.

Those 81 analyzed lots were studied through their respective registrations that contained: the initial number of females, initial number of males, total ration/chicks, ration/bird/initial/breeding phase, ration/bird/initial/laying, laying egg, ration per laying egg, born chicks, percentage of laying females viability, percentage of laying males viability. The method proposed proved to be capable classifying the lineages starting from the chosen entrances. The lineage that had a great amount of samples presented a very precise classification. In the others, with smaller number of data, the classification was made, and, as it was expected, the results were less consistent. With the same database of the closed flocks, we began the second stage of the dissertation. In this part, the training of the artificial neural networks was proceeded where the following exit variables were used: eggs incubated, percentage of eggs incubated, incubated eggs, percentage of incubated eggs, chicks born and chicks profitable. The results showed R^2 oscillating between 0,93 and 0,99.

The medium error and the medium square of the error fittings, demonstrated the usefulness of the nets to explain the exit variables.

In the third and last stage of the dissertation, destined to the validation of the models, four different files were denominated following way: INPESO (3.110 lines of registrations of weights of the reproducers), ININFO (56.018 lines of registrations with the daily information of what happened in the reproduction farms to the hatchery unit), INOVOS (35.000 lines of registrations with information about the processed eggs), INNASC: 43.828 lines of registrations with information of the births. The model generated for 999 was capable of predicting correctly the results of this very year and the years of 2000, 2001, 2002 and 2003. The same procedure was repeated creating a model with the registrations of 1999 and validating it with the registrations of the subsequent years. In every occasion good results were obtained illustrated by a high value in the R^2 .

Finally, the phenomena of the hatchery unit could be explained through the artificial neural networks. The technique, following the same tendency of the dissertations which previously had already demonstrated that this methodology can be used for the management of broiler breeders and of broiler production, can accomplish simulations, predictions and measure the contribution of each variable in the observed phenomenon as well, becoming a powerful tool for the management of the hatchery unit and strong scientific support for taking decisions.

1 INTRODUÇÃO

A avicultura brasileira ocupa posição de destaque no agronegócio brasileiro. A Associação Brasileira de Exportadores de Frangos (ABEF) fornece dados que sustentam esta afirmação. As exportações brasileiras de carne de frangos somaram 2,336 milhões de toneladas entre janeiro e novembro de 2004, com aumento de 23,4% em relação ao mesmo período de 2003. E a receita cambial, chegou a US\$ 2,350 bilhões, o que corresponde a um crescimento de 43% na mesma comparação. Isso representa mais um recorde nas exportações do setor, levando a estimativas de um fechamento de 2004 com embarques de 2,4 bilhões de toneladas (22% acima do verificado em 2003) e receita de US\$ 2,5 bilhões (com um crescimento de 40% sobre o ano anterior). Para 2005, está projetado um crescimento de 10% em volume e de 15% nos valores.

A importância social do segmento é reconhecida ao tornar viável o minifúndio e fixar o homem ao campo. Estes fatos reduzem os cinturões de miséria dos grandes centros urbanos, originados, fundamentalmente, pela desesperança e desilusão dos agricultores refletindo-se de modo positivo na diminuição da criminalidade. Esta última é uma das maiores preocupações do cidadão brasileiro nos dias atuais.

O Brasil, com suas reconhecidas desigualdades sociais, encontrou na avicultura uma fonte de proteína animal de alta qualidade e de baixo custo para as camadas menos favorecidas da população. O consumo per capitã de carne de frango chegou aos 33,32 kg refletindo um aumento de 2,5 vezes sobre a quantidade consumida em 1990 que era de 13,60 kg.

O Rio Grande do Sul ocupa a terceira posição entre os estados produtores e exporta cerca de 600 mil toneladas, ou 28% da sua posição. A Associação Gaúcha de Avicultura (ASGAV) informa que no Estado existem 14 frigoríficos com Inspeção Federal e 6 com Inspeção Estadual. Toda a estrutura que envolve a avicultura é responsável por 45 mil empregos diretos e 800 mil indiretos; 8,5 mil produtores integrados, com um plantel permanente de 60 milhões de pintos de corte e 2,5 milhões de avós/matrizes/poedeiras comerciais.

Há apenas 40 anos, a avicultura brasileira deixava de ser uma atividade de fundo de quintal e tinha ações negociadas nas bolsas de valores. É o resultado da implantação constante de tecnologia, principalmente de origem externa. A incorporação da tecnologia externa, muitas vezes, foi feita sem uma reflexão mais aprofundada para definir sua adaptação às necessidades locais. Portanto, claramente foi pouco cultivado o

espírito do desenvolvimento científico e tecnológico nas empresas brasileiras, o que deixou em segundo plano os projetos de cooperação entre as instituições de ensino e pesquisa e as empresas avícolas, com flagrantes prejuízos para o desenvolvimento setorial, sem falar na renúncia constante aos recursos oficiais destinados a promover este tipo de integração. Um simples levantamento no número e na qualidade das pesquisas internacionais, principalmente nos Estados Unidos da América e no Reino Unido, na área avícola, realizadas nos últimos 40 anos, demonstrará que, entre muitos outros temas, foi desenvolvida a vacina contra a doença de Marek, um tipo de câncer linfático das aves.

Esta vacina, utilizada maciçamente nos plantéis avícolas desde o início da década de 70, foi a primeira realmente eficaz contra esta terrível enfermidade e se constitui num atestado de excelência científica. Por outro lado, neste mesmo período de tempo, os resultados são pouco expressivos, no que diz respeito a vacinas aviárias desenvolvidas no Brasil, as linhagens genuinamente brasileiras competitivas comercialmente, ao desenvolvimento de técnicas de diagnóstico e novas drogas medicamentosas amparadas na pesquisa local. Cabe destacar a desproporção entre a dimensão da avicultura industrial brasileira e a capacidade instalada nas instituições de ensino e de pesquisa do nosso País para prover a renovação tecnológica referida anteriormente. Esta é a maior evidência da nossa fragilidade, quando comparada com nossos competidores. A timidez da pesquisa na área, principalmente naquela que se transformou no calcanhar de Aquiles, a sanidade avícola, é a maior ameaça à manutenção dos mercados atuais ou à conquista de novos. Lembremo-nos que os países que investem os maiores percentuais do PIB e cultivam a parceria entre universidade e empresa na geração do conhecimento, são os mais ricos do mundo. E são eles os nossos maiores rivais.

Esta visão crítica, sem querer desestimular o espírito, serviu com estímulo na busca de novas alternativas para melhorar o gerenciamento da produção avícola. Desta forma já foram desenvolvidos no Centro de Diagnóstico e Pesquisa em patologia Aviária (CDPA), da Faculdade de Veterinária, Universidade Federal do Rio Grande do Sul (UFRGS) projetos de pesquisas, sob a forma de teses de doutorado e de dissertações de mestrado, que utilizaram inteligência artificial, especificamente redes neurais artificiais (RNA), para o gerenciamento da produção de reprodutoras pesadas e da produção de frangos de corte com excelentes resultados.

Pode-se dizer que o incubatório moderno é uma fábrica de pintos. Todos os dias são recebidos milhares de ovos incubáveis e deles nascem indivíduos que necessitam dos melhores cuidados e devem ser distribuídos em segurança para as diferentes granjas que compõem o complexo produtivo de uma integração avícola. É um setor nevrálgico no qual os erros são traduzidos em prejuízos à produção e à imagem da empresa e com isso, surge uma punição em milhares de reais. Neste setor, são empregadas modernas técnicas de gestão e, como de resto em todo o segmento produtivo, é gerada uma infinidade de registros. Assim, sendo, e dando continuidade à linha de pesquisa que usa as RNA no gerenciamento da avicultura, foi desenvolvido este trabalho que pretende demonstrar, pela primeira vez, que esta tecnologia é capaz de explicar os fenômenos que envolvem a produção de pintainhos e permite simular e prever resultados, instrumentos fundamentais para o gerenciamento do incubatório.

2 REVISÃO BIBLIOGRÁFICA

Chesini (1989), já alertava para a importância dos custos de produção no processo produtivo avícola, porém não detalhava suas conclusões. Posteriormente, Franco (1996), apresentou um trabalho onde comparou o custo de produção dos 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 alcançasse os índices técnicos obtidos pelos melhores criadores (dados da época). Morris (1995), também realizou cálculos demonstrando os custos de prevenção e controle de doenças avícolas. O autor concluiu que os benefícios são muito maiores do que os custos dos programas preventivos.

Lima e Bersch (2000), comparando diversos equipamentos, concluíram que a região onde estava localizada a granja influenciava na avaliação do equipamento para melhor, ou para pior.

Foi demonstrado que há uma relação linear entre a quantidade de enzima adicionada à dieta de frangos de corte, quando expressada como um valor logaritmo, e o correspondente desempenho dos pintos. Baseados nisso, os autores concluíram ser possível prever corretamente a resposta de pintos conseqüente à adição da enzima na dieta, usando uma equação relativamente simples por Zhang *et al.*(1996).

A análise multivariada foi a escolhida para investigar possíveis associações entre celulite e outras categorias de condenações em um frigorífico por Elfadil *et al.*(1996). Através deste modelo, os autores foram capazes de avaliar os fatores de risco associados à celulite nos frangos de corte.

Quando foram comparados modelos obtidos de regressão logística e modelos obtidos de regressão linear para prever a ocorrência de ascite em frangos de corte, concluiu-se que embora a regressão linear prediga freqüentemente a incidência de ascite tão bem quanto a regressão logística, esta última é o teste estatístico mais apropriado para ser usado no experimento. (KIRBY *et al.* 1999)

Pesquisadores da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) em Concórdia-SC, 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 para comparações com outros tratamentos. Foram descritos modelos matemáticos estatísticos para estimar, com precisão, curvas de produção de ovos, levando em conta a idade das aves por Fialho & Ledur (2000a) e Fialho & Ledur (2000b). Os autores concluíram que o modelo proposto pode ser utilizado em situações práticas por profissionais, tanto na pesquisa científica quanto na produção.

Ivey (1999), descreveu um programa computacional, baseado em modelos matemáticos estatísticos, 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. Robey *et al.*(2000), desenvolveram programa para computador com o qual, é permitido 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.

As dificuldades encontradas pelos veterinários para avaliar a resposta imunológica após as vacinações foram objeto de estudo no Centro de Diagnóstico e Pesquisa em Patologia Aviária (CDPA) da UFRGS. Soares (1995), bem como Salle *et al.* (1998c, 1998d e 1999c), desenvolveram modelos matemáticos simplificados, usando idade e título de anticorpos, para avaliar a resposta imunológica em reprodutoras à doença de Newcastle, bronquite infecciosa e doença infecciosa bursal. 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 destas enfermidades.

De acordo com Salle *et al.*(1998a; 1999a) foram realizadas análises quantitativas para aflatoxina e ocratoxina em amostras de ração 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. 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 criador. Dos resultados obtidos, foi verificado que é possível correlacionar níveis de aflatoxina e de ocratoxina em alimentos e vísceras de frangos de corte com os parâmetros produtivos do lote.

Sobre este tema, Salle e 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.

A estatística convencional demonstrou sobejamente sua utilidade como ferramenta de suporte às decisões, mas, a partir de meados do século XX, foram desenvolvidas novas tecnologias que utilizam inteligência artificial, entre elas, as redes neurais artificiais.

Rosenblatt, em 1958 descreveu o perceptron que é, na verdade, um modelo computacional inspirado no neurônio humano e precursor das redes neurais artificiais.

As redes neurais foram inspiradas na estrutura e na função de neurônios biológicos. Redes neurais “aprendem” ajustando as interconexões dos pesos entre as camadas de neurônios. As respostas obtidas são, repetidamente, comparadas com as respostas corretas e, em cada vez, os pesos das conexões são ajustados ligeiramente na direção da resposta correta. São adicionados tantos neurônios escondidos quantos forem necessários para a maior precisão da resposta. 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 e WILDING, 1992; ROUSH *et al.*, 1996; XIN, 1999) Os “neurônios” da rede podem receber importância relativa das entradas excitatórias ou inibitórias de outros neurônios (FORSSSTRÖN e DALTON 1995) e produzem uma saída, que geralmente é uma função não linear da entrada da rede. (ASTION e WILDING, 1992) Em contraste com muitos sistemas especialistas, as redes neurais artificiais não dependem de algoritmos pré-definidos (LEE *et al.*, 1999).

Kovács (1996), escreveu que fenômenos complexos têm sido área fértil para o desenvolvimento de modelos com redes neurais. A complexidade reside em envolver várias variáveis com causas inter-relacionadas e dependentes, mas que não podem ser explicadas por uma relação linear ou não linear do tipo polinomial de primeira ordem. 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 em estudo. Neste sentido, podem ser consideradas como uma panacéia pragmática que funciona, mas não se conhece o porquê.

Anteriormente, 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 detalhar) o conhecimento adquirido por qualquer rede de retropropagação. Por esta razão, as redes neurais são frequentemente chamadas de "caixas pretas". Elas aprendem a calcular uma saída corretamente a partir de um padrão de entrada, mas dificilmente revelam, sob qualquer forma compreensível, o que as levou a tais julgamentos. Assim sendo, os mesmos autores enumeram as vantagens e as desvantagens das redes neurais artificiais, as quais são transcritas a seguir.

Vantagens:

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

- 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.

A utilização das redes neurais artificiais tem sido intensa e variada. Podem servir para classificar e reconhecer padrões; reconhecer e gerar fala; otimizar processos

químicos; prever índices financeiros, tais como taxas de câmbio de moedas; reconhecer alvos e localizar 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 à mão; entre outros. (CHENG e TITTERINGTON 1994)

Também são usadas em bancos, principalmente quando se fala de cartões de crédito e, especificamente, de comércio eletrônico através da internet, como segurança contra fraudes nestas operações, de acordo com O'Sullivan (1999) e Estock (1999).

Na medicina humana, as redes neurais artificiais são utilizadas extensivamente.

O diagnóstico do câncer de mama tem nas redes neurais artificiais uma poderosa aliada, quando imagens são analisadas para estabelecer o prognóstico (DAWSON *et al.* 1991). Também 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) As redes neurais foram empregadas para estabelecer o prognóstico para cinco anos do carcinoma de cólon (SNOW *et al.* 2001), um dos três tipos de câncer mais prevalentes nos países desenvolvidos. (ARGOV *et al.* 2002) Recentemente, as redes neurais foram usadas para relacionar marcadores fenotípicos específicos com genes e estado fisiológico em pacientes com este tipo de doença. (BICCIATO *et al.* 2003)

Pacientes com cardiopatia e submetidos à cirurgia foram avaliados em termos de sobrevivência, ou não, através do “aprendizado” das redes neurais sobre as relações de 11 fatores de risco presentes em 1875 pacientes durante um mês de observações. Os autores concluíram que a nova técnica é dinâmica e mais precisa na predição, quando comparada com a metodologia anteriormente utilizada (BUZATU, *et al.* 2001).

Nas emergências hospitalares, os pacientes com dores peitorais receberam o diagnóstico de isquemia cardíaca mais sensível e específico, quando ele foi realizado em base nas redes neurais (BAXT, *et al.* 2002). De forma similar, os eletrocardiogramas intra-cardíacos são mais precisos quando esta moderna tecnologia é empregada (CHETHAM *et al.* 2002).

Na área da medicina veterinária o emprego das redes neurais artificiais ainda é pequeno, e a avicultura parece ser a área melhor contemplada.

A mastite bovina é um dos maiores problemas enfrentados pelos produtores de leite e constantemente são pesquisadas formas de melhorar o diagnóstico precoce. Com este objetivo em mente (HEALD *et al.* 2000) construíram um método computacional

baseado em redes neurais artificiais capazes de classificar as causas bacterianas da doença em tambos leiteiros na Pennsylvania e concluíram que ele era melhor do que os métodos convencionais utilizados anteriormente.

O Brasil abate bilhões de frangos de corte anualmente e a inspeção sanitária ancorada na observação visual parece estar com os dias contados. Trabalhos recentes desenvolvidos nos Estados Unidos da América propuseram um novo tipo de inspeção sanitária nos abatedouros avícolas. Este sistema, resume-se na análise de imagens das carcaças, utilizando as redes neurais artificiais como geradoras do critério de aceitação ou de rejeição. Nos distintos experimentos realizados, analisam-se não só a coloração da pele, mas, inclusive, sua textura. O método é confiável e a margem de acerto das predições está acima dos 95%. (PARK *et al.*, 1998; PARK e CHEN, 2001; CHAO *et al.*, 2002)

Pesquisadores norte-americanos utilizaram a rede neural como uma predição probabilística de ascite em frangos de corte. Uma rede neural probabilística foi treinada para predizer ascite baseada em fatores fisiológicos que não necessitam da morte da ave. As importâncias relativas das entradas da rede 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 incrementar 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 *et al.* 1996; ROUSH *et al.* 1997)

No final dos anos 90, nos Estados Unidos da América, foram estudados dois tipos de redes neurais artificiais (retro-propagação e rede neural de regressão geral) para predição de níveis de aminoácidos em ingredientes alimentares. Além disso, os autores compararam tais redes neurais frente às 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 retro-propagação. (ROUSH *et al.* 1997; CRAVENER, 1999)

A síndrome da hipertensão pulmonar dos frangos de corte mereceu a atenção dos investigadores que procuraram avaliar a relação entre os padrões individuais de ganho de peso e a susceptibilidade dos animais a contraírem a enfermidade. Para isto, utilizaram as redes neurais e concluíram que esta metodologia é capaz de identificar os animais suscetíveis a desenvolverem a síndrome ao aplicarem os modelos para a

velocidade no ganho de peso nos primeiros 14 dias de vida dos animais. (ROUSH e WIDEMAN, 2000; ROUSH *et al.* 2001)

Para estabelecer um procedimento a fim de diferenciar através da inspeção mecânica, frangos normais daqueles com septicemia e toxemia, foram realizadas medidas espectrais de 300 fígados divididos igualmente em normais e condenados por septicemia e toxemia. A classificação por redes neurais dos dados apresentou uma precisão na classificação de 96%. (DEY *et al.* 2003)

No CDPA-UFRGS foram realizados trabalhos originais utilizando-se as redes neurais artificiais no gerenciamento de reprodutoras pesadas. Guahyba (2001), Salle (2001), Salle (2003). Os resultados obtidos demonstraram que é possível explicar os parâmetros de desempenho das aves, 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.

Recentemente, foi defendida uma dissertação de mestrado na qual são utilizadas as redes neurais para explicar os fenômenos envolvidos com a criação de frangos de corte. Os resultados demonstraram com clareza que esta metodologia é adequada e, como na tese de doutorado citada anteriormente, mostrou-se eficaz para o gerenciamento deste segmento da avicultura. Nesta dissertação, os modelos de redes neurais foram validados, através das predições e das respectivas comprovações dos valores reais obtidos, em centenas de lotes de frangos de corte produzidos durante os anos de 2001 e 2002. (REALI, 2004) Outra área importantíssima na produção avícola é o incubatório, local que deixou de ser uma simples reprodutora de pintos. A avicultura, antes da década de 30, resumia-se basicamente em multiplicação de pintos de um dia

deforma não profissional, com índices muito baixos de produtividade, tecnologia informal e passada de pai para filho sem nenhuma visão de negócio. A produção avícola antigamente era muito mais simplista, já que não tinha nenhuma visão empreendedora, deixando assim de lado, variáveis tais como: biossegurança, crescimento industrial e competitividade. Com o passar do tempo isso foi mudando, e com juntamente essas mudanças, todas as variáveis relacionadas com este setor do agronegócio em questão foram sendo gradualmente alteradas. (GUSTIN, 2003)

Os chineses e egípcios já usavam a incubação artificial aproximadamente 3.000 A.C., onde faziam câmaras-fornos com tijolos e produziam calor com a queima de esterco de camelos. Estas incubadoras tinham capacidade para 90.000 ovos e a eclosão atingia até 69%. Os chineses usavam jarras de barro onde estocavam os ovos em locais previamente aquecidos por carvão em brasa.

Em 1747, Reaumur, um cientista francês, construiu caixas que continham esterco em decomposição como fonte de calor para incubar os ovos. Posteriormente este método foi adaptado em barris e juntamente com termômetro, igualmente inventado por Reumur, acabou sendo muito usado pelos granjeiros (AMORIN *et al.* 1985)

O termo qualidade dos pintos cobre todas as variáveis que podem se relacionar diretamente com a habilidade do pinto de gerar lucro. A qualidade de saúde do pinto é um componente de qualidade dos pintos. Controlar este tipo de qualidade implica assegurar que o pinto não é portador de certas infecções: Salmonelose, micoplasmose, colibacilose, etc. (BORNE, 2003) Várias modificações ocorridas nos incubatórios tais como: introdução do monitoramento por computador, controle das máquinas, automatização de vários processos diários de operação, além da melhora na conscientização da importância do incubatório no controle de doenças.

Segundo Adda, (2003) o sucesso para a produção de pintos de um dia depende de ótimas condições de eclodibilidade. Ovos férteis precisam receber correta ventilação, temperatura, umidade e viragem para que o embrião desenvolva-se adequadamente.

O despertar do interesse de grupos econômicos que, investindo, em pesquisas, captação de conhecimento tácito, determinação da configuração básicas dos processos e produtos, vem fazendo desse setor, dentre outros setores agropecuários, o de maior crescimento e dinamismo, tanto econômico-financeiro como tecnológico, especialmente pelos avanços nas áreas de nutrição, sanidade, manejo e, atualmente, ambiência, moldando um padrão mais eficiente e competitivo para o setor (GUSTIN, 2003).

Essas mudanças acabam fazendo com que a avicultura nesses últimos quarenta anos venha sofrendo desenvolvimentos sem precedentes, partindo dos antigos frangos de peito duplo até chegarem às atuais linhagens genéticas. Tal aporte tecnológico citado acima, foi avidamente incorporado pelos empresários avícolas promovendo a transformação da criação de galinhas no agronegócio avícola dos dias atuais que gera empregos, viabiliza o minifúndio e arrecada divisas para o Brasil, através de exportações.

A avicultura industrial moderna se converteu num dos sistemas mais lucrativos da produção animal: isso se deve basicamente a organização dentro de sistemas de integração vertical, utilizando uma economia de escala, a contínua geração e aplicação relativamente mais rápida de ciência e tecnologia e o desenvolvimento de novos produtos de valor agregado.

A medida do sucesso de qualquer incubatório é o número de pintinhos de primeira produzidos. Este número representa uma porcentagem sobre o total de ovos colocados nas máquinas durante a incubação. O nascimento é influenciado por vários fatores. Alguns destes fatores são de responsabilidade do granjeiro e outros são de responsabilidade do incubatório. Fertilidade é um ótimo exemplo de um fator que é inteiramente influenciado pela granja; o incubatório não consegue modificar a fertilidade do ovo, porém, vários outros fatores poder ser influenciados por ambos, granja e incubatório.

Para tanto, esses inúmeros fatores devem ser levados em conta nos três primeiras etapas da produção avícola: período de pré incubação, período de incubação, e no manejo dos pintos propriamente dito. Os fatores que podem causar problemas na produção vão desde a sanidade do plantel de matrizes, o estado dos ninhos, desinfecção dos ovos, seleção e classificação dos ovos, armazenamento, a planta do incubatório, com um isolamento e uma ventilação adequada até a simples observação da qualidade externa dos pintinhos que são: tamanho e peso adequados, olhos brilhantes, pernas saudáveis, umbigo fechado, uma boa plumagem e, uma uniformidade do lote.

Todas essas observações visam um objetivo em comum: o crescimento econômico propriamente dito. E sendo o incubatório uma das mais importantes atividades da produção avícola, deve necessariamente se modernizar, já que isso é uma constante nas demais áreas do agronegócio. Essa competitividade juntamente com a globalização econômica vem fazendo com que não só o setor de incubatório, mas também as demais partes da cadeia produtiva avícola venham a sofrer cobranças, não só

dos consumidores internos, mas também dos compradores de fora do país. Há aproximadamente 20 anos atrás os incubatórios tinham como principal meta formar uma padronização, procurando se adaptar às exigências dos consumidores, seguindo o que é chamado de nível de qualidade aceitável. Com as alterações monetárias e estratégicas na gestão empresarial, os incubatórios tiveram que se submeter a mudanças e metodologias distintas, a fim de adaptar essas modificações ao modelo de produção. A redução dos defeitos e falhas que eram uma constante, necessariamente desaparecem a cada modernização que o setor sofre, já que, o desejado é uma previsibilidade total e uma garantia de qualidade. Controlar essa qualidade do produto acaba representando a sobrevivência da empresa no contexto nacional e da produção avícola no cenário internacional. O mercado atual determina que os incubatórios implantem o sistema de garantia de qualidade, que é alcançado através da aplicação de inúmeros métodos gerenciais e administrativos, à linguagem dentro do mundo da incubação, tendo como metas principais: previsibilidade, confiabilidade ao processo implantado, fidelidade do cliente e, com isso, um aumento no setor econômico-financeiro da empresa. Para que tudo isso seja alcançado, as empresas ainda lidam com outro fator inerente a todo e qualquer ramo ligado à vida biológica, que é definido nos termos do agronegócio como: variabilidade (GUSTIN, 2003). Esta última é influenciada por causas múltiplas, desconhecidas e incontroláveis.

Como uma das etapas mais importantes nos processos de uma atividade avícola, o incubatório tornou-se a menina dos olhos das empresas. Com o advento da globalização, cada vez mais as barreiras políticas e comerciais estão sendo atenuadas. Portanto, produzir com custos competitivos e com uma qualidade assegurada tornou-se pré-requisito para a sobrevivência e perpetuação das organizações. Das principais características das plantas de incubação atuais, têm-se como referências o alto nível tecnológico dos equipamentos e o rigor sanitário (VIRGINI, 2003).

Nos últimos anos, a nutrição inicial de frangos de corte tem despertado grande interesse nos profissionais que militam na avicultura. A primeira semana de vida da ave representa hoje, em torno de 20% do tempo de criação, quando se considera 2kg, o peso ideal de abate. Por diferentes motivos, o tempo entre a eclosão, transporte e alojamento da ave pode variar entre 20 e 60 horas (ARAÚJO, 2004).

Contudo, por exemplo, prever o preço futuro do ovo quando chega à mesa do consumidor é um complexo fenômeno que ao lado de outros fatores, acaba sendo principalmente dirigido pelas forças da demanda e do suporte do mercado. Para que isso

aconteça muitos fatores situados nas entrelinhas que afetam o preço futuro dos ovos são levados em conta. Alguns desses fatores podem incluir, mas não limitar, o número de ovos postos nos ninhos, produção de ovos, custo da alimentação, número de ovos eclodidos, clima, o aspecto sazonal, número de ovos exportados, etc. A força do mercado tem sido complicada por fatores como o comportamento do consumidor, novas pesquisas que afetam este comportamento, e é claro, a própria propaganda (AHMAD *et al.*2001).

3 MATERIAL E MÉTODO

3.1 Dados de registros

O estudo correspondeu a séries históricas de dados de um incubatório pertencente a uma integração avícola do Rio Grande do Sul, durante os anos de 1999 a 2003. Portanto, foi do tipo observacional analítico e transversal.

A empresa participante do experimento forneceu arquivos de dados com as seguintes características:

- INPESO: 3.110 linhas de registros de pesos dos reprodutores;
- ININFO: 56.018 linhas de registros com as informações diárias do ocorrido nas granjas de reprodução até o incubatório;
- INOVOS: 35.000 linhas de registros com informações sobre os ovos processados;
- INNASC: 43.828 linhas de registros com informações sobre os nascimentos;
- ARQUIVO: Resumo total da produção de 83 lotes de reprodutores criados no período de 1995 a 2002.

3.2 Análise estatística dos dados

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

3.3 Redes neurais artificiais

No presente trabalho, o termo “entrada” identifica as variáveis escolhidas para o cálculo do modelo preditivo e a palavra “saída” a variável a ser predita.

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

treinamento usa uma rede neural que dinamicamente cria neurônios escondidos para construir um modelo que generalize bem.

A rede inicia encontrando relações lineares entre as importâncias relativas das entradas e a saída. São atribuídos pesos às ligações entre os neurônios de entrada e de 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 são multiplicados pelos pesos e passados à segunda, que é oculta. Os neurônios da camada ativam, ou produzem, saídas que são baseadas na soma dos valores pesados que passaram por ela. A camada oculta transmite os valores para a camada de saída da mesma forma e os valores desejados são obtidos (predições).

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 quantos 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 todas as decisões ou predições 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.

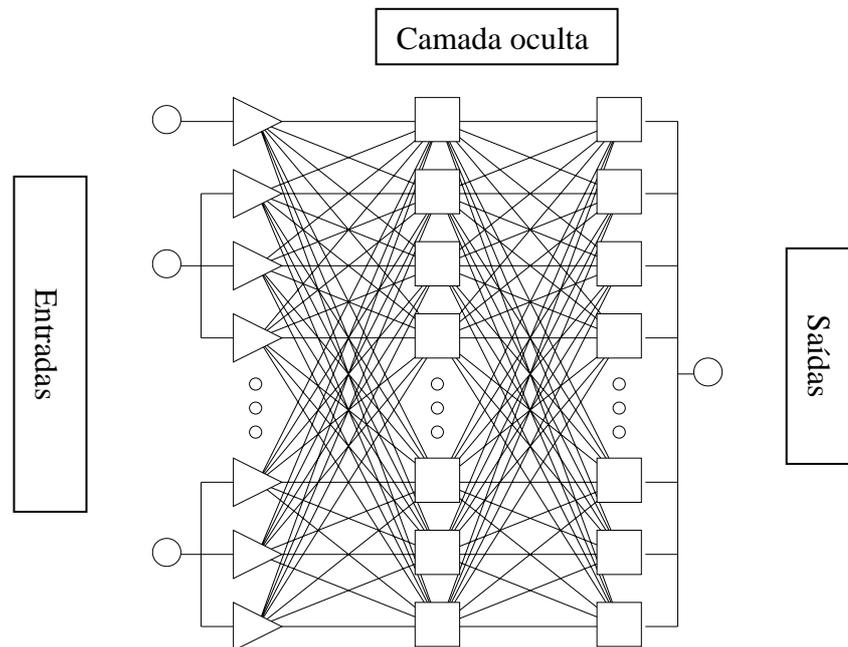


Figura 1 – Exemplo esquemático da arquitetura de rede neural.

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 à potência 2 [QME = média (valores reais - preditos)²].

Para o treinamento das redes foram usados três bancos de dados denominados ARQUIVO, INNASC e ININFO.

As linhagens foram classificadas utilizando-se o banco de dados ARQUIVO, pois ele contém o resumo de todos os eventos ocorridos com 83 lotes de reprodutores. Com estas informações construiu-se a rede neural destinada a classificar a linhagem a partir de variáveis de entrada relacionadas à produção das aves.

Com o banco de dados ARQUIVO também foram construídos seis modelos cujas variáveis de saída foram: Ovos Incubáveis, Percentagem De Ovos Incubáveis,

Ovos Incubados, Percentagem De Ovos Incubados, Pintos Nascidos, Pintos Aproveitáveis.

Para a predição e validação dos resultados de diferentes variáveis de saída nos diferentes anos estudados, foram utilizados os bancos de dados INOVOS e INNASC. Assim sendo, nesta dissertação são apresentados os modelos gerados em cada um dos anos entre 1999 e 2004. Treinaram-se modelos de redes neurais para a saída *pintos aproveitados* para o ano específico e os resultados foram testados e validados com lotes produzidos no próprio ano e nos anos seguintes. Ressalte-se que os testes e validações são realizados com valores que o modelo de redes neurais desconhece completamente.

4 RESULTADOS

Os resultados estão divididos em três partes. Na primeira delas, são apresentadas as classificações por linhagens; na segunda, destacam-se os seis modelos de redes neurais construídos com o resumo das informações obtidas com o fechamento dos lotes e, na terceira, faz-se a construção anual dos modelos de redes neurais para a variável de saída Pintos Aproveitados e as redes foram validadas usando-se os registros do próprio ano que não participaram do treinamento e as informações dos anos subsequentes.

4.1 Classificação por linhagem

A Tabela 1 apresenta as estatísticas do treinamento da rede neural construída para classificar as linhagens exploradas pela empresa avícola no período de 23 de fevereiro de 1995 a 25 de janeiro de 2002 e que totalizou 81 lotes de reprodutores.

Tabela 1. Fase de Treinamento da rede neural artificial destinada a classificar a linhagem das aves a partir de 10 variáveis de entrada relacionadas à produção dos animais.

Linhagem	Porcentagem	Classificação/Real
"COBB"	100,0%	47 de 47
"HIGH YIELD"	100,0%	(4 de 4)
"MPK"	100,0%	(4 de 4)
"ROSS308"	100,0%	(17 de 17)
"X"	100,0%	(10 de 10)

Variáveis de Entrada:

Número inicial de fêmeas
 Número inicial de machos
 Ração total/cabeça
 Ração/cabeça/inicial/recria
 Ração/cabeça/inicial/postura
 Ovos postos
 Ração p/ovo posto
 Pintos nascidos
 Percentagem viabilidade postura fêmea
 Percentagem viabilidade postura machos

Na Tabela 2 estão apresentadas as classificações que a rede neural efetuou nos 81 lotes constantes nos registros do banco de dados. Foram 86,59% de classificações corretas e 13,41% de incorretas.

Tabela 2. Resultado da fase de teste, quando a rede foi aplicada aos 81 lotes constantes no banco de dados.

Lote	Real	Classificação.	COBB++	HIGH Y. ++	MPK++	ROSS30. ++	X++
1	X	X	0,000	0,000	0,000	0,000	1,000
2	COBB	COBB	1,000	0,000	0,000	0,000	0,000
3 *	HIGH Y.	COBB	0,995	0,004	0,000	0,001	0,000
4	COBB	COBB	0,996	0,000	0,000	0,004	0,000
5	COBB	COBB	0,999	0,000	0,000	0,001	0,000
6	COBB	COBB	0,997	0,000	0,000	0,002	0,000
7	MPK	MPK	0,004	0,000	0,996	0,000	0,000
8	MPK	MPK	0,042	0,000	0,958	0,000	0,000
9	COBB	COBB	0,933	0,000	0,000	0,067	0,000
10	X	X	0,000	0,000	0,000	0,000	1,000
11	COBB	COBB	0,992	0,000	0,000	0,007	0,000
12 *	HIGH Y.	COBB	0,831	0,050	0,000	0,112	0,007
13	ROSS30.	ROSS30.	0,000	0,000	0,000	0,999	0,000
14 *	X	COBB	0,685	0,000	0,000	0,000	0,314
15	COBB	COBB	1,000	0,000	0,000	0,000	0,000
16	COBB	COBB	0,984	0,000	0,000	0,014	0,001
17	ROSS30.	ROSS30.	0,275	0,000	0,000	0,725	0,000
18	ROSS30.	ROSS30.	0,005	0,000	0,000	0,995	0,000
19	X	X	0,000	0,000	0,000	0,000	1,000
20	COBB	COBB	0,999	0,000	0,000	0,000	0,000
21 *	ROSS30.	COBB	0,965	0,001	0,000	0,034	0,000
22	COBB	COBB	0,841	0,000	0,000	0,159	0,000
23	X	X	0,021	0,003	0,000	0,000	0,975
24	COBB	COBB	0,975	0,001	0,001	0,023	0,000
25 *	MPK	COBB	0,989	0,000	0,010	0,000	0,001
26	COBB	COBB	0,999	0,000	0,000	0,001	0,000
27	COBB	COBB	0,999	0,000	0,000	0,001	0,000
28	ROSS30.	ROSS30.	0,028	0,000	0,000	0,972	0,000
29	COBB	COBB	1,000	0,000	0,000	0,000	0,000
30	COBB	COBB	0,998	0,000	0,000	0,002	0,000
31	COBB	COBB	1,000	0,000	0,000	0,000	0,000
32	ROSS30.	ROSS30.	0,000	0,000	0,000	1,000	0,000
33	ROSS30.	ROSS30.	0,003	0,000	0,000	0,997	0,000
34	COBB	COBB	1,000	0,000	0,000	0,000	0,000
35	COBB	COBB	0,999	0,000	0,000	0,000	0,000
36	COBB	COBB	0,999	0,000	0,000	0,001	0,000
37	X	X	0,000	0,000	0,000	0,001	0,999
38	ROSS30.	ROSS30.	0,215	0,000	0,000	0,784	0,001
39	COBB	COBB	1,000	0,000	0,000	0,000	0,000
40	COBB	COBB	0,998	0,000	0,000	0,001	0,000
41	COBB	COBB	1,000	0,000	0,000	0,000	0,000

42	X	X	0,001	0,000	0,000	0,001	0,998
43	COBB	COBB	0,728	0,001	0,000	0,267	0,004
44	ROSS30.	ROSS30.	0,000	0,000	0,000	1,000	0,000
45	COBB	COBB	0,996	0,001	0,000	0,001	0,001
46 *	ROSS30.	COBB	0,505	0,000	0,000	0,494	0,000
47 *	ROSS30.	COBB	0,668	0,001	0,000	0,331	0,000
48	MPK	MPK	0,210	0,000	0,787	0,003	0,000
49	ROSS30.	ROSS30.	0,000	0,000	0,000	0,999	0,001
50 *	ROSS30.	COBB	0,918	0,000	0,000	0,082	0,001
51	COBB	COBB	1,000	0,000	0,000	0,000	0,000
52 *	ROSS30.	COBB	0,936	0,000	0,000	0,064	0,000
53	X	X	0,003	0,000	0,001	0,000	0,996
54	COBB	COBB	0,998	0,000	0,001	0,001	0,000
55 *	ROSS30.	COBB	0,716	0,001	0,000	0,283	0,000
56	COBB	COBB	0,998	0,000	0,000	0,001	0,000
57	COBB	COBB	0,999	0,000	0,000	0,000	0,001
58	X	X	0,000	0,000	0,000	0,000	1,000
59	ROSS30.	ROSS30.	0,000	0,000	0,000	0,998	0,001
60	ROSS30.	ROSS30.	0,004	0,000	0,000	0,996	0,000
61	COBB	COBB	0,981	0,019	0,000	0,000	0,000
62	COBB	COBB	1,000	0,000	0,000	0,000	0,000
63	COBB	COBB	0,995	0,002	0,000	0,003	0,000
64	COBB	COBB	0,998	0,000	0,000	0,001	0,000
65	COBB	COBB	0,998	0,000	0,001	0,000	0,000
66	COBB	COBB	1,000	0,000	0,000	0,000	0,000
67	COBB	COBB	0,999	0,000	0,000	0,001	0,000
68	COBB	COBB	1,000	0,000	0,000	0,000	0,000
69	COBB	COBB	0,999	0,000	0,000	0,000	0,000
70	X	X	0,001	0,000	0,000	0,000	0,999
71	COBB	COBB	1,000	0,000	0,000	0,000	0,000
72	COBB	COBB	0,999	0,000	0,000	0,000	0,000
73	COBB	COBB	1,000	0,000	0,000	0,000	0,000
74	HIGH Y.	HIGH Y.	0,015	0,983	0,000	0,001	0,000
75	COBB	COBB	0,980	0,000	0,000	0,020	0,000
76	COBB	COBB	0,973	0,000	0,000	0,026	0,000
77	COBB	COBB	1,000	0,000	0,000	0,000	0,000
78	COBB	COBB	0,997	0,000	0,000	0,003	0,000
79 *	HIGH Y.	COBB	0,635	0,362	0,002	0,000	0,000
80	COBB	COBB	1,000	0,000	0,000	0,000	0,000
81	COBB	COBB	0,998	0,000	0,001	0,000	0,000

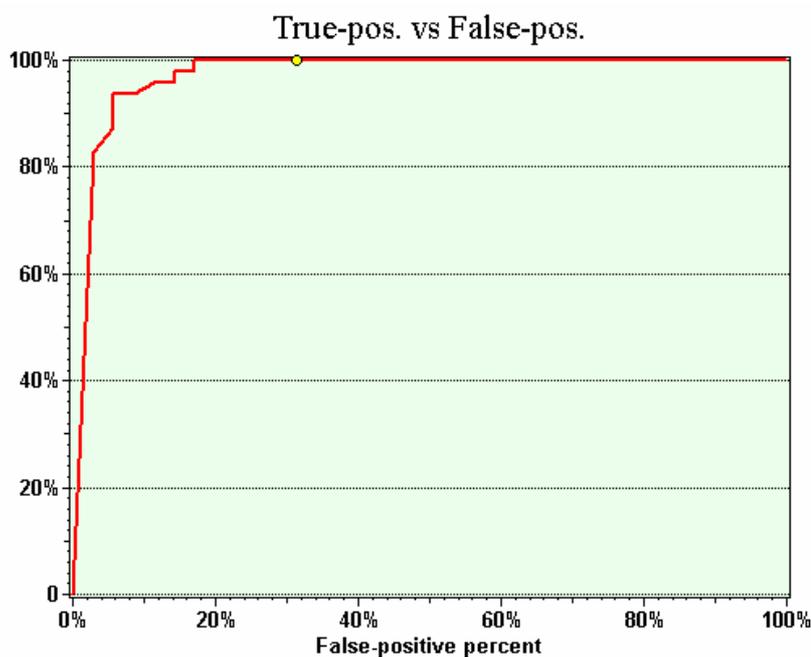
* - identifica as classificações erradas.

++ - probabilidade da classificação.

A Tabela 3 resume as estatísticas da classificação.

Tabela 3. Tabela de contingência com as estatísticas da classificação das linhagens.

	Real "COBB"	Real "HIGH YIELD"	Real "MPK"	Real "ROSS308"	Real "X"	Total
Class. como "COBB"	47	3	1	6	1	58
Class. como "HIGH YIELD"	0	1	0	0	0	1
Class. como "MPK"	0	0	3	0	0	3
Class. como "ROSS308"	0	0	0	11	0	11
Class. como "X"	0	0	0	0	9	9
Total	47	4	4	17	10	82
Relação POS verdadeiro	1,0	0,25	0,75	0,6471	0,9	
Relação Falso POS	0,3143	0,0	0,0	0,0	0,0	
Relação NEG verdadeiro	0,6857	1,0	1,0	1,0	1,0	
Relação falso NEG	0,0	0,75	0,25	0,3529	0,1	
Sensibilidade	100,0%	25,0%	75,0%	64,71%	90,0%	
Especificidade	68,57%	100,0%	100,0%	100,0%	100,0%	



A Figura 2 apresenta a curva ROC (Relative Operating Characteristic) para as classificações da linhagem Cobb.

4.2 Redes neurais construídos com as informações obtidas com o fechamento dos lotes

A Tabela 3 resume as informações obtidas com o treinamento da rede neural cuja variável de saída é Ovos Incubáveis. As estatísticas obtidas refletem um modelo bem ajustado.

Tabela 3 – Características do modelo de rede neural para a predição da saída Ovos Incubáveis.

Estatísticas da predição	Valores
R ²	0,987707
Erro médio	63788,62
Correlação	0,993835
QME	6,88E+09
RQME	82926,87

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

A Tabela 4 e a Figura 3 apresentam as contribuições, ou importâncias relativas, das variáveis de entrada para a saída Ovos Incubáveis.

Tabela 4 – Importância relativa (contribuições) das variáveis de entrada para a saída Ovos Incubáveis.

Entradas	Importância relativa
Ração postura	0,778
Percentagem de viabilidade na postura	0,088
Saldo final de aves em percentagem	0,088
Ração recria	0,045
Percentagem de viabilidade na recria	0,001

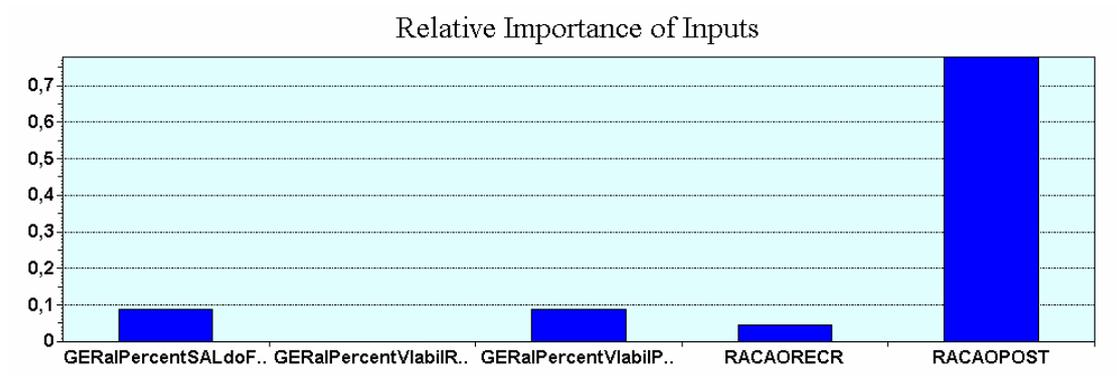


Figura 3 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Ovos Incubáveis.

Na Tabela 5 estão reunidas as estatísticas do teste efetuado sobre 81 lotes de reprodutores com a predição dos Ovos Incubáveis.

Tabela 5 – Características do teste do modelo de rede neural para a predição da saída Ovos Incubáveis em 81 lotes de reprodutores.

Estatísticas da predição	Valores
R ²	0,987707
Erro médio	63788,62
Correlação	0,993835
QME	6,88E+09
RQME	82926,87

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

Os resultados das predições versus os valores reais obtidos em 81 lotes de reprodutores são sumarizados na Tabela 6 e na Figura 4.

Tabela 6 – Resultados reais e as predições de Ovos Incubáveis para 81 lotes de reprodutores.

Lote	Real	Predição	Lote	Real	Predição	Lote	Real	Predição
1	1,29E+06	1,2E+06	28	3,12E+06	3,23E+06	55	1,59E+06	1,55E+06
2	1,68E+06	1,64E+06	29	1,62E+06	1,7E+06	56	0	-7748,727
3	1,73E+06	1,62E+06	30	1,75E+06	1,77E+06	57	0	-2493,964
4	1,67E+06	1,73E+06	31	1,56E+06	1,66E+06	58	1,78E+06	1,89E+06
5	2,02E+06	2,09E+06	32	3,2E+06	3,4E+06	59	1,69E+06	1,68E+06
6	2,43E+06	2,47E+06	33	2,79E+06	2,78E+06	60	2,78E+06	2,71E+06
7	895457	791413	34	1,65E+06	1,67E+06	61	2,91E+06	2,74E+06
8	2,5E+06	2,61E+06	35	1,86E+06	1,81E+06	62	2,57E+06	2,66E+06
9	3,55E+06	3,41E+06	36	1,83E+06	1,78E+06	63	2,54E+06	2,43E+06
10	1,07E+06	1,03E+06	37	1,6E+06	1,7E+06	64	2,64E+06	2,48E+06
11	1,85E+06	1,89E+06	38	1,49E+06	1,52E+06	65	2,64E+06	2,59E+06
12	1,52E+06	1,47E+06	39	1,72E+06	1,77E+06	66	863678	817807,9
13	2,07E+06	1,97E+06	40	1,95E+06	1,96E+06	67	0	-7748,727
14	1,49E+06	1,55E+06	41	3,5E+06	3,49E+06	68	1,65E+06	1,83E+06
15	1,78E+06	1,79E+06	42	1,16E+06	1,13E+06	69	1,35E+06	1,37E+06
16	1,47E+06	1,57E+06	43	1,77E+06	1,7E+06	70	2,61E+06	2,7E+06
17	3,3E+06	3,35E+06	44	1,79E+06	1,69E+06	71	1,8E+06	1,77E+06
18	2,92E+06	2,81E+06	45	1,68E+06	1,68E+06	72	2,59E+06	2,6E+06
19	968707	965695,8	46	1,62E+06	1,72E+06	73	2,5E+06	2,53E+06
20	1,39E+06	1,42E+06	47	1,6E+06	1,58E+06	74	2,75E+06	2,74E+06
21	1,85E+06	1,79E+06	48	3,75E+06	3,61E+06	75	2,56E+06	2,75E+06
22	1,43E+06	1,67E+06	49	3,34E+06	3,18E+06	76	2,67E+06	2,76E+06
23	1,66E+06	1,67E+06	50	1,69E+06	1,68E+06	77	2,42E+06	2,36E+06
24	1,75E+06	1,77E+06	51	1,82E+06	1,8E+06	78	2,59E+06	2,6E+06
25	1,85E+06	1,77E+06	52	1,91E+06	1,92E+06	79	2,71E+06	2,71E+06
26	1,69E+06	1,71E+06	53	1,65E+06	1,59E+06	80	2,77E+06	2,71E+06
27	1,68E+06	1,68E+06	54	1,81E+06	1,74E+06	81	1,67E+06	1,76E+06

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

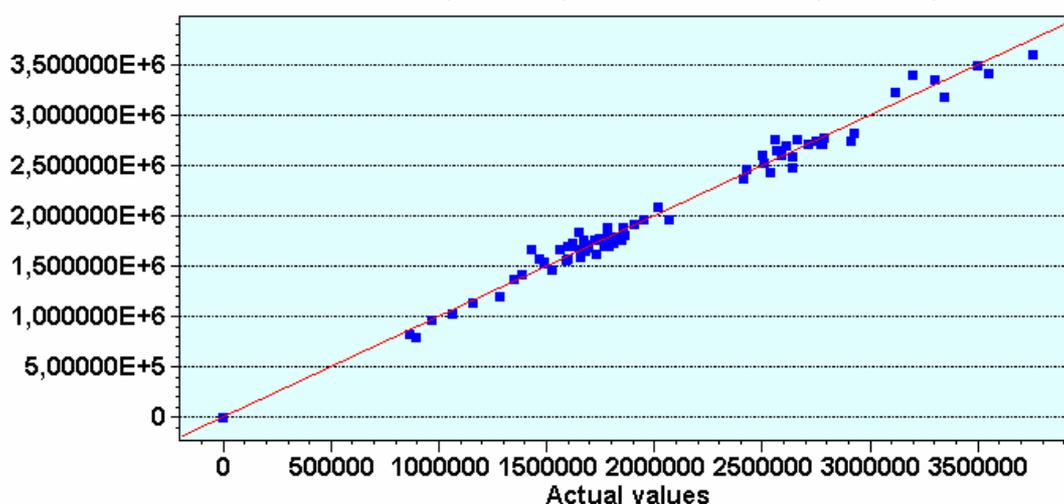


Figura 4 – Valores reais (X) *versus* valores preditos (Y) de Ovos Incubáveis para os 81 lotes de reprodutores.

As estatísticas do modelo de rede neural para a saída Percentual de Ovos incubáveis estão descritas na Tabela 7.

Tabela 7 – Características do modelo de rede neural para a predição da saída Percentagem de Ovos Incubáveis.

Estatísticas da predição	Valores
R ²	0,995214
Erro médio	0,946535
Correlação	0,997604
QME	1,535349
RQME	1,239092

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

A Tabela 8 e a Figura 5 mostram as contribuições, ou importâncias relativas, das variáveis de entrada para a saída Percentagem de Ovos Incubáveis.

Tabela 8 – Importância relativa (contribuições) das variáveis de entrada para a saída Percentagem de Ovos Incubáveis.

Entradas	Importância relativa
Percentagem de viabilidade na recria	0,330
Saldo final de aves em percentagem	0,312
Ração postura	0,161
Ração recria	0,132
Percentagem de viabilidade na postura	0,064

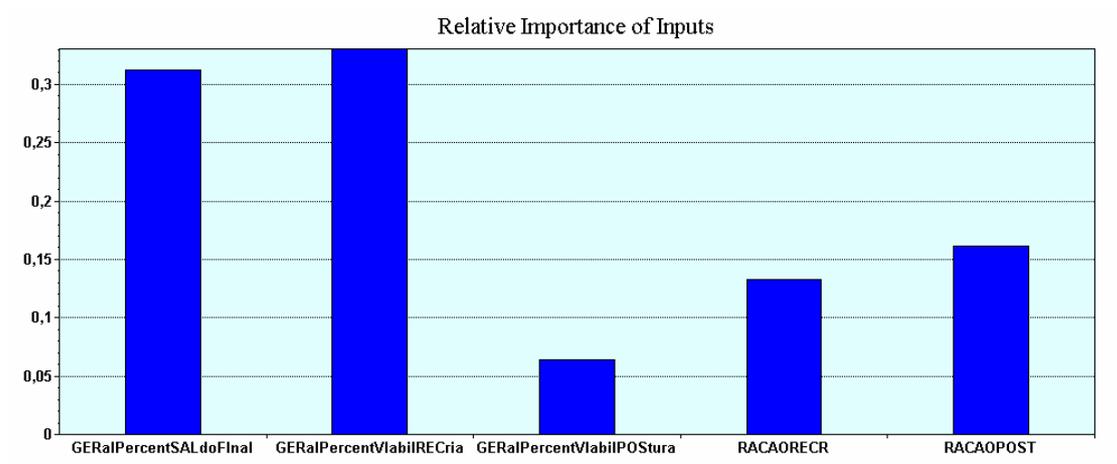


Figura 5 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Percentagem de Ovos Incubáveis.

Na Tabela 9 estão reunidas as estatísticas do teste efetuado sobre 81 lotes de reprodutores com a predição dos Percentagem de Ovos Incubáveis.

Tabela 9 – Características do teste do modelo de rede neural para a predição da saída Percentagem de Ovos Incubáveis em 81 lotes de reprodutores.

Estatísticas da predição	Valores
R ²	0,992903
Erro médio	1,135141
Correlação	0,996448
QME	2,27658
RQME	1,508834

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

Os resultados das predições versus os valores reais obtidos em 81 lotes de reprodutores são sumarizados na Tabela 10 e na Figura 6.

Tabela 10 – Resultados reais e as predições de Percentagem de Ovos Incubáveis para 81 lotes de reprodutores.

Lote	Real	Predição	Lote	Real	Predição	Lote	Real	Predição
1	94,36	92,6395	28	95,57	95,38341	55	94,32	93,5805
2	93,76	93,64866	29	91,61	93,01292	56	0	0,284662
3	92,43	93,96034	30	95,47	93,86929	57	0	-0,26379
4	95,5	95,12093	31	93,03	93,50865	58	92,75	93,90368
5	95,28	94,43762	32	95	94,63762	59	94,94	93,90694
6	96,29	95,99166	33	95,58	95,27062	60	94,55	94,84226
7	95,61	96,616	34	90,58	93,06808	61	96,28	95,10616
8	96,42	95,49062	35	95,57	93,89391	62	94,21	95,2047
9	95,33	95,6243	36	94,03	93,83368	63	96,58	96,27995
10	85,75	90,92054	37	86,07	89,01743	64	94,84	97,1772
11	93,5	92,985	38	92,89	92,72444	65	93,93	93,83616
12	92,54	93,53662	39	93,98	93,72401	66	93,48	91,90502
13	96,99	93,99404	40	96,85	96,66015	67	0	0,284662
14	91,26	93,20803	41	95,82	96,33598	68	95,96	95,67281
15	96,32	93,56079	42	91,7	91,7318	69	87,8	89,24119
16	89,56	93,70627	43	93,22	92,07938	70	92,49	92,81244
17	95,37	95,71655	44	95,83	94,24463	71	95,01	93,73271
18	94,99	96,09942	45	91,57	93,47672	72	95,77	95,40083
19	95,82	92,49299	46	95,5	94,56915	73	89,71	92,15961
20	93,28	93,70661	47	94,1	94,14193	74	94,49	94,33176
21	95,59	94,68098	48	97,18	96,76324	75	92,51	94,88774
22	94,91	93,81666	49	94,96	93,03773	76	95,79	94,60023
23	88,11	88,57315	50	93,58	94,07849	77	96,98	95,45061
24	92,15	92,95208	51	95,29	94,10164	78	92,92	93,84306
25	95,07	94,06672	52	96,45	93,99568	79	95,17	94,50068
26	95,69	95,7528	53	94,85	93,60258	80	90,99	94,13743
27	95,75	94,49973	54	95,62	94,26913	81	92,8	94,14984

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

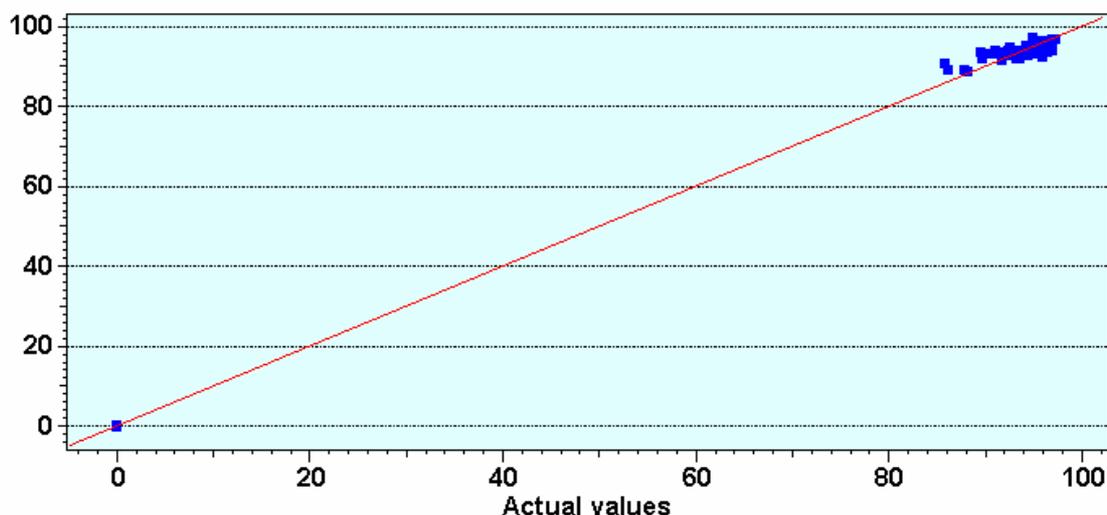


Figura 6 – Valores reais (X) *versus* valores preditos (Y) de Percentagem de Ovos Incubáveis para os 81 lotes de reprodutores.

Os resultados obtidos no treinamento da rede neural para a saída Ovos Incubados estão expostos na Tabela 11.

Tabela 11 – Características do modelo de rede neural para a predição da saída Ovos Incubados.

Estatísticas da predição	Valores
R ²	0,967947
Erro médio	93347,98
Correlação	0,983843
QME	1,75E+10
RQME	132375,3

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

A Tabela 12 e a Figura 7 indicam as contribuições, ou importâncias relativas, das variáveis de entrada para a saída Ovos Incubados.

Tabela 12 – Importância relativa (contribuições) das variáveis de entrada para a saída Ovos Incubados.

Entradas	Importância relativa
Ração postura	0,460
Percentagem de viabilidade na recria	0,334
Saldo final de aves em percentagem	0,101
Ração recria	0,060
Percentagem de viabilidade na postura	0,044

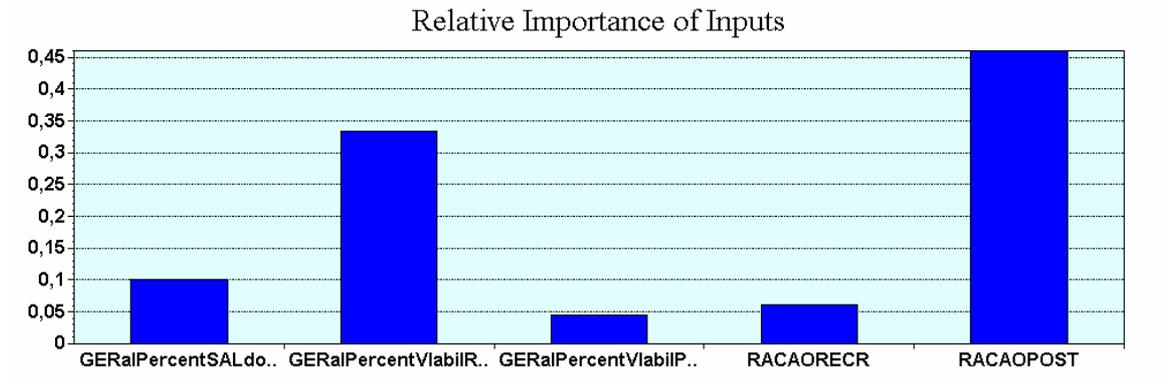


Figura 7 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Ovos Incubados.

Na Tabela 13 estão reunidas as estatísticas do teste efetuado sobre 81 lotes de reprodutores com a predição dos Ovos Incubados.

Tabela 13 – Características do teste do modelo de rede neural para a predição da saída Ovos Incubados em 81 lotes de reprodutores.

Estatísticas da predição	Valores
R ²	0,966384
Erro médio	94149,05
Correlação	0,983049
QME	1,84E+10
RQME	135563,7

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

Os resultados das predições versus os valores reais obtidos em 81 lotes de reprodutores podem ser apreciados na Tabela 14 e na Figura 8.

Tabela 14 – Resultados reais e as predições de Ovos Incubados para 81 lotes de reprodutores.

Lote	Real	Predição	Lote	Real	Predição	Lote	Real	Predição
1	1,23E+06	1,12E+06	28	3,12E+06	3,15E+06	55	1,6E+06	1,48E+06
2	1,57E+06	1,58E+06	29	1,48E+06	1,58E+06	56	0	-10265,06
3	1,71E+06	1,57E+06	30	1,73E+06	1,71E+06	57	0	9459,404
4	1,28E+06	1,59E+06	31	1,56E+06	1,59E+06	58	1,78E+06	1,81E+06
5	1,61E+06	1,95E+06	32	3,2E+06	3,32E+06	59	1,69E+06	1,63E+06
6	2,38E+06	2,41E+06	33	2,78E+06	2,77E+06	60	2,51E+06	2,59E+06
7	930238	957740,2	34	1,55E+06	1,6E+06	61	2,91E+06	2,63E+06
8	2,47E+06	2,44E+06	35	1,87E+06	1,72E+06	62	2,01E+06	2,54E+06
9	3,32E+06	3,32E+06	36	1,82E+06	1,72E+06	63	2,54E+06	2,39E+06
10	997308	967719,8	37	1,47E+06	1,62E+06	64	2,57E+06	2,38E+06
11	1,84E+06	1,81E+06	38	1,49E+06	1,43E+06	65	2,64E+06	2,5E+06
12	1,45E+06	1,4E+06	39	1,71E+06	1,7E+06	66	845941	799092,4
13	2,0E+06	1,88E+06	40	1,74E+06	1,87E+06	67	0	-10265,06
14	1,34E+06	1,48E+06	41	3,5E+06	3,48E+06	68	1,65E+06	1,76E+06
15	1,78E+06	1,71E+06	42	1,07E+06	1,08E+06	69	1,22E+06	1,28E+06
16	1,39E+06	1,52E+06	43	1,73E+06	1,63E+06	70	2,37E+06	2,58E+06
17	3,29E+06	3,29E+06	44	1,78E+06	1,64E+06	71	1,79E+06	1,71E+06
18	2,94E+06	2,7E+06	45	1,58E+06	1,63E+06	72	2,41E+06	2,48E+06
19	862272	909144,5	46	1,62E+06	1,68E+06	73	2,39E+06	2,44E+06
20	1,33E+06	1,34E+06	47	1,6E+06	1,54E+06	74	2,76E+06	2,67E+06
21	1,84E+06	1,74E+06	48	3,74E+06	3,53E+06	75	2,55E+06	2,69E+06
22	1,11E+06	1,63E+06	49	3,05E+06	3,11E+06	76	2,67E+06	2,64E+06
23	1,53E+06	1,57E+06	50	1,61E+06	1,58E+06	77	2,29E+06	2,26E+06
24	1,79E+06	1,72E+06	51	1,82E+06	1,74E+06	78	2,39E+06	2,5E+06
25	1,84E+06	1,7E+06	52	1,88E+06	1,86E+06	79	2,69E+06	2,61E+06
26	1,69E+06	1,63E+06	53	1,58E+06	1,54E+06	80	2,61E+06	2,62E+06
27	1,69E+06	1,56E+06	54	1,8E+06	1,69E+06	81	1,67E+06	1,71E+06

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

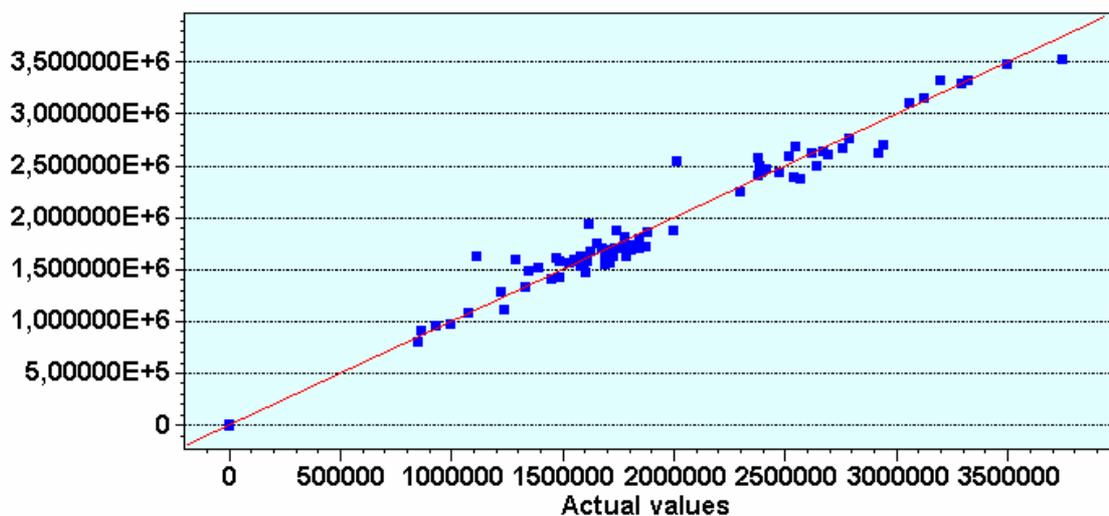


Figura 8 – Valores reais (X) versus valores preditos (Y) de Ovos Incubados para os 81 lotes de reprodutores.

As informações sobre o treinamento do modelo de redes neurais para a saída Percentagem de Ovos Incubados podem ser visualizados na Tabela 15.

Tabela 15 – Características do modelo de rede neural para a predição da saída Percentagem de Ovos Incubados.

Estatísticas da predição	Valores
R ²	0,939982
Erro médio	3,430855
Correlação	0,969527
QME	19,64443
RQME	4,432204

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

A Tabela 16 e a Figura 9 oferecem as contribuições, ou importâncias relativas, das variáveis de entrada para a saída Percentagem de Ovos Incubados.

Tabela 16 – Importância relativa (contribuições) das variáveis de entrada para a saída Ovos Incubados.

Entradas	Importância relativa
Percentagem de viabilidade na recria	0,504
Percentagem de viabilidade na postura	0,156
Ração recria	0,140
Ração postura	0,116
Saldo final de aves em percentagem	0,084

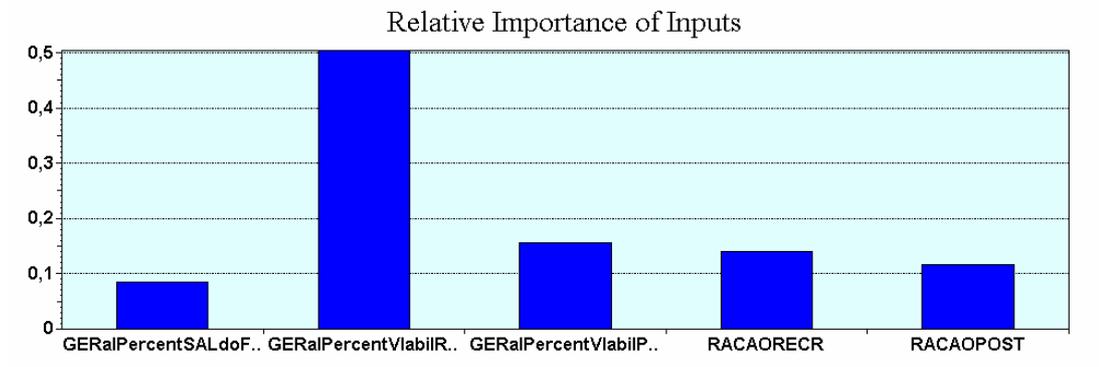


Figura 9 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Percentagem de Ovos Incubados.

Os resultados do teste nos lotes da rede neural para a saída Percentagem de Ovos Incubados podem ser vistos na Tabela 17.

Tabela 17 – Características do teste do modelo de rede neural para a predição da saída Percentagem de Ovos Incubados em 81 lotes de reprodutores.

Estatísticas da predição	Valores
R ²	0,930476
Erro médio	3,676742
Correlação	0,964621
QME	22,75568
RQME	4,770291

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

Os resultados das predições versus os valores reais obtidos em 81 lotes de reprodutores são sumarizados na Tabela 18 e na Figura 10.

Tabela 18 – Resultados reais e as predições de Percentagem de Ovos Incubados para 81 lotes de reprodutores.

Lote	Real	Predição	Lote	Real	Predição	Lote	Real	Predição
1	90,42	82,53242	28	95,68	92,98746	55	1,6E+06	1,48E+06
2	87,76	91,64468	29	83,72	88,62193	56	0	-10265,06
3	91,3	92,05755	30	94,59	91,5249	57	0	9459,404
4	73,41	82,54945	31	92,7	90,18906	58	1,78E+06	1,81E+06
5	76,23	84,92278	32	95,05	90,49792	59	1,69E+06	1,63E+06
6	94,33	95,48134	33	95,46	94,75036	60	2,51E+06	2,59E+06
7	99,33	98,79205	34	85,03	91,11507	61	2,91E+06	2,63E+06
8	95,14	91,99566	35	96,14	89,98399	62	2,01E+06	2,54E+06
9	89,02	91,89626	36	93,33	92,16218	63	2,54E+06	2,39E+06
10	80,21	82,69467	37	79,27	87,23723	64	2,57E+06	2,38E+06
11	92,72	91,01547	38	92,67	93,50417	65	94,12	90,58228
12	87,92	94,74858	39	93,62	91,07732	66	91,56	86,09067
13	93,62	92,92571	40	86,43	87,93183	67	0	-0,753941
14	82,34	91,46577	41	95,69	94,78982	68	95,68	90,44937
15	96,02	91,09287	42	84,86	85,0438	69	79,52	84,22157
16	84,93	90,2289	43	91,17	87,59998	70	84,23	
17	95,26	92,97305	44	95,57	91,73253	71	94,66	90,82869
18	95,48	93,48567	45	86,07	91,74169	72	89,18	88,35474
19	85,29	84,23971	46	95,34	91,9138	73	85,59	86,07738
20	89,23	88,62282	47	93,91	90,32314	74	94,71	93,67289
21	95,11	92,49376	48	96,89	93,36291	75	91,96	95,68347
22	73,61	90,23927	49	86,73	90,75151	76	95,89	90,48717
23	81,14	84,92177	50	89,25	89,72759	77	92,13	88,24793
24	93,95	91,49881	51	95,22	92,72282	78	85,7	89,7519
25	94,93	91,32692	52	95,08	92,42645	79	94,43	91,51122
26	95,61	88,81502	53	90,68	90,77497	80	85,77	91,00319
27	95,96	86,06043	54	95,29	91,69401	81	93,03	92,16094

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

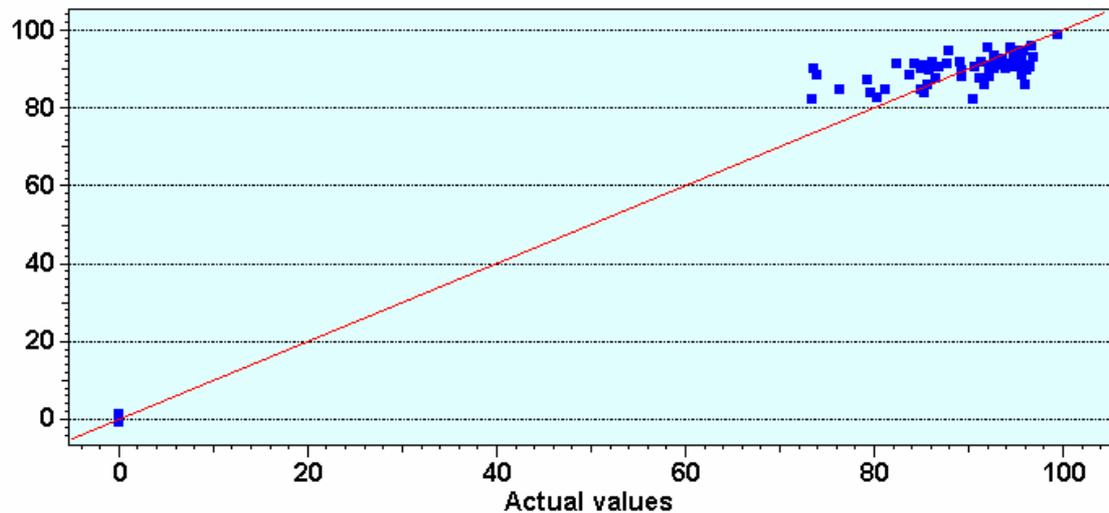


Figura 10 – Valores reais (X) *versus* valores preditos (Y) de Percentagem de Ovos Incubados para os 81 lotes de reprodutores.

Tabela 19 – Características do modelo de rede neural para a predição da saída Pintos Nascidos.

Estatísticas da predição	Valores
R ²	0,960754
Erro médio	86633,67
Correlação	0,980181
QME	1,51E+10
RQME	122927,7

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

A Tabela 20 e a Figura 11 apresentam as contribuições, ou importâncias relativas, das variáveis de entrada para a saída Pintos Nascidos.

Tabela 20– Importância relativa (contribuições) das variáveis de entrada para a saída Pintos Nascidos.

Entradas	Importância relativa
Ração postura	0,946
Percentagem de viabilidade na postura	0,157
Saldo final de aves em percentagem	0,140
Ração recria	0,077
Percentagem viabilidade na recria	0,031

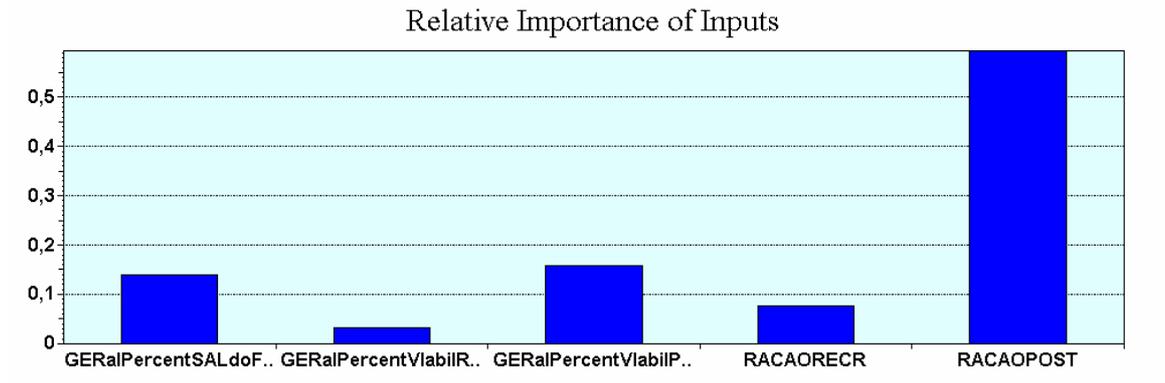


Figura 11 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Nascidos.

Tabela 21 – Características do teste do modelo de rede neural para a predição da saída Pintos Nascidos em 81 lotes de reprodutores.

Estatísticas da predição	Valores
R ²	0,960233
Erro médio	87401,71
Correlação	0,979915
QME	1,52E+10
RQME	123740,7

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

Os resultados das predições versus os valores reais obtidos em 81 lotes de reprodutores são sumarizados na Tabela 22 e na Figura 12.

Tabela 22 – Resultados reais e as predições de Pintos Nascidos para 81 lotes de reprodutores.

Lote	Real	Predição	Lote	Real	Predição	Lote	Real	Predição
1	1,01E+06	909656,9	28	2,62E+06	2,64E+06	55	1,33E+06	1,23E+06
2	1,31E+06	1,28E+06	29	1,23E+06	1,36E+06	56	0	-12358,82
3	1,44E+06	1,29E+06	30	1,46E+06	1,41E+06	57	0	-2912,563
4	1,07E+06	1,38E+06	31	1,29E+06	1,33E+06	58	1,44E+06	1,5E+06
5	1,35E+06	1,65E+06	32	2,7E+06	2,74E+06	59	1,33E+06	1,34E+06
6	1,96E+06	1,99E+06	33	2,29E+06	2,33E+06	60	2,06E+06	2,15E+06
7	781564	653868,6	34	1,28E+06	1,3E+06	61	2,49E+06	2,21E+06
8	2,03E+06	2,09E+06	35	1,59E+06	1,42E+06	62	1,7E+06	2,14E+06
9	2,82E+06	2,74E+06	36	1,54E+06	1,43E+06	63	2,19E+06	2,01E+06
10	822728	774418,1	37	1,21E+06	1,34E+06	64	2,16E+06	1,97E+06
11	1,51E+06	1,47E+06	38	1,21E+06	1,2E+06	65	2,19E+06	2,07E+06
12	1,19E+06	1,17E+06	39	1,37E+06	1,39E+06	66	718591	630343,2
13	1,7E+06	1,58E+06	40	1,42E+06	1,54E+06	67	0	-12358,82
14	1,1E+06	1,22E+06	41	2,99E+06	2,87E+06	68	1,42E+06	1,45E+06
15	1,47E+06	1,39E+06	42	893400	911570,4	69	1,0E+06	1,08E+06
16	1,18E+06	1,25E+06	43	1,42E+06	1,4E+06	70	1,95E+06	2,15E+06
17	2,7E+06	2,71E+06	44	1,46E+06	1,34E+06	71	1,41E+06	1,4E+06
18	2,46E+06	2,3E+06	45	1,31E+06	1,35E+06	72	2,07E+06	2,09E+06
19	715510	714022,4	46	1,37E+06	1,4E+06	73	1,94E+06	2,03E+06
20	1,11E+06	1,14E+06	47	1,34E+06	1,28E+06	74	2,26E+06	2,23E+06
21	1,52E+06	1,46E+06	48	3,12E+06	2,9E+06	75	2,1E+06	2,24E+06
22	915185	1,36E+06	49	2,53E+06	2,58E+06	76	2,15E+06	2,19E+06
23	1,26E+06	1,3E+06	50	1,3E+06	1,3E+06	77	1,96E+06	1,87E+06
24	1,44E+06	1,45E+06	51	1,55E+06	1,45E+06	78	1,95E+06	2,07E+06
25	1,49E+06	1,4E+06	52	1,49E+06	1,56E+06	79	2,21E+06	2,16E+06
26	1,41E+06	1,38E+06	53	1,31E+06	1,27E+06	80	2,2E+06	2,17E+06
27	1,41E+06	1,31E+06	54	1,49E+06	1,4E+06	81	1,39E+06	1,42E+06

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

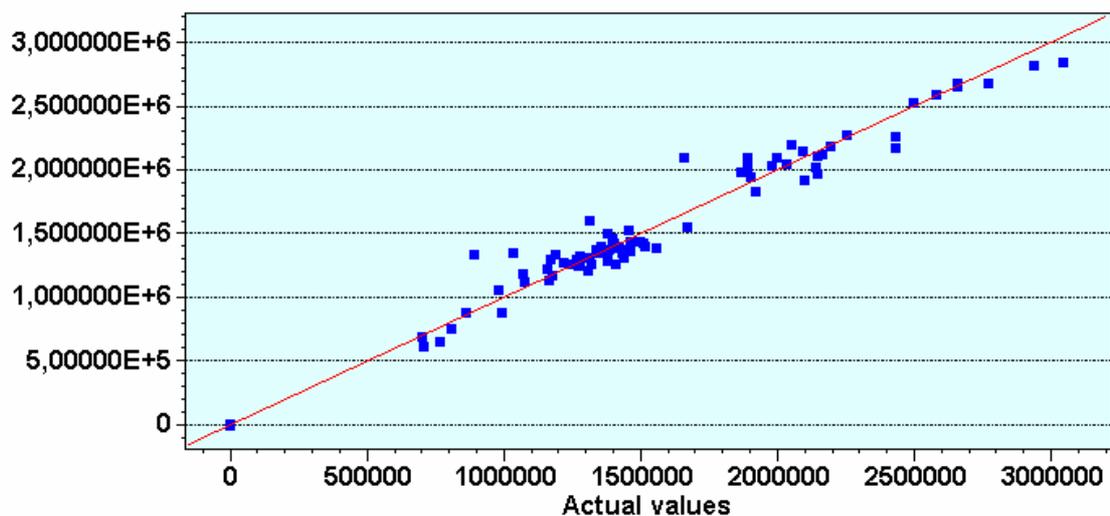


Figura 12 – Valores reais (X) versus valores preditos (Y) de Pintos Nascidos para os 81 lotes de reprodutores.

As características do modelo de rede neural artificial para a predição dos pintos aproveitáveis estão expressos na Tabela 23.

Tabela 23 – Características do modelo de rede neural para a predição da saída Pintos Aproveitáveis.

Estatísticas da predição	Valores
R ²	0,959482
Erro médio	86596,71
Correlação	0,979532
QME	1,5E+10
RQME	122652,5

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

A Tabela 24 e a Figura 13 apresentam as contribuições, ou importâncias relativas, das variáveis de entrada para a saída Pintos Nascidos.

Tabela 24– Importância relativa (contribuições) das variáveis de entrada para a saída Pintos Aproveitáveis.

Entradas	Importância relativa
Ração postura	0,896
Saldo final de aves em percentagem	0,429
Percentagem viabilidade na postura	0,070
Ração recria	0,008
Percentagem viabilidade na recria	0,003

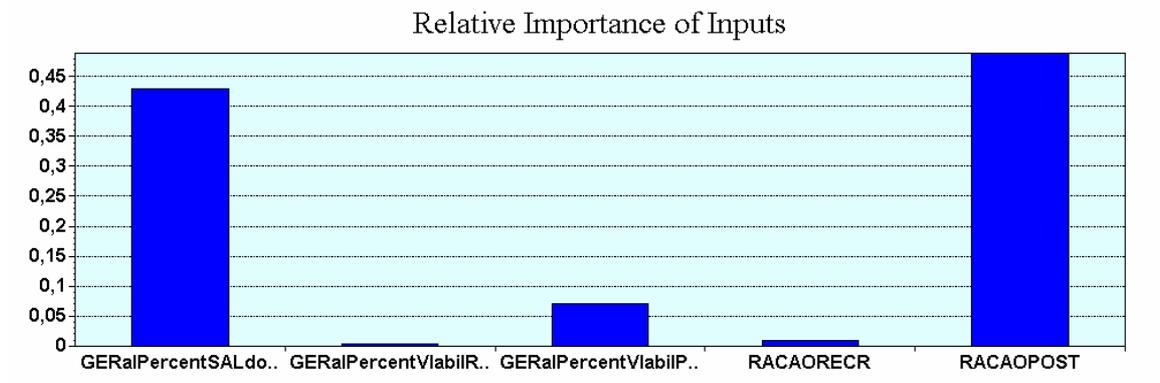


Figura 13 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Aproveitáveis.

Tabela 25 – Características do teste do modelo de rede neural para a predição da saída Pintos Aproveitáveis em 81 lotes de reprodutores.

Estatísticas da predição	Valores
R ²	0,959007
Erro médio	87422,48
Correlação	0,979289
QME	1,52E+10
RQME	123369

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

Os resultados das predições versus os valores reais obtidos em 81 lotes de reprodutores são sumarizados na Tabela 26 e na Figura 14.

Tabela 26– Resultados reais e as predições de Pintos Aproveitáveis para 81 lotes de reprodutores.

Lote	Real	Predição	Lote	Real	Predição	Lote	Real	Predição
1	992281	880130,4	28	2,58E+06	2,59E+06	55	1,31E+06	1,2E+06
2	1,28E+06	1,25E+06	29	1,19E+06	1,33E+06	56	0	-14192,82
3	1,41E+06	1,25E+06	30	1,42E+06	1,38E+06	57	0	-2647,085
4	1,04E+06	1,35E+06	31	1,26E+06	1,3E+06	58	1,4E+06	1,46E+06
5	1,31E+06	1,6E+06	32	2,66E+06	2,68E+06	59	1,31E+06	1,31E+06
6	1,9E+06	1,95E+06	33	2,26E+06	2,27E+06	60	2,0E+06	2,1E+06
7	764777	644978,4	34	1,24E+06	1,26E+06	61	2,43E+06	2,17E+06
8	1,98E+06	2,03E+06	35	1,56E+06	1,38E+06	62	1,66E+06	2,1E+06
9	2,77E+06	2,68E+06	36	1,51E+06	1,4E+06	63	2,14E+06	1,97E+06
10	806200	748573	37	1,17E+06	1,3E+06	64	2,1E+06	1,92E+06
11	1,46E+06	1,43E+06	38	1,18E+06	1,16E+06	65	2,14E+06	2,02E+06
12	1,17E+06	1,14E+06	39	1,34E+06	1,35E+06	66	704386	614298,4
13	1,67E+06	1,55E+06	40	1,38E+06	1,5E+06	67	0	-14192,82
14	1,07E+06	1,18E+06	41	2,94E+06	2,81E+06	68	1,39E+06	1,41E+06
15	1,43E+06	1,35E+06	42	859600	883101,9	69	979008	1,06E+06
16	1,16E+06	1,22E+06	43	1,39E+06	1,37E+06	70	1,89E+06	2,1E+06
17	2,65E+06	2,66E+06	44	1,44E+06	1,31E+06	71	1,38E+06	1,36E+06
18	2,43E+06	2,25E+06	45	1,28E+06	1,32E+06	72	2,04E+06	2,05E+06
19	702960	687946,3	46	1,33E+06	1,37E+06	73	1,87E+06	1,98E+06
20	1,08E+06	1,12E+06	47	1,32E+06	1,26E+06	74	2,2E+06	2,18E+06
21	1,5E+06	1,43E+06	48	3,04E+06	2,84E+06	75	2,05E+06	2,2E+06
22	888750	1,33E+06	49	2,49E+06	2,52E+06	76	2,09E+06	2,14E+06
23	1,22E+06	1,27E+06	50	1,26E+06	1,26E+06	77	1,92E+06	1,83E+06
24	1,4E+06	1,42E+06	51	1,51E+06	1,43E+06	78	1,89E+06	2,02E+06
25	1,46E+06	1,36E+06	52	1,46E+06	1,52E+06	79	2,15E+06	2,11E+06
26	1,38E+06	1,35E+06	53	1,27E+06	1,24E+06	80	2,16E+06	2,12E+06
27	1,38E+06	1,28E+06	54	1,45E+06	1,37E+06	81	1,36E+06	1,39E+06

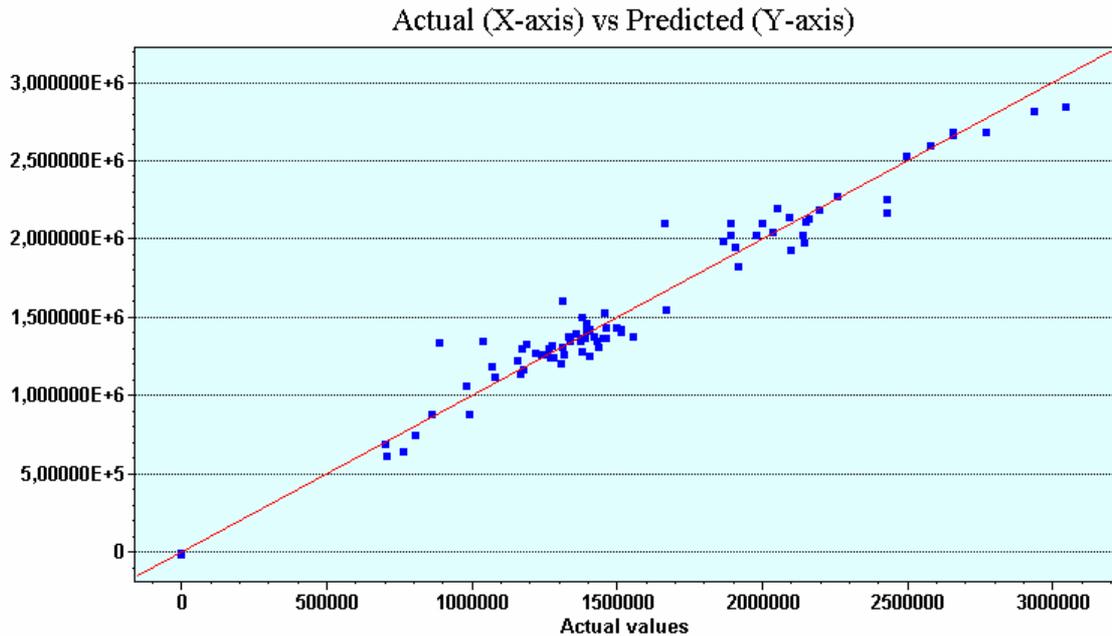


Figura 14 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis para os 81 lotes de reprodutores.

4.3 Validações dos modelos de redes neurais

A primeira tentativa de construção dos modelos de redes neurais foi realizada com o banco de dados com os registros dos nascimentos do ano de 1999. Para tanto, foram usadas como entradas os números de ovos incubados, de pintos nascidos e de pintos refugos e a saída eleita foi pintos aproveitados. O treinamento da rede apresentou ajuste perfeito, ou seja, $R^2 = 1,0$, ou extremamente próximo a isto. Nas demais combinações entre as variáveis em questão, invertendo entradas e saídas, os resultados se repetiram. Na validação do modelo com os registros desconhecidos do mesmo ano, e aplicando cada um dos modelos para estimar o que sucederia nos anos seguintes, o cenário foi sempre o mesmo, ou seja, $R^2 = 1,0$. O processo foi repetido para os anos de 2000, 2001, 2002 e 2003 e o quadro foi exatamente o mesmo. Os resultados estão apresentados nos Apêndices A, B e C. Assim sendo, procurou-se usar outras entradas para dificultar a predição. O modelo escolhido para exemplificar, foi o número de pintos aproveitados e as variáveis de entrada foram quantidade de bandejas, quantidade de ovos por bandeja e quantidade de ovos incubados. Os resultados obtidos estão descritos a seguir.

O treinamento da rede neural para a saída Pintos Aproveitados tem suas estatísticas descritas na Tabela 27.

Tabela 27 – Características do treinamento com 3.000 registros do modelo de rede neural para a predição da saída Pintos Aproveitados de 1999.

Estatísticas da predição	Valores
R ²	0,994584
Erro médio	114,2859
Correlação	0,997289
QME	39554,34
RQME	198,8827

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

Neste ano de 1999, a média \pm desvio padrão de pintos aproveitáveis dos lotes, por nascimento, foi de: 3.464 ± 2.673 , com coeficiente de variação (CV) de 77,16%.

A contribuição das variáveis de entrada, durante o treinamento da rede neural em questão está exposta na Tabela 28 e na Figura 15.

Tabela 28 – Importância relativa (contribuições) das variáveis de entrada para a saída Pintos Aproveitados de 1999.

Entradas	Importância relativa
Quantidade ovos incubados	0,905116
Quantidade de bandejas 1	0,074
Quantidade de bandejas	0,016
Quantidade de ovos por bandeja	0,004
Quantidade de ovos por bandeja 1	0,001

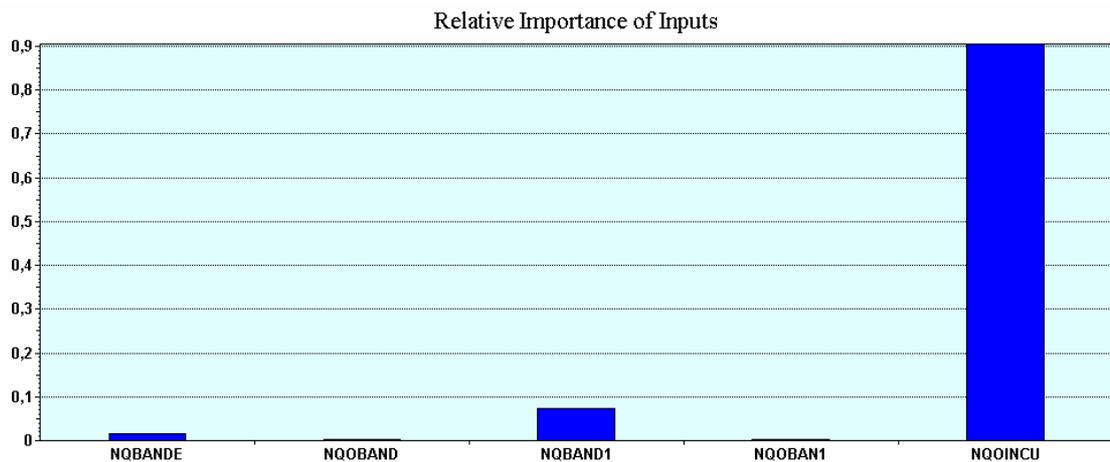


Figura 15 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Aproveitados de 1999.

Sabe-se que restaram registros de 1999 que não foram utilizados no treinamento da rede, mas para os quais foi realizada a predição com o modelo gerado. A Tabela 29 e a Figura 16 expressam os resultados obtidos.

Tabela 29 – Características do teste do modelo de rede neural de 1999 para a predição da saída Pintos Aproveitados em 2.822 registros do mesmo ano.

Estatísticas da predição	Valores
R ²	0,964493
Erro médio	292,19
Correlação	0,983281
QME	229279,7
RQME	478,8316

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

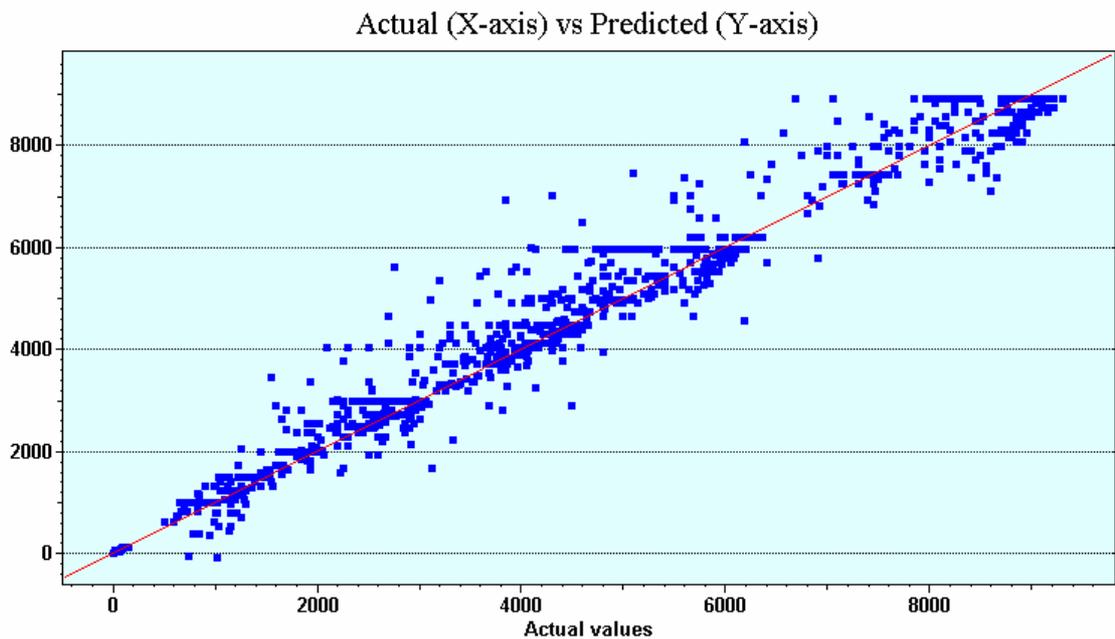


Figura 16 – Valores reais (X) versus valores preditos (Y) de Pintos Aproveitáveis testados em 2.822 registros de 1999.

O modelo com os dados de 1999 foi utilizado para prever os resultados dos 6.500 registros do ano 2000. Estes, podem ser visualizados na Tabela 30 e na Figura 17.

Tabela 30 – Características do teste do modelo de rede neural de 1999 para a predição da saída Pintos Aproveitados em 6.500 registros de 2000.

Estatísticas da predição	Valores
R ²	0,976182
Erro médio	152,3355
Correlação	0,988159
QME	50007,58
RQME	223,6237

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

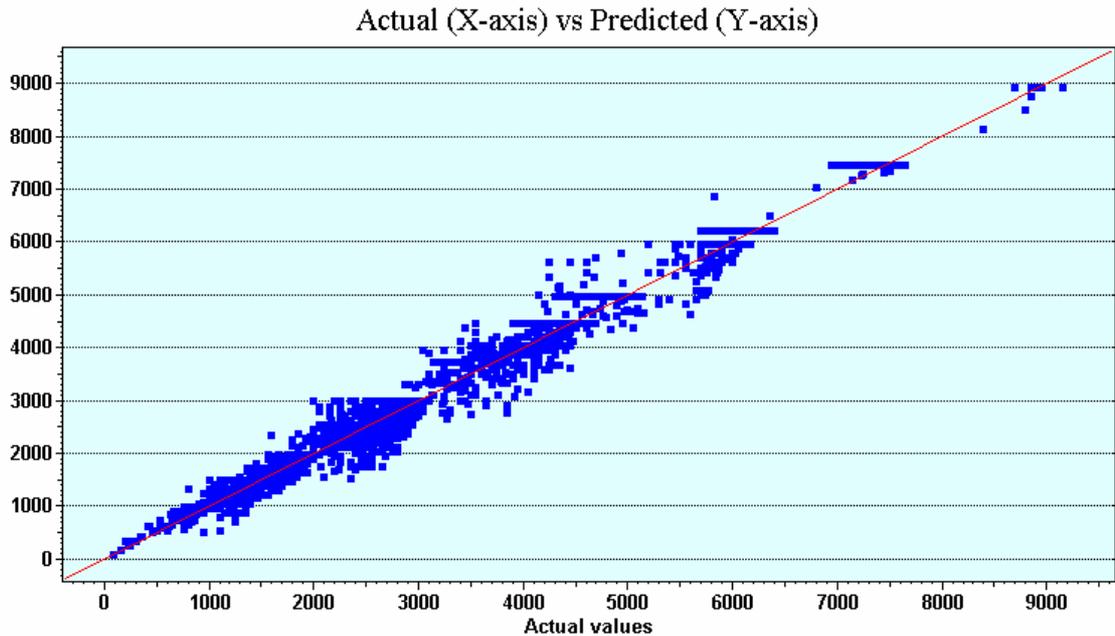


Figura 17 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados 6.500 registros de 2000 com o modelo de 1999.

A validação para os registros de 2001 revelou estatísticas precisas, representadas por um R^2 de 0,97 e Erro médio de 138,25 pintos (Tabela 31 e Figura 18).

Tabela 31 – Características do teste do modelo de rede neural de 1999 para a predição da saída Pintos Aproveitados em 9.183 registros de 2001.

Estatísticas da predição	Valores
R^2	0,976876
Erro médio	138,2551
Correlação	0,989117
QME	46798,2
RQME	216,3289

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

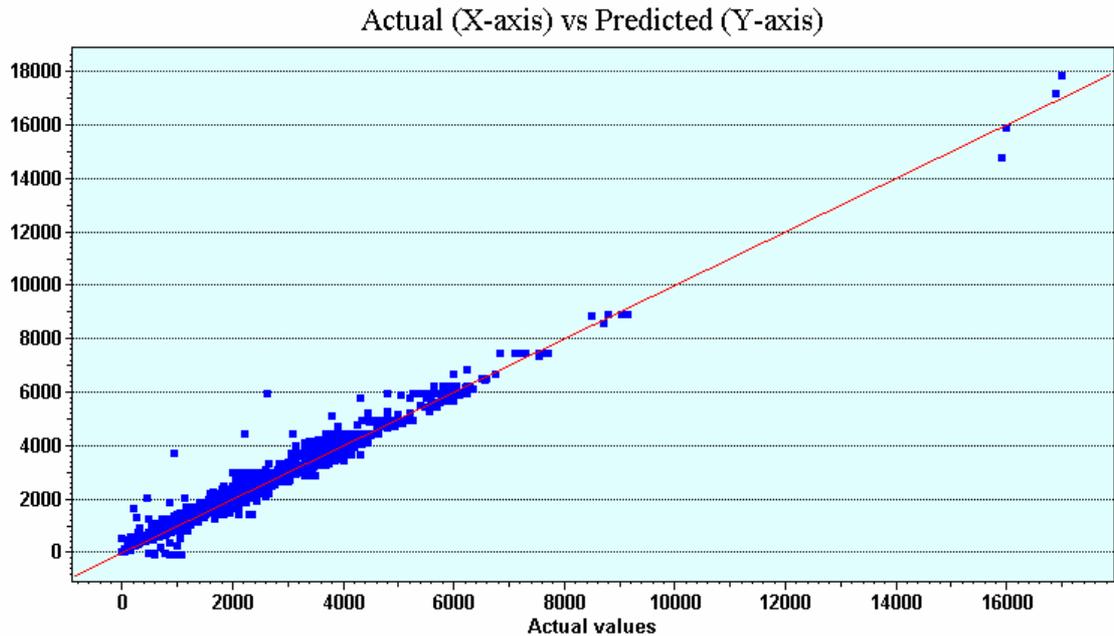


Figura 18 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados 9.183 registros de 2001 com o modelo de 1999.

Seguindo com o mesmo objetivo de validar o modelo de rede gerado com os dados de 1999, este foi testado frente aos registros de 2002. A Tabela 32 e a Figura 19 expõem os resultados obtidos.

Tabela 32 – Características do teste do modelo de rede neural de 1999 para a predição da saída Pintos Aproveitados em 7.307 registros de 2002.

Estatísticas da predição	Valores
R ²	0,963355
Erro médio	215,0035
Correlação	0,981894
QME	180579,6
RQME	424,9465

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

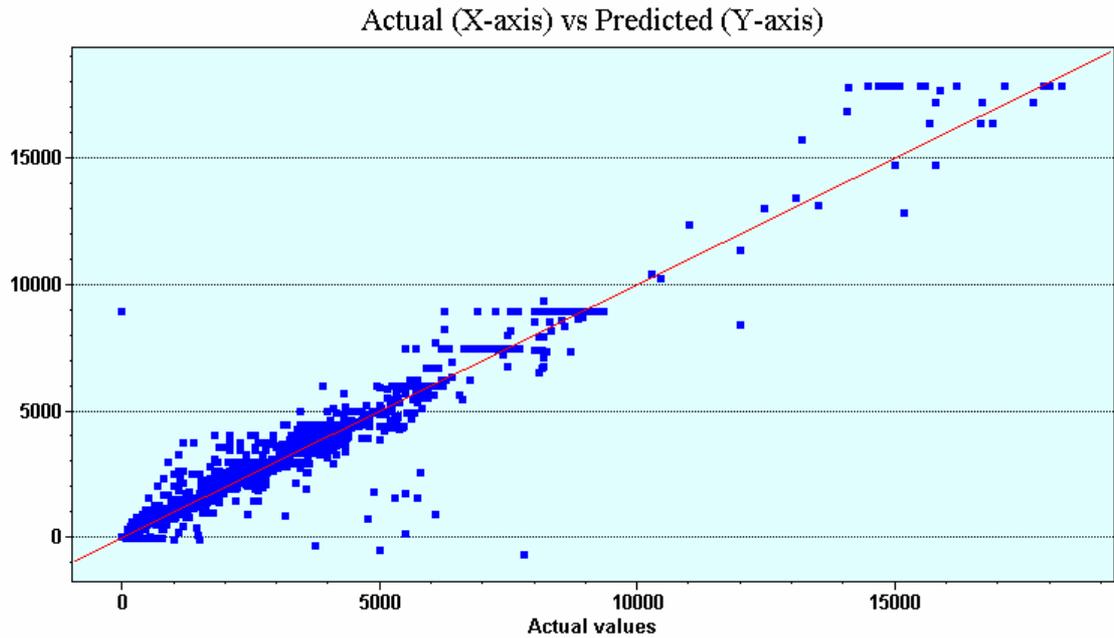


Figura 19 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados 7.307 registros de 2002 com o modelo de 1999.

Para o ano seguinte, o modelo de rede neural artificial de 1999 também foi capaz de prever resultados (Tabela 33 e Figura 20).

Tabela 33 – Características do teste do modelo de rede neural de 1999 para a predição da saída Pintos Aproveitados em 6.903 registros de 2003.

Estatísticas da predição	Valores
R^2	0,969297
Erro médio	165,154
Correlação	0,98464
QME	90950,21
RQME	301,5795

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

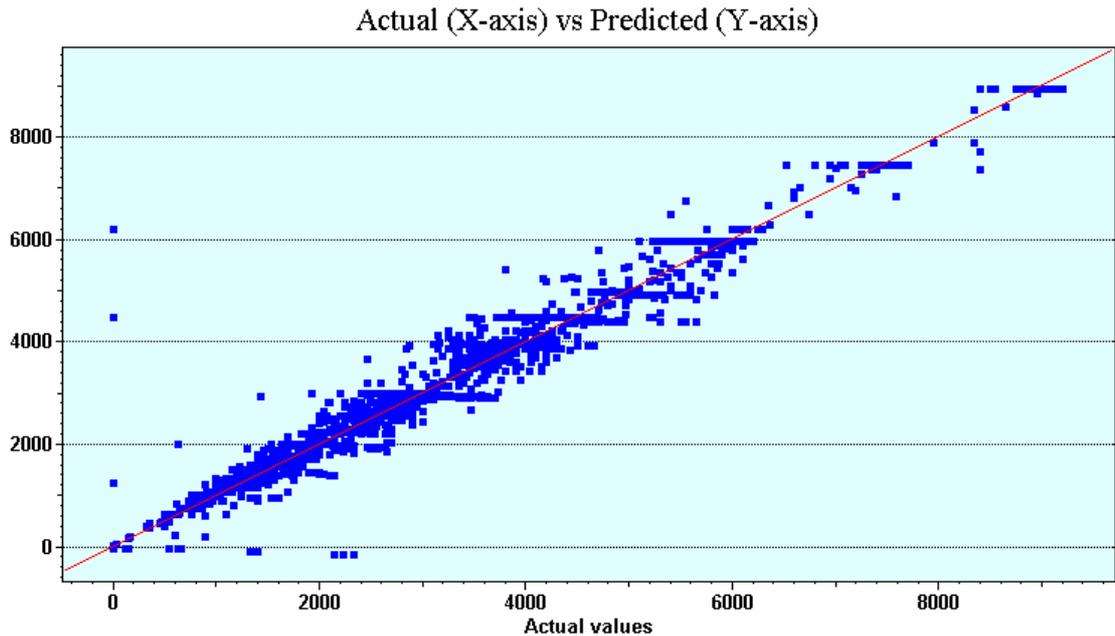


Figura 20 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados 6.903 registros de 2003 com o modelo de 1999.

Com os registros do ano de 2000 foi realizado o mesmo procedimento. Construiu-se um modelo de rede neural artificial com 4000 registros e as estatísticas da rede estão contidas na Tabela 34.

Tabela 34 – Características do treinamento com 4.000 registros do modelo de rede neural para a predição da saída Pintos Aproveitados de 2000.

Estatísticas da predição	Valores
R ²	0,980154
Erro médio	152,9935
Correlação	0,990027
QME	45685,2
RQME	213,741

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

A média \pm desvio padrão dos pintos aproveitáveis, por nascimento, no ano de 2000 foi de 2.919 ± 1.449 e CV de 49,64%.

Tabela 35 – Importância relativa (contribuições) das variáveis de entrada para a saída Pintos Aproveitados de 2000.

Entradas	Importância relativa
Quantidade de bandejas	0,596
Quantidade ovos incubados	0,325
Quantidade de ovos por bandeja	0,0796

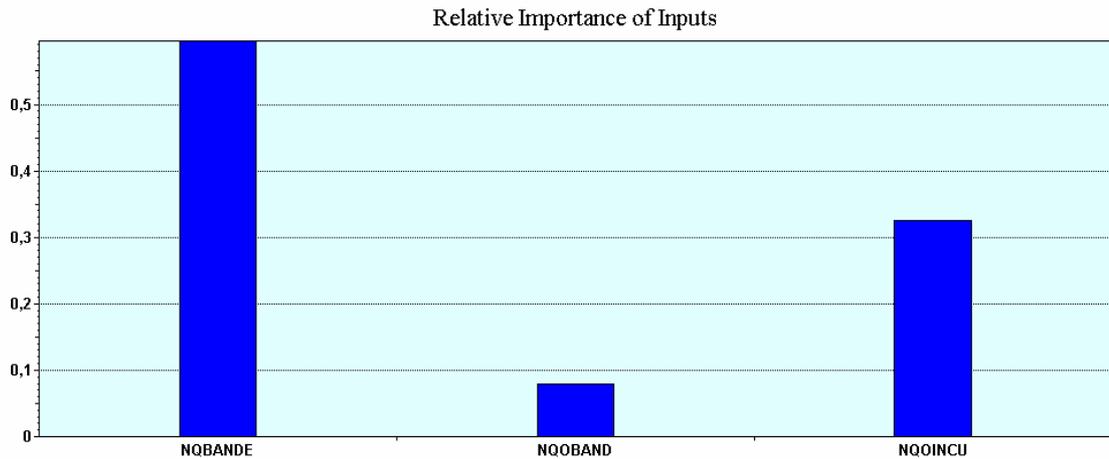


Figura 21 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Aproveitados de 2000.

Os registros que não foram utilizados no treinamento da rede foram testados e os resultados estão contidos na Tabela 36 e na Figura 22.

Tabela 36 – Características do teste do modelo de rede neural de 2000 para a predição da saída Pintos Aproveitados em 2.499 registros do mesmo ano.

Estatísticas da predição	Valores
R^2	0,983582
Erro médio	138,1825
Correlação	0,993373
QME	29081,49
RQME	170,533

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

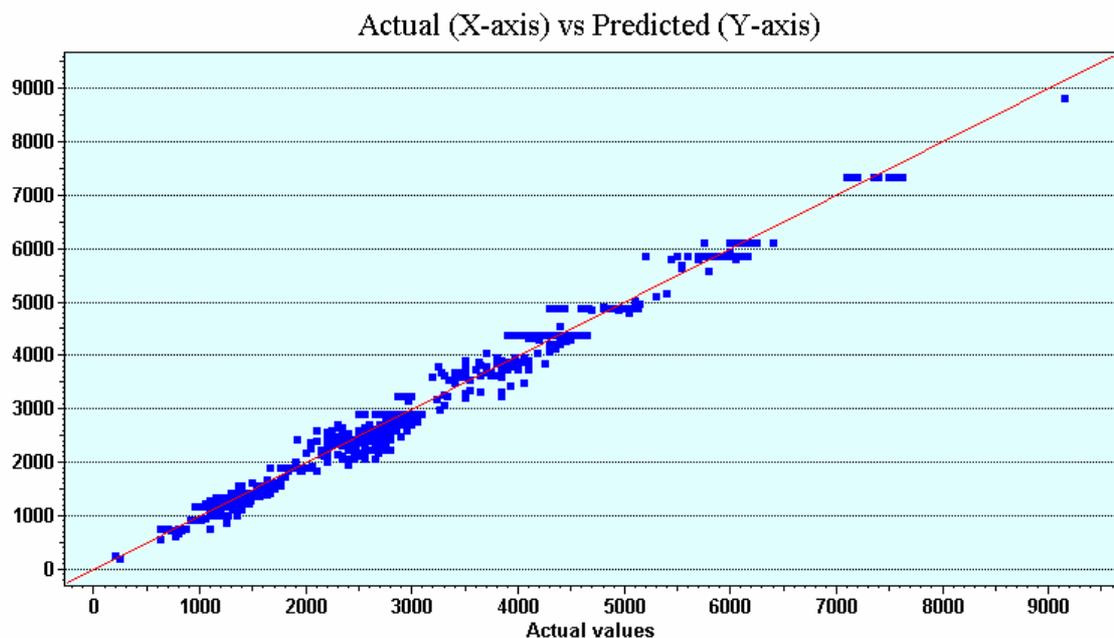


Figura 22 – Valores reais (X) versus valores preditos (Y) de Pintos Aproveitáveis testados em 2.499 registros de 2000 com o modelo do mesmo ano.

Na Tabela 37 e Figura 23 são visualizados os valores obtidos com as previsões dos registros de 2001, aplicando-se o modelo de 2000.

Tabela 37 – Características do teste do modelo de rede neural de 2000 para a previsão da saída Pintos Aproveitados em 9.183 registros de 2001.

Estatísticas da previsão	Valores
R^2	0,958464
Erro médio	174,7383
Correlação	0,979714
QME	84060,89
RQME	289,9326

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

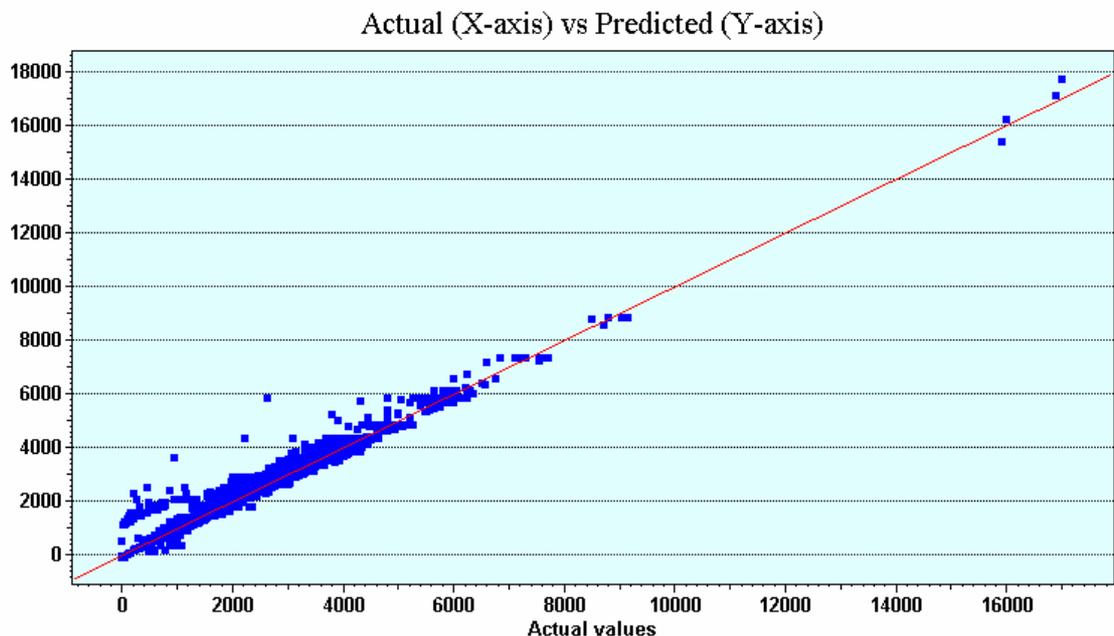


Figura 23 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados 9.183 registros de 2001 com o modelo de 2000.

O mesmo procedimento, previsão através do modelo de rede neural gerado com os registros de 2000, foi aplicado para as previsões do aproveitamento de pintos em 2002 (Tabela 38 e Figura 24).

Tabela 38 – Características do teste do modelo de rede neural de 2000 para a previsão da saída Pintos Aproveitados em 7.307 registros de 2002.

Estatísticas da previsão	Valores
R^2	0,972886
Erro médio	208,1933
Correlação	0,986403
QME	133610,8
RQME	365,5281

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

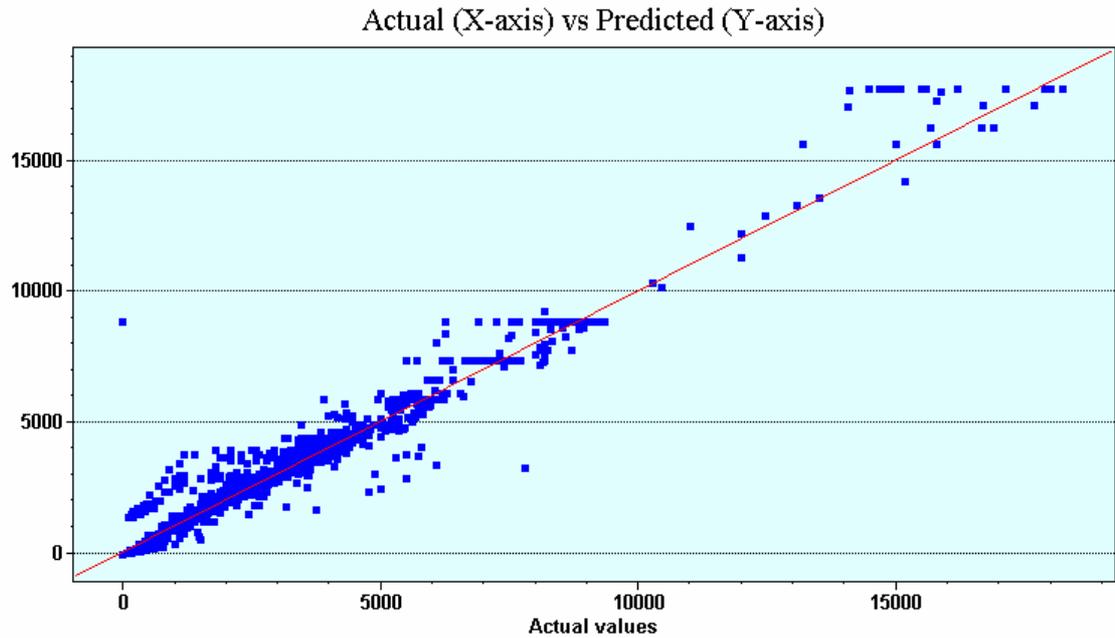


Figura 24 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados 7.307 registros de 2002 com o modelo de 2000.

A validação com os dados de 2003 estão descritos na Tabela 39 e na Figura 25.

Tabela 39– Características do teste do modelo de rede neural de 2000 para a predição da saída Pintos Aproveitados em 6.903 registros de 2003.

Estatísticas da predição	Valores
R^2	0,975112
Erro médio	160,8005
Correlação	0,987556
QME	73724,61
RQME	271,5228

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

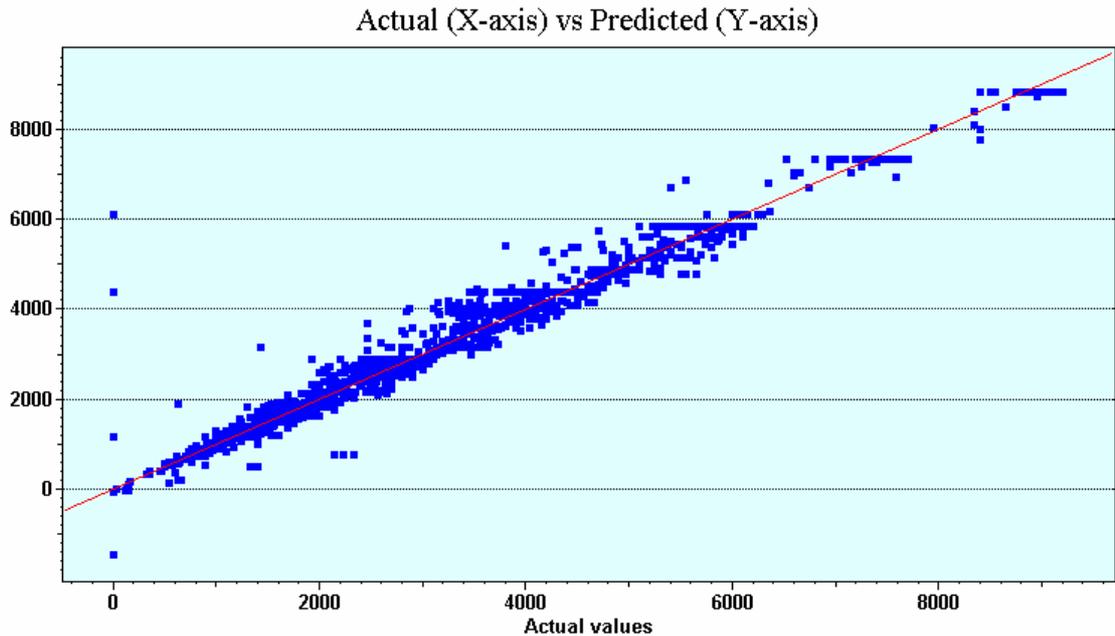


Figura 25 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados 6.903 registros de 2003 com o modelo de 2000.

Em 2001, foram usados 7.000 registros para o treinamento da rede neural artificial. A Tabela 40 apresenta as características do modelo obtido.

Tabela 40 – Características do treinamento com 7.000 registros do modelo de rede neural para a predição da saída Pintos Aproveitados de 2001.

Estatísticas da predição	Valores
R ²	0,984409
Erro médio	125,2999
Correlação	0,992174
QME	30,245,7
RQME	173,9129

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

No ano de 2001, a produção média \pm desvio padrão de pintos aproveitáveis por nascimento 2.463 ± 1.422 e CV de 57,73%.

As contribuições das variáveis de entrada estão indicadas na Tabela 41 e na Figura 26.

Tabela 41– Importância relativa (contribuições) das variáveis de entrada para a saída Pintos Aproveitados de 2000.

Entradas	Importância relativa
Quantidade ovos incubados	0,824
Quantidade de bandejas	0,098
Quantidade de bandejas 1	quantidade de 0,071 bandejas
Quantidade de ovos por bandeja	quantidade de 0,005 ovos por bandeja

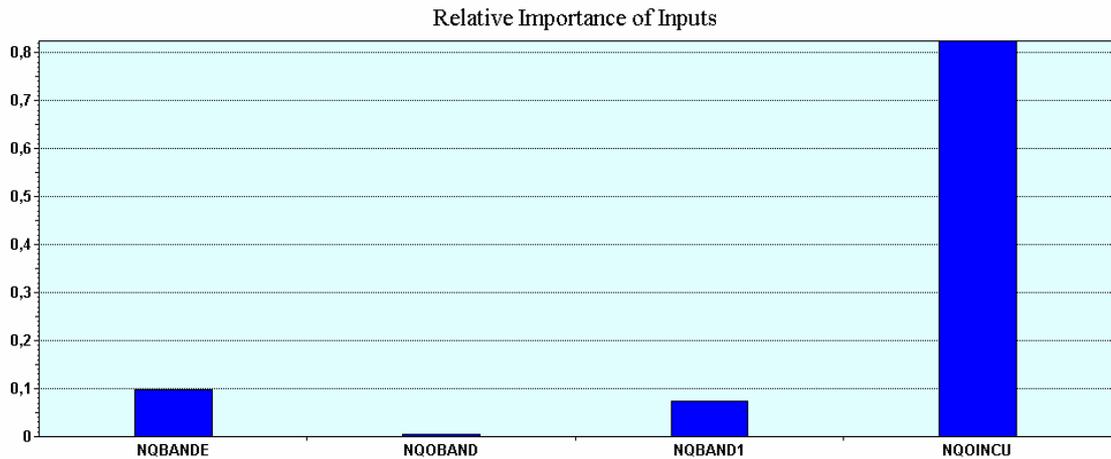


Figura 26 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Aproveitados de 2001.

Os resultados do teste da rede neural de 2001 com as previsões para o restante dos registros de pintos aproveitados neste ano, e que não participaram do treinamento, estão mostrados na Tabela 42 e na Figura 27.

Tabela 42 – Características do teste do modelo de rede neural de 2001 para a previsão da saída Pintos Aproveitados em 2.183 registros do mesmo ano.

Estatísticas da predição	Valores
R ²	0,966364
Erro médio	174,2394
Correlação	0,983936
QME	73124,67
RQME	270,4157

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

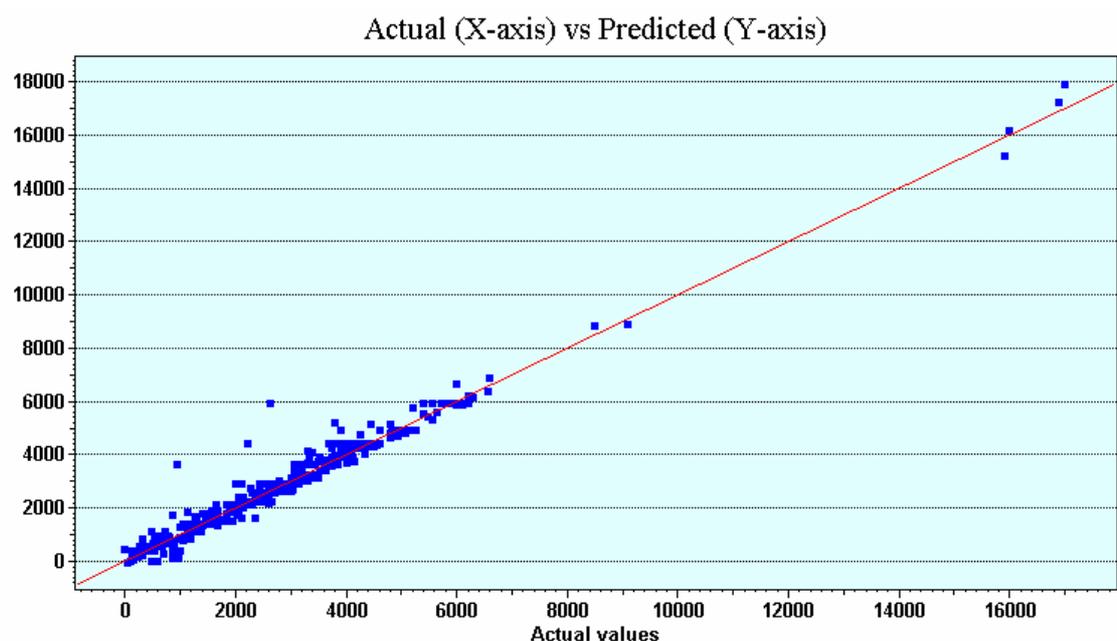


Figura 27 – Valores reais (X) versus valores preditos (Y) de Pintos Aproveitáveis testados em 2.183 registros de 2001 com o modelo do mesmo ano.

As previsões para o ano seguinte através do modelo de 2001, podem ser apreciados na Tabela 43 e na Figura 28.

Tabela 43 – Características do teste do modelo de rede neural de 2001 para a previsão da saída Pintos Aproveitados em 7.307 registros de 2002.

Estatísticas da previsão	Valores
R ²	0,97212
Erro médio	202,3187
Correlação	0,98628
QME	137387,9
RQME	370,6588

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

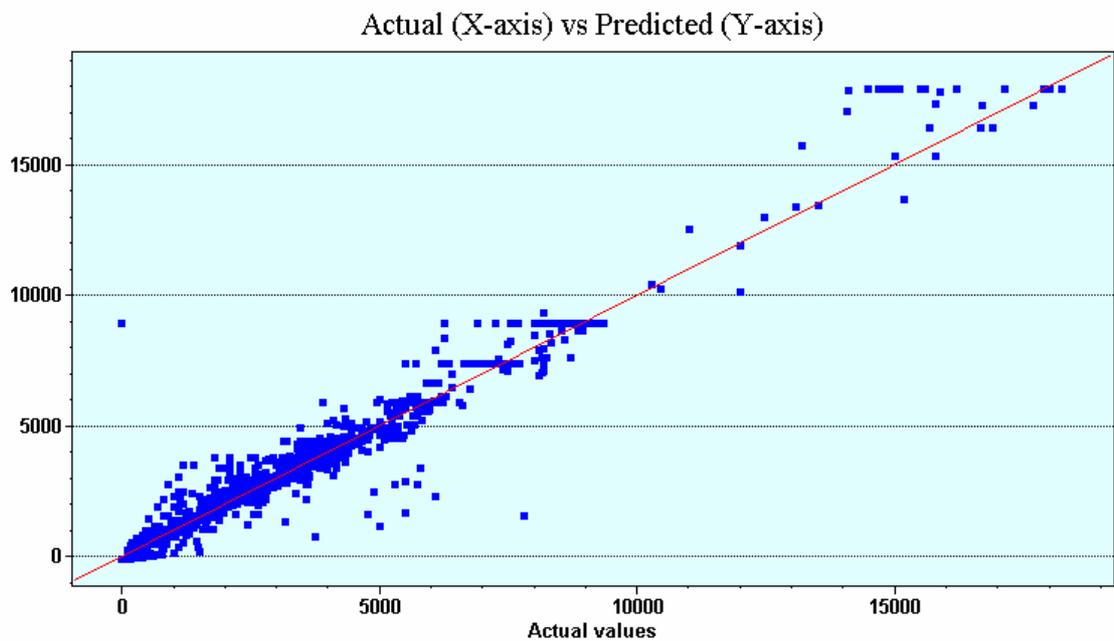


Figura 28 – Valores reais (X) versus valores preditos (Y) de Pintos Aproveitáveis testados em 7.307 registros de 2002 com o modelo de 2001.

Obedecendo a mesma estratégia, o modelo de 2001 fez as previsões para o aproveitamento de pintos de 2003. Os resultados são apresentados na Tabela 44 e na Figura 29.

Tabela 44 – Características do teste do modelo de rede neural de 2001 para a previsão da saída Pintos Aproveitados em 6.903 registros de 2003.

Estatísticas da previsão	Valores
R ²	0,973367
Erro médio	163,3583
Correlação	0,986855
QME	78893,76
RQME	280,8803

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

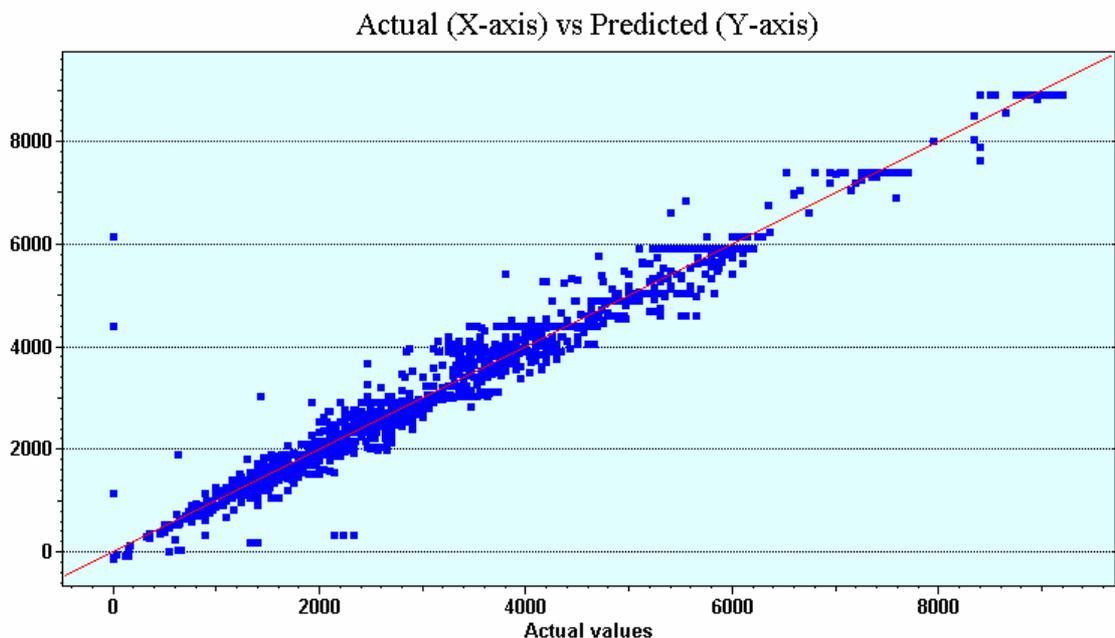


Figura 29 – Valores reais (X) versus valores preditos (Y) de Pintos Aproveitáveis testados em 6.903 registros de 2003 com o modelo de 2001.

Utilizaram-se 5.000 registros de 2002 para o treinamento da rede neural artificial e os resultados estão na Tabela 45.

Tabela 45 – Características do treinamento com 5.000 registros do modelo de rede neural para a previsão da saída Pintos Aproveitados de 2002.

Estatísticas da previsão	Valores
R ²	0,984409
Erro médio	125,2999
Correlação	0,992174
QME	30,245,7
RQME	173,9129

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

A média \pm desvio padrão de pintos aproveitáveis, por nascimento, no ano de 2002 foi de 3.249 ± 2.220 e CV de 68,33%.

Na Tabela 46 e na Figura 30 vemos as importâncias relativas das variáveis de entrada para a saída Pintos Aproveitados em 2002.

Tabela 46 – Importância relativa (contribuições) das variáveis de entrada para a saída Pintos Aproveitados de 2002.

Entradas	Importância relativa
Quantidade ovos incubados	0,6616
Quantidade de bandejas 1	0,321
Quantidade de ovos por bandeja	0,004

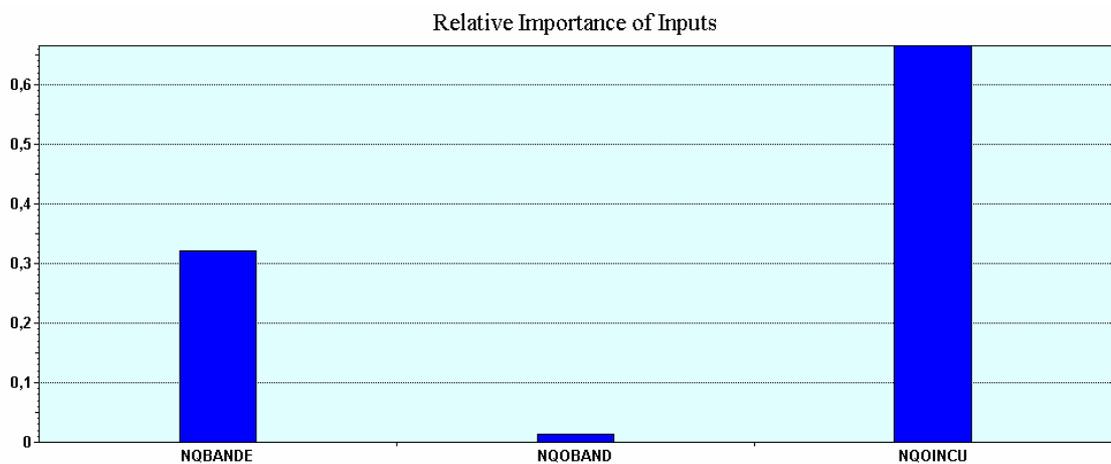


Figura 30 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Aproveitados de 2002.

Os resultados da aplicação do modelo da rede neural de 2002, para prever o aproveitamento de pintos neste mesmo ano, e que não participaram da fase de treinamento, estão expostos na Tabela 47 e Figura 31.

Tabela 47 – Características do teste do modelo de rede neural de 2002 para a predição da saída Pintos Aproveitados em 2.308 registros do mesmo ano.

Estatísticas da predição	Valores
R ²	0,974841
Erro médio	250,4911
Correlação	0,987593
QME	149929,3
RQME	387,2071

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

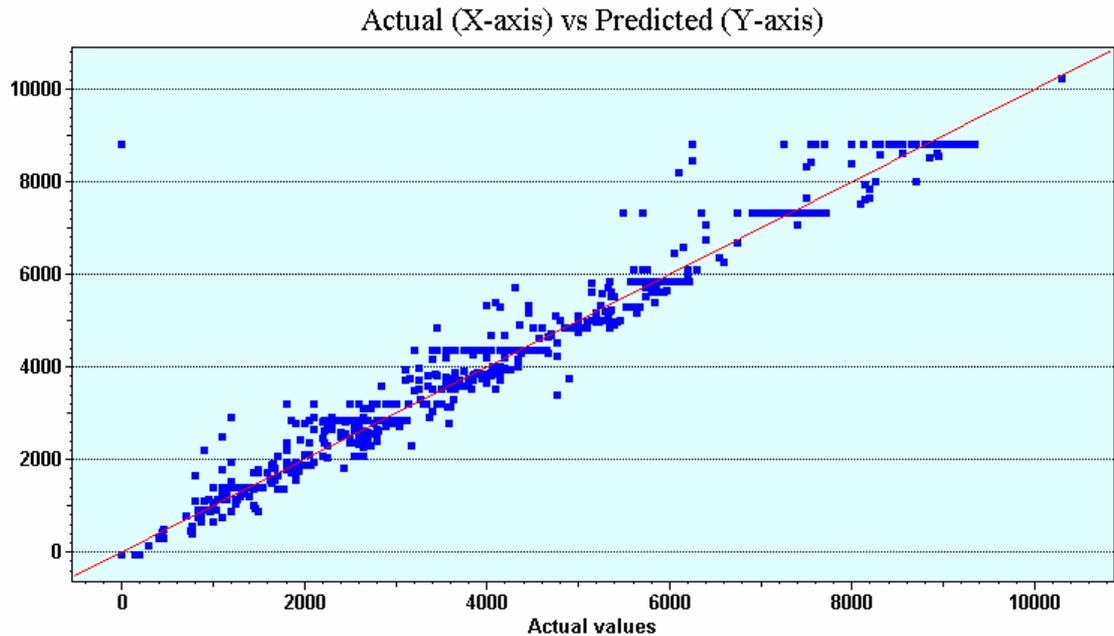


Figura 31 – Valores reais (X) *versus* valores preditos (Y) de Pintos Aproveitáveis testados em 2.308 registros de 2002 com o modelo do mesmo ano.

Na Tabela 48 e na Figura 32, são observadas as características das predições sobre o aproveitamento dos pintos em 2003, quando foi aplicada a rede neural treinada com dados de 2002.

Tabela 48– Características do teste do modelo de rede neural de 2002 para a predição da saída Pintos Aproveitados em 6.903 registros de 2003.

Estatísticas da predição	Valores
R^2	0,973367
Erro médio	163,3583
Correlação	0,986855
QME	78893,76
RQME	280,8803

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

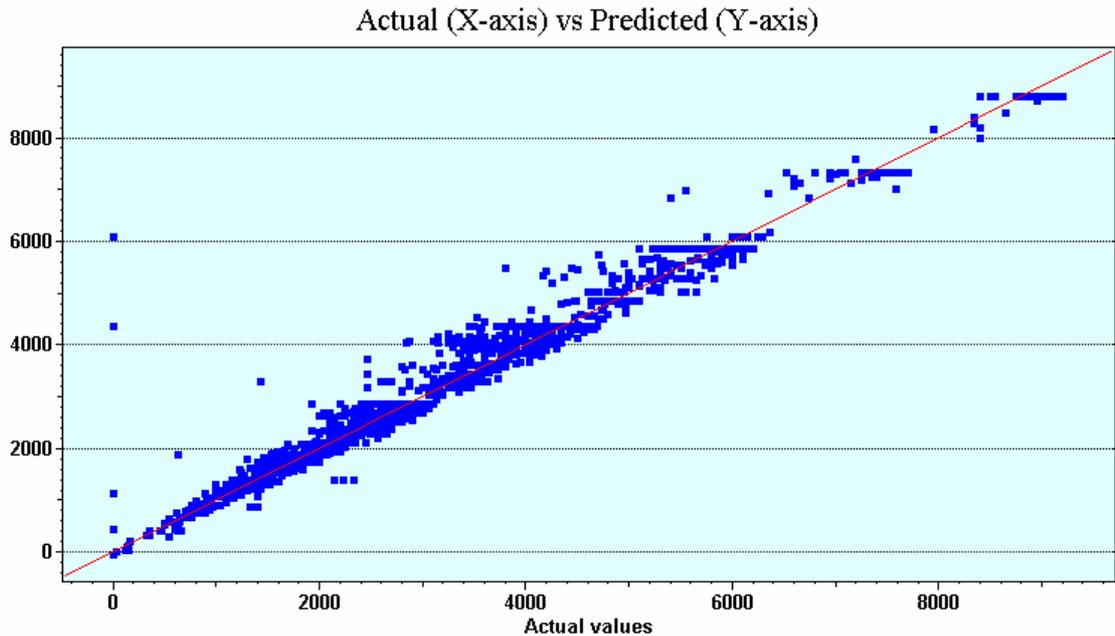


Figura 32 – Valores reais (X) versus valores preditos (Y) de Pintos Aproveitáveis testados em 6.903 registros de 2003 com o modelo de 2002.

Finalmente, foi elaborada a rede neural com 4.500 registros dos pintos aproveitados em 2003. As estatísticas obtidas podem ser observadas na Tabela 49.

Tabela 49 – Características do treinamento com 4.500 registros do modelo de rede neural para a predição da saída Pintos Aproveitados de 2003.

Estatísticas da predição	Valores
R ²	0,978566
Erro médio	151,4005
Correlação	0,989225
QME	66876,26
RQME	258,6044

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

No último ano estudado, 2003, a média \pm desvio padrão de pintos aproveitáveis, por nascimento, foi de 3.234 ± 1.721 e CV de 53,21%.

Em 2003, as importâncias relativas das variáveis de entrada usadas na construção do modelo são oferecidas na Tabela 50 e na Figura 33.

Tabela 50 – Importância relativa (contribuições) das variáveis de entrada para a saída Pintos Aproveitados de 2002.

Entradas	Importância relativa
Quantidade de ovos por bandeja	0,461
Quantidade de ovos por bandeja	0,461
Quantidade de bandejas	0,067
Quantidade de ovos incubados	0,006
Quantidade de bandejas 1	0,004

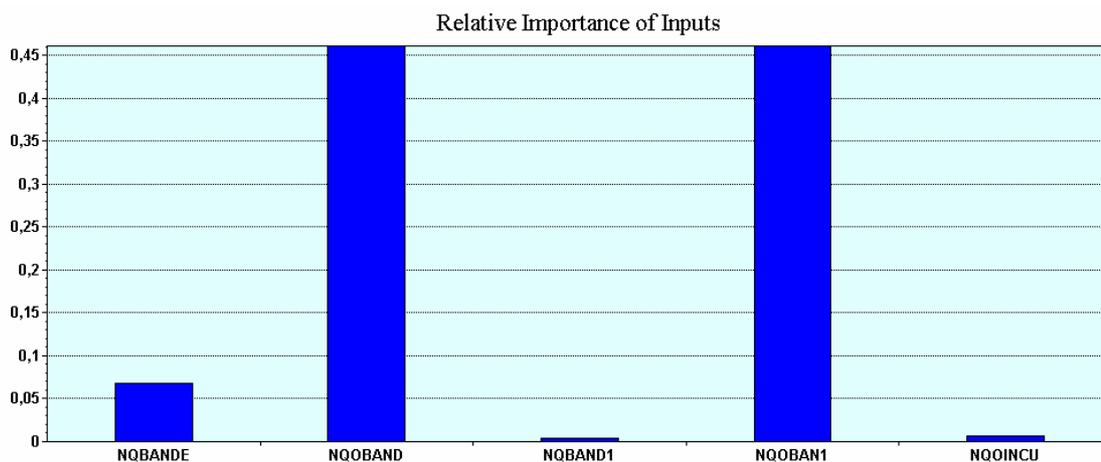


Figura 33 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Aproveitados de 2003.

Por último, a Tabela 51 e a Figura 34 apresentam as previsões da rede neural de 2003 sobre os registros restantes do mesmo ano. Como sempre, estes não participaram do treinamento do modelo.

Tabela 51 – Características do teste do modelo de rede neural de 2003 para a predição da saída Pintos Aproveitados em 2.403 registros do mesmo ano.

Estatísticas da predição	Valores
R ²	0,968769
Erro médio	159,3511
Correlação	0,98435
QME	81961,37
RQME	286,289

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

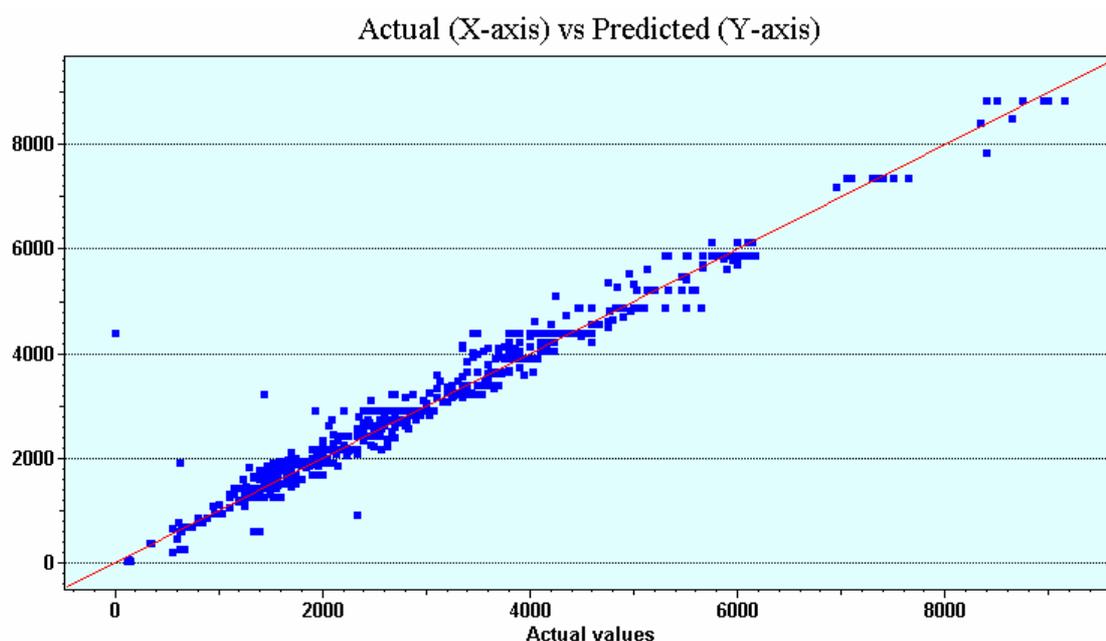


Figura 34 – Valores reais (X) versus valores preditos (Y) de Pintos Aproveitáveis testados em 2.403 registros de 2003 com o modelo do mesmo ano.

5 DISCUSSÃO

Os resultados obtidos nesta dissertação demonstraram claramente que os eventos que envolvem um incubatório avícola podem ser explicados através da criação de modelos de inteligência artificial que empregam redes neurais artificiais. Assim, foi plenamente atingido o objetivo que motivou a realização deste estudo.

Anteriormente, pesquisadores do CDPA já haviam demonstrado que esta metodologia pode ser utilizada para o gerenciamento de reprodutoras pesadas (Guahyba, 2001; Salle et al., 2001; Salle et al., 2003) e de frangos de corte (Reali, 2004). Na literatura consultada não foram encontradas publicações que utilizassem as redes neurais nos incubatórios para que se pudesse comparar resultados. Além dos trabalhos desenvolvidos no CDPA, citados anteriormente e que mais se aproximam do objetivo deste estudo, existem referências sobre inteligência artificial, especificamente as redes neurais artificiais, para a criação de modelos para ascite dos frangos (Roush et al., 1997; Roush et al., 1996; Roush et al., 2001) e para a inspeção de carcaças nos abatedouros utilizando esta tecnologia acoplada à digitalização de imagens (Park & Chen, 2003; Park & Chen, 2001; Park et al., 1998).

Os resultados demonstraram, que foi possível a classificação da linhagem das aves a partir das informações dos parâmetros produtivos contidos nas variáveis de entrada. Para a linhagem Cobb, com o maior número de lotes, o modelo foi capaz de classificar corretamente 100% dos lotes pertencentes a esta linhagem. No entanto, para as linhagens com menor número de lotes participantes do aprendizado das redes neurais, como era de se esperar, as classificações foram menos precisas. Nestes casos, é recomendável, embora de difícil solução prática, que se adicione um número maior de amostras para melhorar o desempenho do modelo. Em geral, as empresas elegem uma linhagem principal, neste caso a Cobb, e escolhem alguma, ou algumas, outras para não ficarem excessivamente dependentes dos fornecedores de pintos matrizes.

De qualquer forma, fica evidente que é possível a classificação das linhagens avícolas através da utilização de redes neurais artificiais. Desta maneira, processos simulatórios podem ser realizados como suporte às decisões daqueles que têm a responsabilidade de escolha das linhagens com a finalidade de preencher satisfatoriamente as necessidades produtivas da empresa em consonância com as suas características de mercado. Na literatura consultada não foi encontrada nenhuma

referência que relatasse a classificação de linhagens através de modelos de redes neurais artificiais, de forma igual, ou similar, ao aqui realizado.

É conhecido que as redes neurais necessitam um grande número de registros para construir modelos precisos. Felizmente, com 81 linhas de dados referentes ao fechamento dos lotes da integração que forneceu os dados foi possível o treinamento de seis redes neurais que explicam e predizem as saídas Ovos Incubáveis, Percentagem De Ovos Incubáveis, Ovos Incubados, Percentagem De Ovos Incubados, Pintos Nascidos, Pintos Aproveitáveis as quais são os pontos medulares de um incubatório. Quando testadas, embora não houvesse volume de dados para uma validação mais consistente, foram observadas as importâncias relativas de cada variável de entrada para a construção do modelo e o R^2 , o erro médio e o QME eram indicadores de um bom ajuste. Nestes casos, o R^2 variou de 0,93 a 0,99 demonstrando, mais uma vez, que o incubatório pode ter seus registros analisados através das redes neurais artificiais. É interessante observar que o erro médio pode ser medido em alguns milhares dando a primeira impressão de ser grande. Porém ele adquire a dimensão real, quando se verifica que os valores médios de ovos incubáveis, ovos incubados, pintos nascidos e pintos aproveitáveis são expressos em milhões. No caso dos valores expressos em percentuais, sejam de ovos incubáveis e de ovos incubados, o erro médio situou-se entre 1,13% e 3,43%, respectivamente.

Ao serem comparados os resultados deste estudo com os trabalhos desenvolvidos pelo mesmo grupo de pesquisadores desta Universidade, é observado que os modelos de redes neurais gerados para o incubatório são mais precisos do que aqueles relacionados com as reprodutoras pesadas e menos consistentes, quando comparados com os modelos para o gerenciamento dos frangos de corte. Estas diferenças podem estar relacionadas com as diferenças nas características das explorações, e por via de consequência na maior, ou menor, variabilidade dos dados originados por cada um destes segmentos da avicultura. Da mesma forma que o relatado nos experimentos com reprodutoras e com frangos de corte, aqui também foram estabelecidas as importâncias relativas, ou contribuições de cada uma das variáveis de entrada para a saída escolhida. Desta forma, neste trabalho também é oferecido um dado objetivo para ser avaliado por ocasião do gerenciamento do incubatório.

Na tentativa de validar modelos com dados desconhecidos pelas redes na fase de treinamento, foram construídos modelos de redes neurais para a saída Pintos Aproveitados, Pintos Nascidos e Pintos Refugos (Apêndices A, B e C). Os resultados,

tanto para os treinamentos quanto para as validações, foram de $R^2=1,0$, ou muito próximos a este valor, o chamado ajuste perfeito. Inicialmente, ficou-se com a impressão de que haveria pouco valor na construção deste tipo de rede já que ela refletiria o óbvio. É verdade, mas a obtenção de um resultado que poderia ser alcançado através de uma calculadora eletrônica capaz de realizar quatro operações aritméticas reforça a credibilidade nesta tecnologia de inteligência artificial que constrói modelos complexos, nos quais são consideradas as relações não lineares e as interações entre as variáveis. Por outro lado, estes modelos podem ser vistos como controles do procedimento, ou seja, chegaram aos resultados que se esperavam obter e, com isto, alicerçam a credibilidade naqueles outros em que as inter-relações entre as variáveis são mais complexas. Assim sendo, e para fugir da circunstância do ajuste perfeito, foram construídos modelos de redes neurais para a saída Pintos Aproveitados com diferentes variáveis de entrada. Usaram-se os registros do ano em questão e validados com dados desconhecidos do mesmo ano e dos anos subseqüentes. Mesmo nesta situação deliberadamente adversa, os modelos foram ajustados e capazes de prever com precisão confiável os acontecimentos futuros.

A média por nascimento de Pintos Aproveitados em 1999 foi de 3.464 aves. O treinamento do modelo apresentou $R^2=0,99$ e o erro médio de 114 animais (Tabela 27). Na validação com os lotes deste mesmo ano que não participaram do treinamento da rede neural (Tabela 29 e Figura 18) o cenário se repetiu, embora o erro, como era de se esperar, fosse um pouco maior, mas, mesmo assim, oferecendo uma predição com utilidade para uma eventual tomada de decisão.

O modelo de rede neural artificial Pintos Aproveitados em 1999 foi capaz de prever adequadamente o aproveitamento dos pintos que nasceriam em 2000, 2001, 2002 e 2003 como pode ser visto nas diferentes tabelas e figuras que expressam estes resultados (tabelas 30 a 33 e figuras 19 a 22). O mesmo fenômeno foi evidenciado quando se construiu a rede para 2000 e a validou para os registros do mesmo ano que ficaram de fora do treinamento. (tabelas 34 e 36 e Figura 24) e, posteriormente, usando o mesmo modelo de 2000 para prever 2001, 2002 e 2003 (tabelas 37 a 39 e figuras 25 a 27). Como poderá ser observado nas tabelas e figuras restantes, as validações dos demais modelos, sob circunstâncias similares, apresentaram os resultados semelhantes.

O emprego de uma nova proposta de análise dos resultados que utiliza banco de dados desenhados sob a ótica do contexto antigo traz contratempos. A maior dificuldade encontrada foi obter a informação completa dos lotes no mesmo banco de dados. Desta

forma, muitas das análises que poderiam ser realizadas ficaram inviabilizadas. Se, por um lado, é lamentável que milhares de registros de um determinado arquivo contenham somente parte da informação, já que outros dados relacionados estarão em outro conjunto de registros, por outro, é um fato compreensível e está de acordo com a maneira atual como a empresa analisa seus resultados. Ressalte-se que os dados mais importantes só serão reunidos após o fechamento dos lotes. Exemplo disto, são as 81 linhas com registros dos lotes fechados, comparados com os milhares de linhas de dados, com informações diárias, usados para a validação dos modelos de redes neurais com a saída Pintos Aproveitados. A alternativa de re-arranjo dos registros para formar um único arquivo, torna-se uma tarefa hercúlea e de difícil execução. No presente estudo, o arquivo ININFO tem 56.018 linhas com informações diárias das granjas de reprodutoras e do incubatório. Já o arquivo INOVOS, apresenta 35.000 linhas com os registros diários dos ovos processados e, de forma similar, o arquivo INNASC reúne em 43.828 linhas as informações anotadas diariamente sobre os nascimentos dos pintos. Neste ponto, o autor deste trabalho é levado a imaginar a riqueza de informações que estariam disponíveis em um sistema de registros desenhado especificamente para ser utilizado com a metodologia proposta neste trabalho e que, ressalte-se novamente, mostrou-se capaz de atingir o objetivo desta dissertação que era demonstrar a capacidade das redes neurais artificiais de explicarem os fenômenos que envolvem as atividades de um incubatório de uma integração avícola.

6 CONCLUSÃO

As redes neurais artificiais foram capazes de explicar os fenômenos envolvidos com as atividades do incubatório de uma integração avícola.

Com a criação de um sistema de registros delineado para a utilização de redes neurais artificiais as combinações de entradas e saídas serão sensivelmente melhoradas.

A técnica aqui proposta disponibiliza critérios objetivos, gerados cientificamente, que oferecerão subsídios para as decisões daqueles que têm a responsabilidade pelo incubatório. Também apresenta a importância relativa de cada variável de entrada para a saída escolhida e permite a realização de simulações para prever resultados futuros.

REFERÊNCIAS

ADDA, T. R. B. L. Embrio-diagnóstico. In: E.Gonzales and M.Macari. Manejo da incubação.2.ed. **Fundação Apinco de Ciência e Tecnologia Avícolas**, p.499-514, 2003.

AHMAD, H. A.; DOZIER, G. V.; ROLAND SR, D. A. Egg price forecasting using neural networks. **Journal of Applied Poultry Research**. v.10, p.162-171, 2001.

AMORIN, A. B., DUARTE, E. S., ZAFFARI, J. P., PAIM FILHO, J. R., COSTA NETO, M. V. Patologia da incubação. Não publicado 1-6-1985.

ARAÚJO, L. F. Nutrição pós-eclosão: aspectos teóricos e práticos. **Aveworld**. v.2, n.12, p.38-47, 2004.

ARGOV, S.; RAMESH, J.; SALMAN, A.; SINELNIKOV, I.; GOLDSTEIN, J.; GUTERMAN, H.; MORDECHAI, S. Diagnostic potential of Fourier-transform infrared micro spectroscopy and advanced computational methods in colon cancer patients. **Comunicado Técnico n. 257 Embrapa Suínos e Aves**. v.7, p.248-254, 2002.

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.

BAXT, W. G.; SHOFER, F. S.; SITES, F. D.; HOLLANDER, J. E. A neural network aid for the early diagnosis of cardiac ischemia in patients presenting to the emergency department with chest pain. **Ann. Emerg. Med**. v.40, n.6, p.575-583, 2002.

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.

BORNE, P. M.; COMTE, S. Vacinas e vacinação na produção avícola. **Gessulli Guias**, p.1-140, 2003.

BUZATU, D. A.; TAYLOR, K. K.; PERET, D. C.; DARSEY, J. A.; LANG, N. P. The determination of cardiac surgical risk using artificial neural networks. **J. Surg. Res**. v.95, n.1, p.61-66, 2001.

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.

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

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

- CHETHAM, S. M.; BARKER, T. M.; STAFFORD, W. Neural networks in cardiac electrophysiological signal classification. *Australas. Phys. Eng Sci. Med.* v.25, n.3, p.124-131, 2002.
- CRAVENER, T. L.; ROUSH, W. B. Improving neural network prediction of amino acid levels in feed ingredients. *Poult. Sci.* v.78, n.7, p.983-991, 1999.
- DAWSON, A. E.; AUSTIN, R. E.; JR, WEINBERG D. S. Nuclear grading of breast carcinoma by image analysis. Classification by multivariate and neural network analysis. *Am. J. Clin. Pathol.* v.95, p.S29-S37, 1991.
- DEY, B. P.; CHEN, Y. R.; HSIEH, C.; CHAN, D. E. Detection of septicemia in chicken livers by spectroscopy. *Poult. Sci.* v.82, n.2, p.199-206, 2003.
- 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.* v.49, n.11, p.21-23, 1999.
- FIALHO, F.B.; LEDUR, M.C. Estimador da produção de ovos. **Comunicado Técnico n. 257 Embrapa Suínos e Aves.** p.1-2, 2000a.
- FIALHO, F.B.; LEDUR, M.C. Modelo matemático para curvas de produção de ovos. **Comunicado Técnico n. 256 Embrapa Suínos e Aves.** p.1-3, 2000b.
- 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.
- FRANCO, J.L.K. Custo das doenças avícolas. **IV Encontro de qualidade industrial Ministério da Agricultura e Abastecimento e Indústrias Avícolas do RS.** Imbé - RS, 1996.
- GUAHYBA, Adriano da Silva. **Tese de Doutorado:** Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento de reprodutoras pesadas. Porto Alegre: UFRGS, Faculdade de Veterinária, PPGCV, 116p., 2001.
- GUSTIN, P. C. Gerenciamento administrativo e controle de qualidade do incubatório. In: E.Gonzales and M.Macari. Manejo da incubação.2.ed. **Fundação Apinco de Ciência e Tecnologia Avícolas**, p.471-498, 2003.
- HAN, M.; SNOW, P. B.; BRANDT, J. M.; PARTIN, A. W. Evaluation of artificial neural networks for the prediction of pathologic stage in prostate carcinoma. *Cancer.* v.91, n.8 Suppl, p.1661-1666, 2001.
- HEALD, C. W.; KIM, T.; SISCHO, W. M.; COOPER, J. B.; WOLFGANG, D. R. A computerized mastitis decision aid using farm-based records: an artificial neural network approach. *J. Dairy Sci.* v.83, n.4, p.711-720, 2000.
- 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.

KIRBY, Y.K.; MCNEW, R.W.; KIRBY, J.D.; WIDEMAN JR., R.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.

KOVÁCS, Z.L. Redes Neurais Artificiais: Fundamentos e Aplicações: um texto básico. 2.ed. São Paulo: **Edição acadêmica**, p.1-174, 1996.

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, p.482-485, 1999.

LIMA, I.L.; BERSCH, F.X. Avaliação técnica dos equipamentos de frangos de corte e seus diferenciais. **Anais do I Simpósio Brasil Sul de Avicultura**. Chapecó - SC, p.89-103, 2000.

LOCH, T.; LEUSCHNER, I.; GENBERG, C.; WEICHERT-JACOBSEN, K.; KUPPERS, F.; RETZ, M.; LEHMANN, J.; YFANTIS, E.; 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.

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.

PARK, B.; CHEN, Y. R. Matrix texture features of multi-spectral images on poultry carcasses. **J. agric. Engng**. v.78, p.127-139, 2001.

REALI, Egídio Henrique. **Dissertação de Mestrado**: Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento do Produção de Frangos de Corte. Porto Alegre: UFRGS, Faculdade de Veterinária, PPGCV, 127p., 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 21-11-2000.

ROSENBLATT, F. 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. 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. Artificial neural network prediction of amino acid levels in feed ingredients. **Poult. Sci**. v.76, n.5, p.721-727, 1997.

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.

ROUSH, W. B.; WIDEMAN JR., R. F. Evaluation of broiler growth velocity and acceleration in relation to pulmonary hypertension syndrome. **Poult. Sci.** v.79, n.2, p.180-191, 2000.

ROUSH, W. B.; WIDEMAN JR., R. F.; CAHANER, A.; DEEB, N.; CRAVENER, T. L. Minimal number of chicken daily growth velocities for artificial neural network detection of pulmonary hypertension syndrome (PHS). **Poult. Sci.** v.80, n.3, p.254-259, 2001.

SALLE, C. T. P.; CÉ, M. C.; LORENZINI, G.; SFOGGIA, M. V. B.; GUAHYBA, A. S.; MORAES, H. L. S.; NASCIMENTO, V. P. Correlation between aflatoxin and ocratoxin levels with production parameters in a poultry company. **Abstracts of the IV Asia-Pacific Poultry Health Conference.** Melbourne - Australia, p.131-131, 1998a.

SALLE, C.T.P.; CÉ, M.C.; LORENZINI, G; SFOGGIA, M.V.B.; GUAHYBA, A.S.; MORAES, H.L.S.; NASCIMENTO, V.P. Correlation between aflatoxin and ocratoxin levels with production parameters in a poultry company. **Abstracts of the 48th Western Poultry Disease Conference.** Vancouver - Canada, p.130-130, 1999a.

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 - Australia, p.148-148, 1998c.

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. **Abstracts of the 48th Western Poultry Disease Conference.** Vancouver - Canada, p.129-129, 1999c.

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.; SILVA, A. B. Prevenção de Doenças / Manejo Profilático / Monitorização. In: Berchieri Junior, Angelo and Macari, Marcos. **Doenças das Aves.**1.ed. p.03-12, 2000.

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 Estimar Parâmetros de Produção de Galinhas Reprodutoras Pesadas em Recria. **Revista Brasileira de Ciência Avícola.** v.3, p.257-264, 2001.

SALLE, C. T.; 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.

SOARES, Roberto Carlos Bastarrica. **Dissertação de Mestrado**: 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, Faculdade de Veterinária, PPGCV, 75p., 1995.

SNOW, P. B.; KERR, D. J.; BRANDT, J. M.; RODVOLD, D. M. Neural network and regression predictions of 5-year survival after colon carcinoma treatment. **Cancer**. v.91, n.8 Suppl, p.1673-1678, 2001.

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.

VIRGINI, C. E. Projeto incubatório. In: E.Gonzales and M.Macari. Manejo da incubação.2.ed. **Fundação Apinco de Ciência e Tecnologia Avícolas**, p.125-149, 2003.

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.

ZHANG, Z.; MARQUARDT, R.R.; WANG, G.; GUENTER, W.; CROW, G.H.; HAN, Z.; BEDFORD, M.R. A simple model for predicting the response of chicks to dietary enzyme supplementation. **J. Anim. Sci**. v.74, p.394-402, 1996.

APÊNDICE A – Pintos aproveitados em 1999

Nº. DE REGISTROS: 5.822

USADOS PARA TREINAR: 3.000

USADOS PARA TESTAR E VALIDAR: 2.822

Variável de Saída: PINTOS APROVEITADOS

TREINAMENTO DA REDE NEURAL ARTIFICIAL

Tabela 1 – Características do modelo de rede neural para a predição da saída Pintos Aproveitados em 1999.

Estatísticas da predição	Valores
R ²	1,0
Erro médio	0,175084
Correlação	1,0
QME	2,300322
RQME	1,516681

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

Importância Relativa das Entradas:

Tabela 2 – Importância Relativa (contribuições) das Entradas.

Entrada	Importância Relativa
Quantidade de pintos nascidos	0,970
Quantidade de pintos refugados	0,030

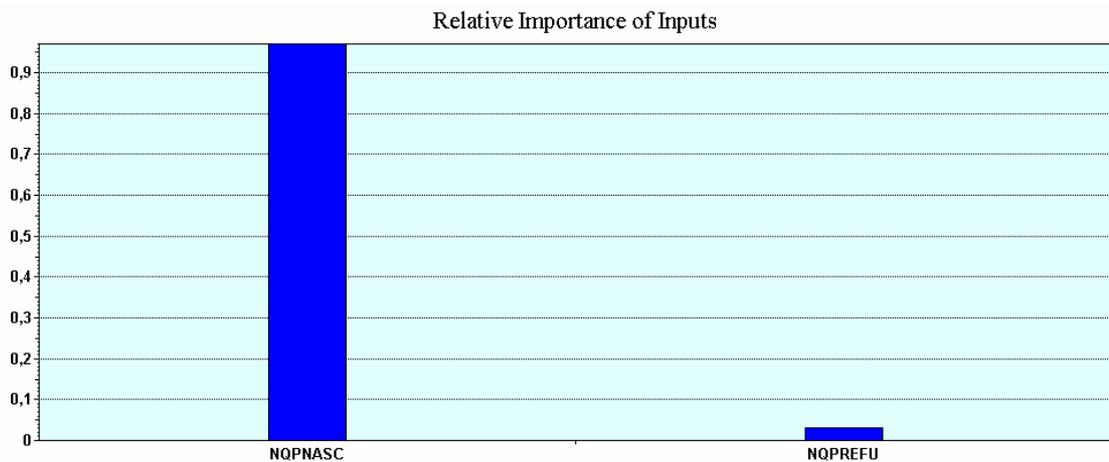


Figura 1 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Aproveitados em 1999.

TESTE E VALIDAÇÃO DA REDE NEURAL ARTIFICIAL
PREDIÇÕES DA REDE PARA OS 2.822 REGISTROS DE 1999.

Tabela 3 – Validação do modelo de redes neurais para a predição variável Pintos Aproveitados obtido pelos 2.822 registros de 1999.

Estatísticas da predição	Valores
R ²	1,0
Erro médio	0,106601
Correlação	1,0
QME	0,104346
RQME	0,323027

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

Tabela 4 – Resultados reais e as predições da variável Pintos Aproveitados para 57 registros de 1999.

Reg.	Real	Predição	Reg.	Real	Predição	Reg.	Real	Predição
3001	8900	8900,005	4000	3383	3382,999	5000	3067	3066,999
3002	9170	9170,005	4001	3383	3382,999	5001	3067	3066,999
3003	9170	9170,005	4002	2425	2424,998	5002	3067	3066,999
3004	7350	7350,002	4003	2425	2424,998	5003	6133	6133,002
3005	7350	7350,002	4004	7275	7275,002	5004	6133	6133,002
3006	1445	1444,997	4005	7275	7275,002	5005	6133	6133,002
3007	1445	1444,997	4006	3730	3729,999	5006	8050	8050,003
3008	2887	2886,998	4007	3730	3729,999	5007	8050	8050,003
3009	2887	2886,998	4008	5950	5950,001	5008	4500	4500
3010	2887	2886,998	4009	5950	5950,001	5009	4500	4500
3011	4425	4425	4010	2920	2919,998	5010	2853	2853,998
3012	4425	4425	4011	2920	2919,998	5011	2853	2853,998
3013	4633	4634	4012	6084	6084,002	5012	2853	2853,998
3014	4633	4634	4013	6083	6083,002	5013	5580	5580,001
3015	4633	4634	4014	6083	6083,002	5014	5580	5580,001
3016	1480	1479,997	4015	3000	2999,998	5015	5580	5580,001
3017	1480	1479,997	4016	3000	2999,998	5016	9000	9000,005
3018	5813	5814	4017	6100	6100,001	5017	9000	9000,005
3019	5813	5814	4018	6100	6100,001	5018	7550	7550

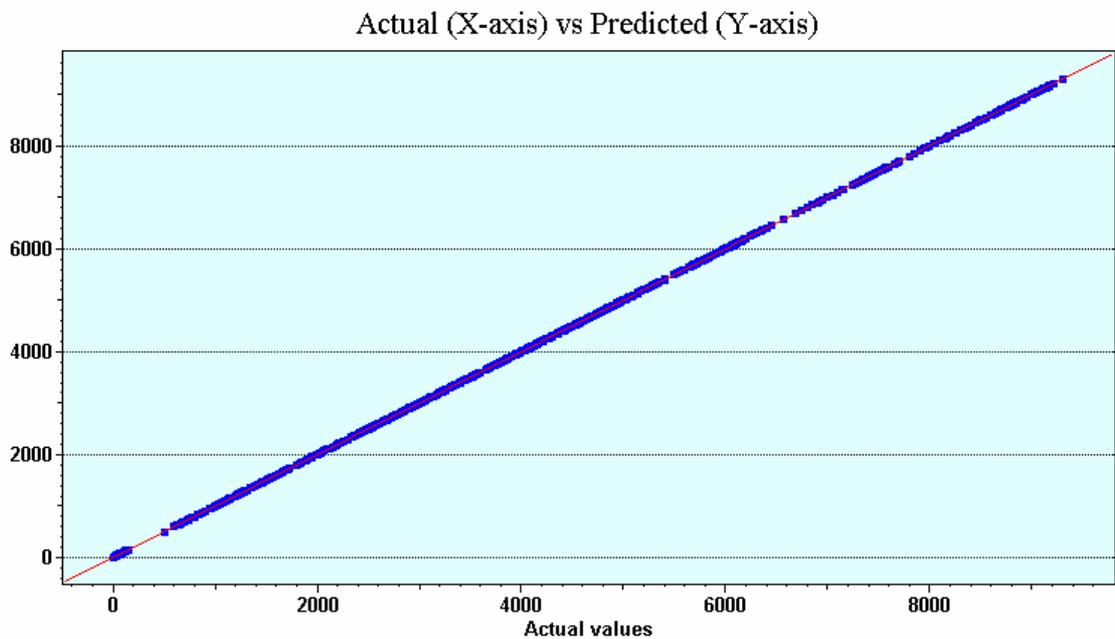


Figura 2 – Valores reais (X) versus valores preditos (Y) da variável Pintos Aproveitados para os 2.822 registros de 1999.

PREDIÇÕES DA REDE PARA OS 889 CRIADORES EM 2002

Tabela 5 – Validação do modelo de redes neurais para a predição variável Pintos Aproveitados obtido pelos 889 lotes alojados em 2002.

Estatísticas da predição	Valores
R ²	0,999812
Erro médio	50,63017
Correlação	0,999908
QME	7526,333
RQME	86,75444

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

Tabela 6 – Resultados reais e as predições da variável Pintos Aproveitados para 57 lotes criados em 2002.

Lote	Real	Predição	Lote	Real	Predição	Lote	Real	Predição
1	11019	11058,93	270	9105	9096,194	600	6216	6164,678
2	6118	6122,887	271	18347	18332,76	601	5715	5690,131
3	37990	38104,15	272	17838	17871,95	602	5760	5707,163
4	10090	10094,1	273	14508	14620,22	603	8576	8536,642
5	3290	3203,166	274	13860	13839,47	604	5924	5813,015
6	10752	10760,01	275	15126	15105,14	605	9624	9574,606
7	17208	17208,18	276	11907	11894,1	606	8000	7909,473
8	10000	10003,78	277	9936	9930,157	607	6030	5969,984
9	15972	15956,54	278	5931	5899,846	608	5904	5781,317
10	10654	10633,83	279	5464	5446,617	800	5796	5769,711
50	20664	20398,53	410	10719	10700,96	801	6066	6126,754
51	9504	9508,239	411	10976	10981,02	802	35996	35828,67
52	20721	20831,2	412	10318	10322,16	803	13100	13092,11
53	6210	6241,938	413	9555	9549,784	804	6249	6245,728
54	11808	11779,06	414	17586	17594,66	805	6114	6178,292
55	17879	17771,28	415	25246	25082,66	806	10054	10075,37
56	5948	6000,713	416	25808	25935,88	807	6321	6337,731
57	9456	9552,522	417	11745	11707,3	808	6375	6459,10
58	7761	7734,676	418	9288	9303,962	809	7320	7347,68

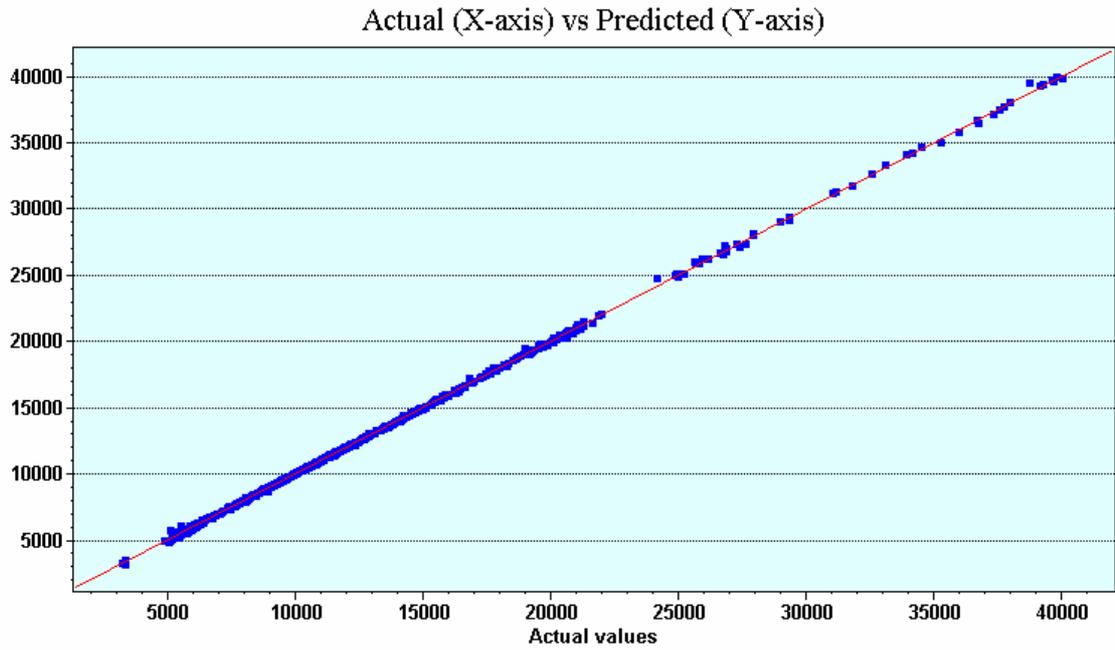


Figura 3 – Valores reais (X) *versus* valores preditos (Y) da variável Pintos Aproveitados para os 2.822 registros de 1999.

APÊNDICE B – Pintos nascidos em 1999

Nº. DE REGISTROS: 5.822

USADOS PARA TREINAR: 3.000

USADOS PARA TESTAR E VALIDAR: 2.822

Variável de Saída: PINTOS NASCIDOS

TREINAMENTO DA REDE NEURAL ARTIFICIAL

Tabela 1 – Características do modelo de rede neural para a predição da saída Pintos Nascidos em 1999.

Estatísticas da predição	Valores
R ²	1,0
Erro médio	0,175818
Correlação	1,0
QME	2,300315
RQME	1,516679

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

Importância Relativa das Entradas:

Tabela 2 – Importância Relativa (contribuições) das Entradas.

Entrada	Importância Relativa
Quantidade de pintos aproveitados	0,970
Quantidade de pintos refugados	0,030

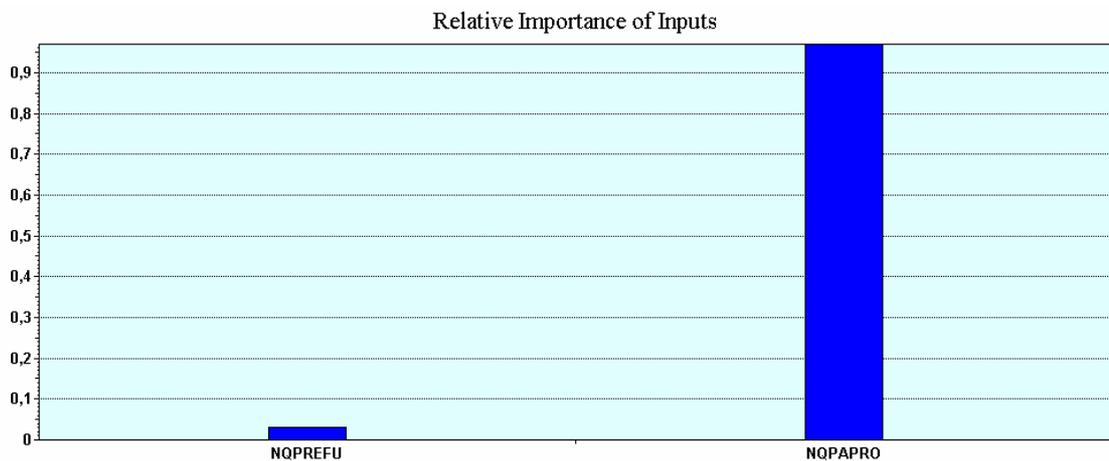


Figura 1 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Nascidos em 1999.

TESTE E VALIDAÇÃO DA REDE NEURAL ARTIFICIAL
 PREDIÇÕES DA REDE PARA OS 2.822 REGISTROS DE 1999.

Tabela 3 – Validação do modelo de redes neurais para a predição variável Pintos Nascidos obtido pelos 2.822 registros de 1999.

Estatísticas da predição	Valores
R ²	1,0
Erro médio	0,107416
Correlação	1,0
QME	0,104346
RQME	0,323114

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

Tabela 4 – Resultados reais e as predições da variável Pintos Nascidos para 57 registros de 1999.

Reg.	Real	Predição	Reg.	Real	Predição	Reg.	Real	Predição
3001	8972	8971,992	4000	3408	3408	5000	3084	3084
3002	9238	9237,991	4001	3408	3408	5001	3084	3084
3003	9238	9237,991	4002	2457	2457,002	5002	3084	3084
3004	7443	7442,995	4003	2457	2457,002	5003	6165	6164,996
3005	7443	7442,995	4004	7371	7370,996	5004	6165	6164,996
3006	1468	1468,003	4005	7371	7370,996	5005	6165	6164,996
3007	1468	1468,003	4006	3777	3777	5006	8156	8155,995
3008	2942	2942,002	4007	3777	3777	5007	8156	8155,995
3009	2942	2942,002	4008	6008	6007,997	5008	4530	4529,998
3010	2942	2942,002	4009	6008	6007,997	5009	4530	4529,998
3011	4499	4499	4010	2956	2956,001	5010	2887	2886,001
3012	4499	4499	4011	2956	2956,001	5011	2887	2886,001
3013	4683	4681,999	4012	6129	6128,996	5012	2887	2886,001
3014	4683	4681,999	4013	6128	6127,996	5013	5648	5647,998
3015	4683	4681,999	4014	6128	6127,996	5014	5648	5647,998
3016	1502	1502,003	4015	3046	3046,001	5015	5648	5647,998
3017	1502	1502,003	4016	3046	3046,001	5016	9059	9058,991
3018	5929	5927,999	4017	6174	6173,997	5017	9059	9058,991
3019	5929	5927,999	4018	6174	6173,997	5018	7761	7760,999

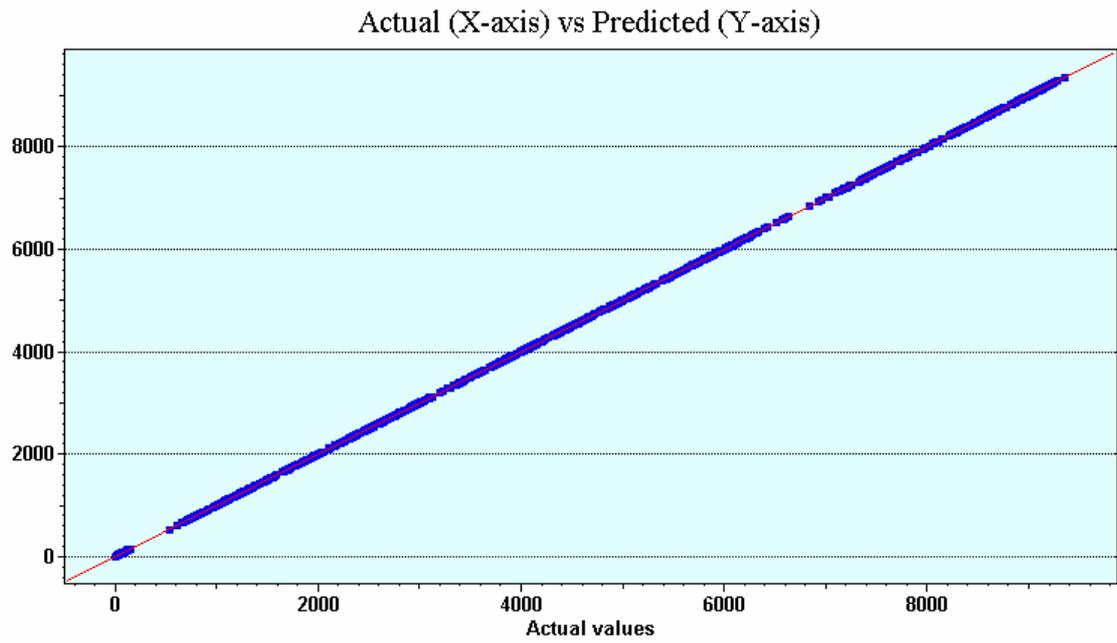


Figura 2 – Valores reais (X) *versus* valores preditos (Y) da variável Pintos Nascidos para os 2.822 registros de 1999.

APÊNDICE C – Pintos refugos em 1999

No. DE REGISTROS: 5.822

USADOS PARA TREINAR: 3.000

USADOS PARA TESTAR E VALIDAR: 2.822

Variável de Saída: PINTOS REFUGOS

TREINAMENTO DA REDE NEURAL ARTIFICIAL

Tabela 1 – Características do modelo de rede neural para a predição da saída Pintos Refugos em 1999.

Estatísticas da predição	Valores
R ²	0,999681
Erro médio	0,192968
Correlação	0,999841
QME	2,298822
RQME	1,516187

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

Importância Relativa das Entradas:

Tabela 2 – Importância Relativa (contribuições) das Entradas.

Entrada	Importância Relativa
Quantidade de pintos nascidos	0,505
Quantidade de pintos aproveitados	0,495

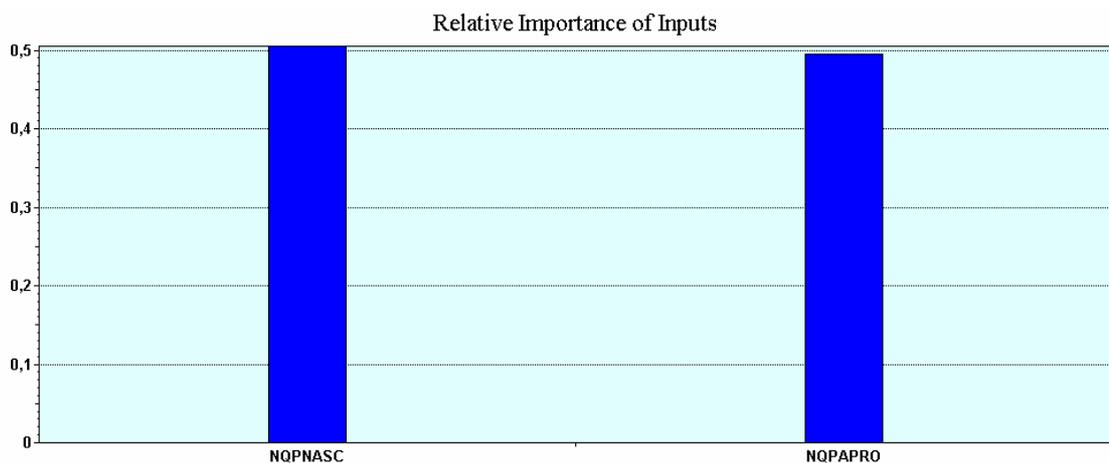


Figura 1 – Contribuições, ou importâncias relativas, de cada uma das variáveis de entrada para a saída Pintos Refugos em 1999.

TESTE E VALIDAÇÃO DA REDE NEURAL ARTIFICIAL PREDIÇÕES DA REDE PARA OS 2.822 REGISTROS DE 1999.

Validação do modelo de redes neurais para a predição variável Pintos Refugos obtido pelos 2.822 registros de 1999.

Tabela 3 –

Estatísticas da predição	Valores
R ²	0,999979
Erro médio	0,133228
Correlação	0,99999
QME	0,107193
RQME	0,327404

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

Tabela 4 – Resultados reais e as predições da variável Pintos Refugos para 57 registros de 1999.

Reg.	Real	Predição	Reg.	Real	Predição	Reg.	Real	Predição
3001	72	72,07942	4000	25	25,03101	5000	17	17,0315
3002	68	68,08566	4001	25	25,03101	5001	17	17,0315
3003	68	68,08566	4002	32	32,01329	5002	17	17,0315
3004	93	93,04482	4003	32	32,01329	5003	32	32,06524
3005	93	93,04482	4004	96	96,04192	5004	32	32,06524
3006	23	23,00509	4005	96	96,04192	5005	32	32,06524
3007	23	23,00509	4006	47	47,02236	5006	106	106,0466
3008	55	55,00564	4007	47	47,02236	5007	106	106,0466
3009	55	55,00564	4008	58	58,0467	5008	30	30,04359
3010	55	55,00564	4009	58	58,0467	5009	30	30,04359
3011	74	74,01551	4010	36	36,01777	5010	33	34,01806
3012	74	74,01551	4011	36	36,01777	5011	33	34,01806
3013	49	50,03316	4012	45	45,05656	5012	33	34,01806
3014	49	50,03316	4013	45	45,05655	5013	68	68,03538
3015	49	50,03316	4014	45	45,05655	5014	68	68,03538
3016	22	22,0062	4015	46	46,01275	5015	68	68,03538
3017	22	22,0062	4016	46	46,01275	5016	59	59,08881
3018	115	116,0092	4017	74	74,03897	5017	59	59,08881
3019	115	116,0092	4018	74	74,03897	5018	211	210,9751

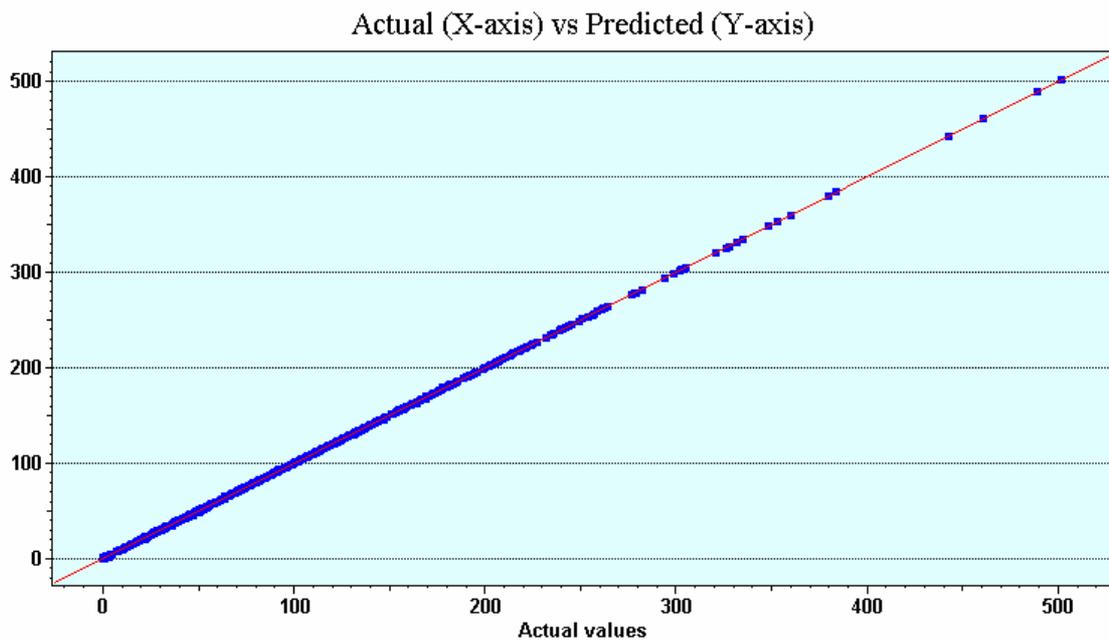


Figura 2 – Valores reais (X) *versus* valores preditos (Y) da variável Pintos Refugos para os 2.822 registros de 1999.