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

USO DE REDES NEURAIS ARTIFICIAIS NO GERENCIAMENTO DE MATADOUROS-FRIGORÍFICOS DE AVES E SUÍNOS NO SUL DO BRASIL.

Priscila Rech Pinto.

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.

00 0110110010111

Co-orientador: Adriano da Silva

Gua hyba.

#### P659u Pinto, Priscila Rech

Uso de redes neurais artificiais no gerenciamento de matadouros-frigoríficos de aves e suínos no sul do Brasil. / Priscila Rech Pinto. – Porto Alegre: UFRGS, 2006.

- 74 f.; il. Dissertação (Mestrado) Universidade Federal do Rio Grande do Sul, Faculdade de Veterinária, Programa de Pós-graduação em Ciências Veterinárias, Porto Alegre, RS-BR, 2006. Carlos Tadeu Pippi Salle, Orient.
- Redes neurais artificiais
   Avicultura
   Suinocultura
   Matadouros I. Salle, Carlos Tadeu Pippi, Orient. II. Guahyba, Adriano da Silva, Co-orient. III. Título.

CDD 619.602605

Catalogação na fonte: Biblioteca da Faculdade de Veterinária da UFRGS

## PRISCILA RECH PINTO

USO DE REDES NEURAIS ARTIFICIAIS NO GERENCIAMENTO DE MATADOUROS-FRIGORÍFICOS DE AVES E SUÍNOS NO SUL DO BRASIL. Aprovado em 21/12/2006.

Aprovado por:	
Prof. Dr.	<b>∴</b>
Carlos Tadeu Pippi Salle	
Orientador e Presidente da Comissão	
Prof. Dr.	_•
Hamilton Luiz de Souza Moraes	
Membro da Comissão	
Profa. Dra.	_•
Luciana Ruschell dos Santos	
Membro da Comissão	
Prof. Dr.	_•
Luiz César Bello Fallavena	
Membro da Comissão	

# **DEDICATÓRIA**

Dedico este
trabalho aos meus
pais, que me
ensinaram desde cedo
a lutar por tudo aquilo
que eu desejava.
Queridos pais, essa é
mais uma batalha
vencida.

#### **AGRADECIMENTOS**

Agradeço aos meus pais, Carmem e Máximo, que me apoiaram a iniciar o mestrado, mesmo diante de diversas dificuldades. Agradeço a meu noivo Ramon, minha irmã Patrícia, meu orientador, Dr. Carlos Tadeu Pippi Salle, meu co-orientador, Dr. Adriano da Silva Guahyba, ao professor Dr. Hamilton Luiz de Souza Moraes, Dra. Ana Cristina P. da Rocha, ao secretário do CDPA, Luis Henrique (Zico) e ao biólogo Silvio Rocha.

Aos estagiários do CDPA que me ajudaram na execução do projeto, Daniela Pinheiro, Débora Maciel Leal, Gabriella Bettiol, Vanessa Ferraro, Fabrício Imperatori, Rafael Peruzzollo, Tatiane Lima, Caroline Hiller, Thiago Kirst, Gabriel Lima, José Roberto Bastos, João Guahyba, e aos mestrandos e doutorandos do CDPA, Lucas Brunelli Moraes, Flávia B. B. Fortes, Felipe Salle, Guilherme Fonseca de Souza e Anderlise Borsoi. As amigas Michele Maroso e Cibele Araújo Torres pelas hospedagens que necessitei e pela amizade.

Aos meus sogros Anete Moser e Francisco Moser pelo apoio. As amigas Jane Costa e Mirele Lavagnoi pela ajuda nos momentos difíceis.

Obrigada a todos.

# SUMÁRIO

RESUMO	5
ABSTRACT	6
1. INTRODUÇÃO	7
2. REVISÃO BIBLIOGRÁFICA	10
2.1 Resfriamento de carcaças.	10
2.2 Modelos matemáticos e Inteligência Artificial	14
3. MATERIAL E MÉTODO	24
3.1 Dados de registro	24
3.2 Análise estatística dos dados:	26
3.3 Redes Neurais Artificiais:	26
4. RESULTADOS E DISCUSSÕES	29
4.1 Modelo de rede neural artificial para o estudo das causas de condenação	
parcial na inspeção final da empresa A.	30
4.2 Modelo de rede neural artificial para a variável de saída "Peso da Carca	ça na
Saída do Chiller" na Empresa B.	35
4.3 Modelo de redes neurais artificiais para a variável de saída "Teste De	
Absorção" em carcaças da empresa B.	40
4.4 Modelo de redes neurais artificiais para a variável de saída "Condenação	Por
Falha Operacional"	45
4.5 Modelo de redes neurais artificiais para a variável de saída "Quebra De	
Resfriamento" em carcaças suínas na empresa C.	49
4.6 Modelo de redes neurais artificiais para a variável de saída "Peso Vivo I	De
Suínos" na empresa C	54
4.7 Considerações finais:	58
5. CONCLUSÃO	60
REFERÊNCIAS BIBLIOGRÁFICAS	
APÊNDICE A- Modelo de redes neurais artificiais para a variável de saída	
"Condenação Total De Carcaça Na Inspeção Final" da empresa A	66
APÊNDICE B-Modelo de redes neurais artificiais para variável de saída	
"Condenação Total Na Pré - Inspeção" na Empresa A.	71

#### **RESUMO**

Este trabalho teve por objetivo utilizar redes neurais artificiais para explicar fenômenos que ocorrem em matadouros-frigoríficos avícolas. A estatística descritiva e a diferença entre as variáveis foram calculadas através do programa computacional SPSS for Windows 10.0 e para a construção das redes neurais artificiais foi utilizado o programa Neuroshell Predictor desenvolvido pela Ward Systems Group. Foram utilizados dados de 2004 a 2006 de dois matadouros-frigoríficos de aves e ocasionalmente um matadouro-frigorífico de suínos. Nos arquivos oferecidos pelas empresas, haviam dados de gerenciamento de matadouros-frigoríficos, como por exemplo, planilhas de condenação da inspeção, dados sobre chiller, teste de absorção das carcaças, dados sobre peso de carcaças, entre outros. Para a construção dos modelos foram escolhidas as "entradas", para o cálculo do modelo preditivo, e a variável de "saída" a ser predita. Foram gerados oito (8) modelos com diferentes bancos de dados. Todos esses modelos apresentaram redes neurais artificiais bem ajustadas, com valores altos para Correlação e Coeficiente de Determinação Múltipla (R2) e valores baixos para o Erro Médio e o Quadrado médio do Erro (QME). Não houve diferenças significativas entre os valores reais e os valores preditos em todas as validações dos oito (8) modelos. As redes neurais artificiais, com o software utilizado, foram capazes de explicar os fenômenos que envolvem o gerenciamento de matadouros-frigoríficos de aves, e ocasionalmente de suínos. A técnica utilizada oferece critérios objetivos, cientificamente desenvolvida, que será de grande valia no auxílio do técnico responsável pela tomada de decisões. A técnica permite também realizar simulações e mensurar a contribuição de diferentes variáveis que influenciam no fenômeno. É importante ressaltar que a utilização das redes neurais artificiais é uma ferramenta de auxílio à tomada de decisões, e não um programa que substitua o conhecimento científico e técnico.

#### **ABSTRACT**

This work aimed to use artificial neural networks to explain the occurred phenomena in the poultry slaughterhouse. The descriptive statistics and the difference among the variable averages from the initial data were calculated with SPSS software, and the software used to build the artificial neural networks was Neruoshell Predictor, developed by Ward Systems Group. Data from three poultry and one swine slaughterhouses, gathered from 2004 until 2006, were used in this study. In these data there were information about carcasses condemnation, chillers, absorption tests, carcasses weights, medications and others. To build the neural networks, the chosen variables were identified as "input" and "output". The "input" variables were selected for the predictive model calculation and the "output" variable for the one to be predicted. It was made 8 models with different databases. In all these models, the generated artifical neural networks were well adjusted always presenting a high Multiple Determinant Coefficient  $(R^2)$  and correlation and the lowest Mean Squared Error (QME) and mean error. Also the differences between the real value and the predicted value in the 8 models studied were not statistically significant. This study concludes that artifical neural network, with the used software, were capable to explain the phenomena involved in the poultry slaughterhouse and that the modeling can also be extended to swine slaughterhouse. This powerfull technique offers objective criteria, scientifically generated, which can be used to assist in the decisions analysis process for this industry. It also allows to make simulations and to measure the contribution of each variable in the phenomena studied. It's important to point out that artificial neural networks are intruments to assist the technician in decision making. Thus, it is not a program able to replace the cientific and technical knowledge.

# 1. INTRODUÇÃO

A avicultura na América do Sul e do Norte concentrou em 2005 o maior volume de carne de frango do planeta com 48% da produção e 79% das exportações mundiais. Os Estados Unidos são os maiores produtores do mundo, com produção de 16 milhões de toneladas, seguido do Brasil com 9 milhões. O Brasil, maior exportador mundial, e os Estados Unidos representam 76% dos embarques globais. Por ser grande produtor de grãos e pelos avanços tecnológicos alcançados, tanto na área genética como na industrial, o continente americano ganha importância cada vez maior, seja na produção de frangos, seja no consumo e nas exportações.

O desempenho do frango de corte, no ano de 2005, cresceu acima das previsões iniciais, com as empresas apresentando resultados positivos, mesmo considerando algumas dificuldades como a queda contínua das cotações do dólar, as preocupações com os focos de Influenza Aviária na Ásia, Europa e na Colômbia, e a greve dos Fiscais Federais Agropecuários ocorrida no mês de novembro no país.

Foram abatidos 4,4 bilhões de frangos, que resultaram em 9,3 milhões de toneladas de carne. Essa performance representou aumento de 9,5% na produção de carne de frango em comparação com o total alcançado em 2004. Do total produzido, 6,5 milhões de toneladas foram encaminhadas ao mercado interno. O consumo *per capita* nacional elevou-se para 35,47 kg. Para o mercado externo foram destinadas 2,7 milhões de toneladas. A receita cambial proveniente dos embarques, incluindo os produtos industrializados, atingiu US\$ 2,8 bilhões. O consumo *per capita* foi estimado considerando a população brasileira de 2005 projetada em 184 milhões de habitantes. Não estão computadas as exportações de industrializados de frango, só são consideradas as exportações de carne *in natura*.

As exportações brasileiras de carne de frango consolidaram em 2005, mais um ano de recordes históricos na posição de maior exportador mundial tanto em volumes embarcados quanto em receita cambial. Ao final de 2005 o Brasil chegou a um total de 142 mercados compradores, e uma participação de 41% no comércio internacional de carne de frango. O setor também consolidou a posição de segundo lugar no ranking das exportações do agronegócio nacional, superado apenas pelo complexo da soja.

Os principais mercados brasileiros em 2005 foram a União Européia, cujos embarques somaram 387 mil toneladas, o Oriente Médio, principal mercado das exportações brasileiras de carne de frango, na análise por volumes, a América do Sul

que obteve vendas totalizando 114.861 toneladas, a África, a Ásia, a Rússia e o Japão, que já era o maior mercado brasileiro em receita e se tornou o principal cliente também em volumes embarcados, ao importar 404.769 toneladas. O fato de um mercado exigente como o japonês ampliar de forma tão expressiva as compras de nosso produto, nos últimos anos, é um excelente atestado da qualidade e da sanidade da carne de frango brasileira.

Os focos de Influenza Aviária em outros países passaram a provocar, a partir do final de 2005, sinais de retração no consumo mundial. Um ritmo de oferta, por parte da avicultura brasileira, superior à demanda poderia ter um efeito negativo sobre os preços e comprometer a remuneração deste que é um dos mais importantes setores da economia nacional. Um dos desafios para a avicultura brasileira é a efetiva implantação do plano de prevenção contra a gripe aviária, elaborado pelo Ministério da Agricultura Pecuária e Abastecimento juntamente com as Secretarias da Agricultura dos Estados. Dessa forma, o Brasil manterá seu status de maior exportador mundial, mostrando a OIE (Organização Mundial de Saúde Animal), credibilidade de sua atuação e sanidade de seu plantel.

Em 2006, os números divulgados de janeiro a setembro pela ASGAV apresentaram queda de 17% no volume total de frangos produzidos, 15,5% na exportação e 14,6% no alojamento de pintos de corte.

A gripe aviária em outros países foi um dos principais abalos que a avicultura gaúcha enfrentou. O volume de frango inteiro, cortes e industrializado enviado para outros países entre janeiro e setembro deste ano foi de 492 mil toneladas contra 583 mil toneladas enviadas no ano passado.

Com a queda do consumo externo, o planejamento comercial foi desestruturado. O caso isolado de Doença de Newcastle registrado no Vale Real-RS, em julho de 2006, trouxe alguns prejuízos para o RS. Alguns estados brasileiros adotaram barreiras sanitárias e alguns países restringiram parcialmente os produtos avícolas.

O Rio Grande do Sul ocupa a terceira posição entre os estados produtores e exporta cerca de 600 mil toneladas. O Estado possui 14 frigoríficos com Inspeção Federal e 6 com Inspeção Estadual. A magnífica 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, ou seja, além de um setor economicamente

rentável, ainda possui o fator social, onde viabiliza o produtor rural e mantém tradições de povos culturalmente agrários. A avicultura viabiliza o minifúndio evitando o êxodo rural e conseqüentemente os cinturões de miséria e criminalidade urbana.

O Centro de Diagnóstico e Pesquisa em Patologia Aviária (CDPA), da Faculdade de Medicina Veterinária da Universidade Federal do Rio Grande do Sul (UFRGS) alavancaram no Brasil projetos de pesquisas, sob a forma de teses de doutorado e de dissertações de mestrado, que utilizaram inteligência artificial, especificamente redes neurais artificiais (RNAs), para o gerenciamento da produção de reprodutoras pesadas, da produção de frangos de corte e de incubatório com excelentes resultados. Para completar a cadeia avícola e devido à atual importância de combate a fraude com adição de água no frango nos matadouros-frigoríficos e da preocupação dos consumidores perante este problema, decidiu-se estudar dentro de um matadouro-frigorífico o uso de inteligência artificial para explicar além de fenômenos de resfriamento de carcaças e teste de absorção de água, outros fatores que influenciam a qualidade da carne e ainda ferramentas de gerenciamento da produção.

O presente trabalho tem como objetivo demonstrar que a utilização de inteligência artificial é capaz de explicar fenômenos em um matadouro-frigorífico. Essa nova ferramenta utilizada para tomada de decisões tem demonstrado sucesso em todos os segmentos. Para completar a cadeia avícola, faltaria concluir um segmento da avicultura, o matadouro-frigorífico.

## 2. REVISÃO BIBLIOGRÁFICA

#### 2.1 Resfriamento de carcaças.

O processo de um matadouro-frigorífico pode ser dividido nas seguintes etapas: recepção, atordoamento, sangria, escaldagem, depenagem, escaldagem dos pés e das cutículas, evisceração, lavagem final, resfriamento, gotejamento, embalagem, armazenamento e aproveitamento dos subprodutos (Bassoi, 1994).

O processo de resfriamento das carcaças é complexo em sua modelagem fenomenológica, devido ao grande número de fatores que interferem no processo. Os modelos gerados são de difícil solução exata, dificultando qualquer tentativa de simulação. As previsões que se consegue obter são aproximadas e muitas vezes baseadas em ajustes por correlação com dados empíricos (Klassen, 2004).

Há vários métodos de resfriamento das aves (Beraquet, 1994). O resfriamento de carcaças pode ser realizado a seco, por resfriamento em câmaras frigoríficas, por refrigeração com dióxido de carbono, por imersão contínua em água gelada, por aspersão com água gelada ou pela associação dos métodos (Klassen, 2004; Ministério da Agricultura e do Abastecimento, 1998).

O processo a seco consiste em refrigerar a carcaça com o ar, em uma câmara frigorífica, onde há um menor risco higiênico, principalmente se a potência frigorífica é suficiente e se as câmaras estão bem limpas. Este processo se aplica para carcaças que se comercializam a uma temperatura ao redor de 0°C (Bremner, 1981).

A refrigeração com dióxido de carbono é empregada no comércio da carne resfriada. Éa neve carbônica que produz o congelamento superficial da carcaça. O perigo deste método é que possa alcançar um nível perigoso de dióxido de carbono e possa afetar os trabalhadores caso a zona não esteja bem ventilada (Bremner, 1981).

O processo mais comum no Brasil é a imersão das carcaças em tanques longos com uma mistura de água e gelo fundente, ou reversão com camisa que permita a passagem de um líquido refrigerante, como o etileno-glicol (Beraquet, 1994). Esses tanques são chamados de *chillers*.

Em alguns experimentos foram comprovados que o processo de refrigeração por imersão contínua em água tem riscos consideráveis, inclusive alguns países decidiram proibir o uso deste método. A refrigeração por imersão em água tem sido objeto de muitos estudos científicos e em alguns países, principalmente nos Estados Unidos, se permite seu emprego somente com um estrito controle (Bremner, 1981).

Quando o conjunto de operações do frigorífico é realizado de forma higiênica como um todo, de forma que as carcaças já entrem nos *chillers* adequadamente limpas, foi comprovado que este sistema é considerado higiênico e que as carcaças saem dos *chillers* tão limpas quanto entraram. O sistema de imersão em *chillers* tem a vantagem de que a água resfria as carcaças mais rapidamente que qualquer outro método, utilizando um menor espaço físico. Na opinião de alguns especialistas é necessário adicionar cloro para melhorar a higiene do sistema, chegando até a 50 partes por milhão de cloro residual. Outros cientistas consideram que se o sistema é utilizado adequadamente não se justifica a adição de cloro (Bremner, 1981).

As carcaças absorvem água ao passar pelos tanques resfriadores, e isto deve ser controlado rigorosamente. Em alguns países em que se permite esse sistema de refrigeração, se considera aceitável uma captação próxima de 8% nas carcaças de aves, entre a evisceração e o congelamento, em outros países se limita ao nível de 5%. A Comunidade Européia adotou o nível máximo de 7,4% para a quantidade total de água nos frangos, galinhas e capões congelados (Bremner, 1981).

No Brasil, o Ministério da Agricultura Pecuária e do Abastecimento (MAPA) realiza através do Serviço de Inspeção Federal (SIF) o controle de absorção e temperatura de carcaça nos matadouros-frigoríficos. A Portaria 210, de 10 de novembro de 1998 prevê que a água no sistema de pré-resfriamento (*pré-chiller*) não deve ser superior a 4°C e deve estar com constante renovação, podendo a mesma ser hiperclorada, permitindo-se no máximo cinco (5) ppm de cloro. A temperatura da água residente, medida nos pontos de entrada e saída das carcaças do sistema de pré-resfriamento por imersão não deve ser superior a 16°C e 4°C, respectivamente, no primeiro e último estágio, observando-se o tempo máximo de permanência no primeiro *chiller* de trinta minutos (Ministério da Agricultura e do Abastecimento, 1998).

Considerando-se o que estabelece o Artigo nº 895 do Regulamento da Inspeção Industrial e Sanitária dos Produtos de Origem Animal (RIISPOA), aprovado pelo Decreto nº 30.691 de 29/03/1952 e suas alterações subseqüentes, e com o objetivo de prestar esclarecimentos aos consumidores, baseado na transparência das ações realizadas pelo MAPA, o Departamento de Inspeção de Produtos de Origem Animal (DIPOA) tem divulgado a relação das empresas que infringiram a legislação no que se refere à quantidade de água absorvida no produto frango congelado *in natura*. O Programa de Combate à Fraude por Adição de Água em Carcaças de Aves, cujo objetivo é coibir a prática de fraude econômica que ocorre durante o processo de resfriamento das carcaças de aves por ocasião do abate, iniciou-se em 2000, seguindo os parâmetros definidos na Portaria nº 210, de 10 de novembro de 1998, que aprovou o Regulamento Técnico de Inspeção Tecnológica e Higiênico-Sanitária de Carnes de Aves.

O programa estabelece a metodologia de análise (*Drip Test*) em que se determina o limite máximo de 6% de água resultante do desconge lamento da carcaça congelada. O DIPOA informa sobre os produtos que estão sendo oferecidos ao consumo, bem como sobre as empresas que foram autuadas e multadas por excesso de água em carcaças de aves, através da divulgação das mesmas nos veículos de comunicação e de forma permanente no *site* do MAPA.

Em casos de constatação de índices de absorção de água acima do permitido pela legislação (6%), aplica-se imediatamente as sanções administrativas estabelecidas na Resolução nº 4, de 29 de outubro de 2002, que determina:

I - até o resultado de 7% (sete por cento) no Teste do Gotejamento, levando-se em consideração as variáveis que interferem no processo de amostragem, fica estabelecida a recessidade de nova colheita de amostras, antes de serem definidos os procedimentos administrativos fiscais.

II - as carcaças de aves congeladas apreendidas em decorrência da violação do Teste de Gotejamento deverão ser devolvidas ao estabelecimento de origem ou outro do mesmo grupo industrial e destinada ao processamento (cortes, recortes, industrialização ou outros) a critério do DIPOA;

III - no primeiro resultado laboratorial de análise fora dos padrões, a firma infratora é autuada e advertida;

IV - no ægundo resultado laboratorial de análise fora dos padrões, a firma infratora é autuada e multada em até R\$ 25.000,00 (vinte e cinco mil reais);

V - no terceiro resultado laboratorial de análise fora dos padrões, a firma infratora é autuada e multada, dobrando o valor da multa em até R\$ 25.000,00 (vinte e cinco mil reais);

VI - no quarto resultado laboratorial de análise fora dos padrões, a firma infratora é autuada e multada, dobrando o valor da multa em até R\$ 25.000,00 (vinte e cinco mil reais) e sendo necessário, para a comercialização das produções posteriores, a apresentação de resultados oficiais de testes de gotejamento de quatro lotes (definido por turno de abate) consecutivos;

VII - nos próximos resultados laboratoriais de análise fora dos padrões, a firma infratora é autuada e multada, dobrando o valor da multa em até R\$ 25.000,00 (vinte e cinco mil reais) e sendo necessário, para a comercialização das produções posteriores, a apresentação de resultados oficiais de testes de gotejamento de tantos lotes consecutivos quanto for o número de violações.

Após aplicação das penalidades, os processos administrativos finalizados são encaminhados à Procuradoria da República e Ministério da Justiça para instauração de procedimentos civis cabíveis.

Outra legislação utilizada é a Instrução Normativa nº 26 de 23 de abril de 2003 que estabelece que os produtos apreendidos devam ser doados, após serem considerados aptos para o consumo humano, preferencialmente ao Ministério e Estado Extraordinário de Segurança Alimentar e Combate a Fome – MESA.

O processo de resfriamento das carcaças é necessário pela presença de bactérias mesófilas nas carcaças. Poucas delas podem multiplicar-se a uma temperatura de 7°C. Algumas bactérias mesófilas produzem enfermidades ao homem e por isso é de tamanha importância um processo de resfriamento rápido e efetivo de carcaças, inibindo assim o crescimento microbiano (Bremner, 1981).

O Ministério da Agricultura admite no final do processo de pré-resfriamento, uma temperatura de carcaça igual ou inferior a 7°C, para as carcaças de congelamento imediato.

### 2.2 Modelos Matemáticos e Inteligência Artificial

É uma característica do Homem valer-se cada vez mais de sua supremacia sobre os demais representantes do reino animal. Isto se reflete, e sempre esteve presente na História, na feitura de ferramentas, equipamentos, maquinários e quaisquer outros elementos artificiais por ele criado, para contribuir com aquilo que ele sempre entendeu como melhoria de vida. Nada mais lógico, portanto, que nesta última metade de século, o Homem tenha encetado esforços imensos, e quase todos recompensados, na tentativa de construir equipamentos para ajudá-lo na resolução de problemas que o afligem, problemas estes que necessitam de uma inteligência aplicada para a sua resolução.

Na avicultura, os sistemas de integração são caracterizados pela subdivisão dos setores de produção como matrizes, incubatório, recria ou engorda e matadouro-frigorífico. Essa subdivisão favorece a identificação e controle de pontos críticos do processo de produção. Devido à complexidade e interação entre os diversos fatores que influem no processo produtivo, é praticamente impossível à mente humana predizer com certeza as conseqüências de uma implantação ou mudança de estratégia de manejo, nutrição, seleção, sanidade, entre outras, para o processo de produção. Para ajudar a tomada de decisão por parte do corpo técnico, uma alternativa, tanto na indústria como na pesquisa, é o uso de modelagem computacional (Rondón, 2002).

Em 1983, Freitas estimou peso de frangos de corte em fêmeas e machos utilizando modelos matemáticos. Os resultados obtidos poderiam ser utilizados pelos criadores para visualizar o crescimento corporal com a idade do animal, verificar a proporção de crescimento entre sexos, estimar conversão alimentar diária e padronizar crescimentos para a seleção de novas linhagens.

Em 1986, Curnow desenvolveu um dos primeiros modelos matemáticos de predição na Universidade de Reading. O Modelo de Reading determina os requerimentos em aminoácidos para maximizar os lucros. O modelo baseia-se na

relação do custo dos aminoácidos com o valor do produto e o desvio padrão dos parâmetros resposta dos frangos.

Em 1996, Lokhorst utilizou um modelo para avaliar a produção diária de ovos, o peso do ovo, os ovos classificados como de segunda, ovos de cama, mortalidade acumulativa, peso corporal e uniformidade do lote de galinhas, através de variáveis de entrada como consumo diário de alimento, o consumo de água e a temperatura ambiente. Esse conjunto de variáveis permitiu determinar, com base nas mudanças diárias durante o ciclo de produção, quando um lote apresentava um problema produtivo significativo. As simulações e posterior avaliação deste modelo permitiram determinar a importância produtiva de reduzir a variação diária de temperatura.

Em 1997, Kirby *et al.*, compararam modelos obtidos de regressão logística e modelos obtidos de regressão linear para predizer 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.

As técnicas utilizando modelos matemáticos também foram aplicadas para se avaliar estratégias de melhoramento genético. O trabalho de acompanhamento de populações por várias gerações, que poderia durar vários anos e ter altos custos, pode ser simulado em poucos minutos (Muir, 1997)

Em trabalhos realizados em 1995 por Soares, Salle (1998ª) e por Salle (1999c) realizou-se modelos matemáticos para uma interpretação objetiva dos resultados sorológicos da resposta imune em reprodutoras de perus vacinadas contra a Doença de Newcastle. Com as equações obtidas foi possível interpretar resultados sorológicos de resposta imune contra o vírus vacinal da Doença de Newcastle de forma objetiva e com confiabilidade estatística, possibilitando o estabelecimento de modelos preditivos.

Salle *et al.*(1998<sup>a</sup>); Salle *et al.*(1998c) e Salle *et al.*(1999b) traçaram modelos matemáticos que ajustavam a curva de anticorpos produzidos pela vacinação contra Doença de Newcastle, Doença de Gumboro , Bronquite Infecciosa *versus* a idade das aves.

Em 1998 foi desenvolvido por Salle *et al.*(1998b) e Salle *et al.*(1999a) um método para detectar aflatoxina e ocratoxina em vísceras, para avaliar a produção de micotoxinas durante o armazenamento do alimento nas granjas e para obter o reflexo dos níveis de aflatoxina e ocratoxina encontrados na ração e víscera de frango de corte sobre os parâmetros produtivos do lote. 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 refugo, que haviam sido alimentadas com a dieta analisada. A detecção das toxinas foi realizada 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.

Outro programa com um alto nível de precisão foi testado em larga escala com dados da indústria. O modelo foi calibrado com as curvas de crescimento das diferentes linhagens genéticas disponíveis comercialmente, curvas de crescimento observadas previamente na granja, sexo da ave, peso vivo, conversão alimentar, idade ao abate, temperatura ambiente e programa alimentar (níveis nutricionais e idade de troca de alimentos). A calibração é fundamental para que o programa ajuste suas curvas de crescimento de acordo com as condições particulares de cada complexo de produção. Sem esse ajuste, bons níveis de precisão não poderiam ser obtidos nos passos seguintes de simulação e otimização. Após a calibração, o programa simula o crescimento diário dos animais e calcula as exigências nutricionais de energia, proteína e aminoácidos e consumo de ração. Baseado nisso, esse programa calcula os custos de produção e gráficos ajudam a visualizar tempos ótimos para o abate e os benefícios econômicos de cada dieta. O programa pode predizer a distribuição das partes da carcaça e formula as rações a fornecer de acordo com o tipo de otimização que seja escolhida: otimização por metro quadrado, por ave ou quilograma de peso vivo alojado, ou por quilograma por dia do ciclo (Ivey, 1999).

Em 1999, Ivey 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.

Foi estimado por Pesquisadores da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) em Concórdia-SC, pesos 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. Os autores concluíram que o modelo proposto pode ser utilizado em situações práticas por profissionais, tanto na pesquisa científica quanto na produção (Fialho *et al.*, 2000ª; . Fialho *et al.*, 2000b).

Em 2001, King estimou os efeitos das mudanças dos níveis de aminoácidos da dieta na composição da carcaça e no crescimento. Outro software desenvolvido determinou a ótima concentração de nutrientes num programa de alimentação de frangos de corte. O programa incluiu um programa de formulação a mínimo custo, um modelo dinâmico de crescimento de frangos e um processo de otimização. As três partes do programa interagiam para gerar o programa alimentar que maximiza os benefícios econômicos de acordo com os objetivos de produção.

Na Universidade de Hebrew, foi desenvolvido um modelo baseado nas determinações de exigências de aminoácidos e energia para crescimento e manutenção diária dos frangos. O custo dos alimentos foi estimado dos ganhos diários e utilizado para obter o menor custo no crescimento (Rondón, 2002).

Robey *et al.*(2006) 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.

Apesar dos modelos de determinação de exigências nutricionais terem alcançado um alto grau de refinamento, ainda são pouco empregados pela indústria avícola. Os modelos também podem descrever os sistemas industriais de

processamento de alimentos para as aves, sistemas de abate, sistemas de manejo de excretas e de ambiente, e muitos outros aspectos (Rondón E.O., 2002).

Salle & Silva (2000) colocaram a necessidade de critérios objetivos de tomada de decisões e interpretação dos resultados de monitorações, sem os quais o processo decisório e as medidas corretivas associadas a decisão tomada, ficam seriamente comprometidas. A estatística convencional tem sido amplamente utilizada, mas foram desenvolvidas novas tecnologias que poderiam servir como ferramenta para tomadas de decisões, entre elas, as redes neurais artificiais.

Já em 1958, Rosenblatt, descreveu o *perceptron* que é, na verdade, um modelo computacional inspirado no neurônio humano e precursor das redes neurais artificiais (RNAs). As RNAs, terminologia genérica que abrange um grande número de arquiteturas e paradigmas, têm como objetivo compreender o funcionamento do cérebro humano e, de alguma forma, procurar reproduzi-lo. Elas são compostas de um grande número de elementos de processamento, denominados neurônios (Dougherty, 1995).

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. As RNAs "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 ocultos quantos forem necessários para a maior precisão da resposta (Astion & Wilding, 1992; Roush; *et al*, 1996; Xin, 1999).

Os "neurônios" da rede podem receber importância relativa das entradas excitatórias ou inibitórias de outros neurônios e produzem uma saída, que geralmente é uma função não linear da entrada da rede (Astion & Wilding, 1992). Em contraste com muitos sistemas, as redes neurais artificiais não dependem de algoritmos prédefinidos (Lee *et al.*, 1999).

A rede neural se baseia nos dados disponíveis para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitar modelos falsos. Todo o conhecimento de uma rede neural está armazenado nas

sinapses, ou seja, nos pesos atribuídos às conexões entre os "neurônios". De 50 a 90% do total de dados deve ser separado para o treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras e não "decore" exemplos. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados (Tatibana & Kaetsu, 2006).

As principais vantagens das análises com as redes neurais são que os cálculos são realizados por "neurônios" individuais, permitem a execução de análises mais complexas do que as executadas por técnicas de estatística convencional, utilizam dados qualitativos e quantitativos no mesmo modelo, não requerem a transformação de dados (muitas vezes necessário para a estatística convencional) e realizam análises de dados não lineares e multivariados (comuns em biologia). As principais desvantagens das redes neurais incluem a não existência de regras que expressem o conhecimento aprendido ou uma equação e a necessidade de um número maior número de dados que a estatística convencional.

As aplicações das RNAs são inúmeras. Já são utilizadas com o objetivo de fazer prognóstico de mercados financeiros; reconhecer e gerar fala; localizar pontos de origem no radar, otimizar processos químicos; reconhecer alvos e detectar minas bélicas; identificar células cancerosas; reconhecer anormalidades cromossômicas; detectar fibrilação ventricular; predizer trajetórias de entrada de naves espaciais; reconhecer automaticamente caracteres escritos à mão entre outros. Grupos de investimento também utilizam este tipo de rede para analisar pelo menos uma parte do mercado financeiro e fazerem suas seleções entre outras (Cheng & Titterington, 1994). Conseguiu-se, inclusive, a elaboração de um programa de computador que veio a derrotar um mestre mundial de xadrez no jogo de sua especialidade. Os cálculos e planejamentos para as viagens espaciais, e em várias outras áreas da atuação humana, já não são mais feitos pela inteligência humana, mas sim pela Inteligência Artificial dos computadores (Lemos et al, 2006).

O progresso tecnológico neste campo tem sido de tal monta, principalmente no decorrer das duas últimas décadas, que defensores ferrenhos da falta de limite no crescimento da Inteligência Artificial já afirmam que o computador pode vir a ter emoções, e não apenas igualar-se ao Homem, mas superá-lo em grande parte de suas características. Estas considerações já foram descritas, e são defendidas por cientistas como Herbert Simon e Marvin Minski. Por outro lado, estudiosos defensores da

impossibilidade desta proposta, de igualação do ser humano pela máquina, ou mesmo de sua superação, apresentam razões, nas quais se amparam, para julgar tal fato como impossível, mesmo em um futuro longínquo (Lemos et al, 2006).

As RNAs têm apresentado um melhor desempenho comparado aos métodos estatísticos convencionais utilizados para o mesmo fim, dependendo do tipo de problema ao qual são submetidas (Bocanegra, 2002).

As rede neurais artificiais (RNAs) são freqüentemente utilizadas em medicina humana. O diagnóstico do câncer de mama utiliza as redes neurais artificiais como uma poderosa aliada analisando imagens para estabelecer um prognóstico (Dawson *et al.* 1991). O câncer de próstata pode ter um diagnóstico precoce utilizando esta tecnologia (Loch, 2000; Han, 2001; Ziada, 2001). As RNAs 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, 2002). As redes neurais também foram usadas para relacionar marcadores fenotípicos específicos com genes e estado fisiológico em pacientes com este tipo de doença (Bicciato, 2003).

Em 2002, Baxt *et al.* descreveu o uso de redes neurais artificiais nas emergências hospitalares. Os pacientes com dores peitorais receberam o diagnóstico de isquemia cardíaca mais sensível e específico, quando ele foi realizado com base nas RNAs. De forma similar, os eletrocardiogramas intra-cardíacos foram mais precisos quando esta moderna tecnologia foi empregada (Chetam *et al.* 2002).

As redes neurais artificiais foram utilizadas em pacientes com cardiopatia que foram submetidos à cirurgia. Os pacientes 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, 2001).

As RNAs já foram utilizadas em outras áreas, incluindo as áreas agrícolas, classificando frutos por meio de vetores de padrões. Foi utilizada uma rede *percepton* de múltiplas camadas, com algoritmos de treinamento tipo retro-propagação para armazenar os vetores de padrões de frutos e para classificação desses padrões de entrada. A rede treinada conseguiu aprender a relação entre vetores de entrada e saída,

demonstrando a potencialidade do uso de tais ferramentas na classificação artificial (Ramos, 2003).

O uso em medicina veterinária ainda é recente, sendo que a avicultura está sendo a área mais contemplada com a sua utilização.

Roush *et al.* 1996 e Roush *et al.* 1997 utilizaram redes neurais artificiais para predizer a ocorrência 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 O<sub>2</sub> 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 serão úteis na escolha e no desenvolvimento de linhagens de frangos de corte que não tenham propensão à ascite.

Nos Estados Unidos da América, Park (1998, 2001) e Chao *et al.* (2002) 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%.

Roush & Wideman (2000) e Roush et al. (2001) avaliaram a relação de ganho de peso com propensão a hipertensão pulmonar em frango de corte nos primeiros 14 dias de vida com a utilização das RNAs.

Salle et al. 2001,2003) utilizaram RNAs para predição de parâmetros de desempenho em aves em recria. Foram utilizados os registros de 11 lotes em recria, do período compreendido entre 09/11/97 a 10/01/99 e de 21 lotes em produção, do período compreendido entre 26/04/98 a 19/12/99, para a análise por redes neurais artificiais. Os dados utilizados corresponderam a 273 linhas de registros semanais, do período de recria e 689 linhas de registros semanais, do período de produção. Os modelos de redes neurais foram comparados e selecionados como melhores, baseados no Coeficiente de Determinação Múltipla (R), Quadrado Médio do Erro (QME), bem como pela análise de gráficos. O método utilizado permitiu simulações das conseqüências de tais decisões e forneceu a porcentagem de contribuição de cada variável no fenômeno estudado.

Em 2003, Dey *et al.* utilizaram RNAs na inspeção de frangos de cortes, diferenciando frangos normais daqueles com septicemia e toxemia. A classificação apresentou uma precisão de 96%. 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%.

Em 2004, Reali, utilizou RNAs para gerenciamento de frangos de corte, mostrando-se eficaz como ferramenta para gerenciamento desse segmento da avicultura. Foi utilizada uma série histórica de dados de produção de frangos de corte, obtidos nos anos de 2001 e 2002, fornecidos por uma Integração Avícola do Rio Grande do Sul, contendo informações de 1.516 criadores com lotes alojados em 2001 e 889 criadores com lotes alojados em 2002. Nos arquivos estavam registrados, para cada lote, suas variáveis de produção, tais como número do lote, data do alojamento, data do abate, idade ao abate, número de pintos alojados, quilogramas de ração consumidos, quilogramas de frangos produzidos, número de aves abatidas, custo do frango produzido, mortalidade, peso médio, ganho de peso diário, índice de conversão alimentar, índice de eficiência, quilogramas 1íquido de frangos, quilogramas de ração inicial, quilogramas de ração crescimento, quilogramas de ração abate, além de outros. A técnica ofereceu critérios objetivos, que serviram de embasamento para as decisões dos responsáveis pela produção industrial de frangos de corte da empresa.

Em 2004, Salle defendeu uma dissertação de mestrado, em que se utilizou RNAs no gerenciamento de um incubatório. 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. Os fenômenos próprios do incubatório puderam ser explicados através das RNAs. A técnica mostrou-se eficiente para realizar simulações, predições 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.

Klassen, 2004 realizou um trabalho de especialização utilizando RNAs para obter um modelo que descrevesse o funcionamento do sistema de resfriamento das carcaças por imersão e água gelada. Ele utilizou 300 linhas para treinamento e 100 para a validação do modelo. Os resultados obtidos mostraram que a rede com 8

neurônios na camada de entrada e 24 na camada intermediária foi a que melhor representou o sistema investigado.

Em 2006, Rocha defendeu uma tese utilizando inteligência artificial para classificação de amostras patogênicas de *E. coli*. Na tese são apresentadas três redes neurais artificiais que foram desenvolvidas através da análise dos genes *papC*, 10 *felA*, *cvaC*, *iutA*, *iss*, *tsh e kpsII*, da motilidade e do índice de patogenicidade (IP) para realizarmos a predição ou classificação de patogenicidade de cepas de *E. coli* sem a necessidade da utilização de animais. Na Rede 1, utilizaram 11 categorias de IP obtivemos 54,27% de acerto. No intuito de melhorar o desempenho do modelo foi criada uma segunda rede, utilizando 3 categorias de IP obtendo-se a classificação correta em 80,55%. Na tentativa de melhorar ainda mais seu desempenho, passaram a trabalhar com apenas duas categorias construindo, desta forma, a Rede 3. Com esta nova configuração a classificação correta do IP foi de 83,96%.

## 3.MATERIAL E MÉTODO

#### 3.1 Dados de registro

O estudo correspondeu a dados de registros já existentes do sistema de inspeção oficial e de controle de qualidade de três matadouros-frigoríficos do sul do Brasil. Através de dados já registrados, foram escolhidas as variáveis de entradas e as variáveis de saída de cada modelo.

O sistema de inspeção oficial da empresa A forneceu dados diários do período de janeiro a março de 2005, totalizando 2910 lotes que foram abatidos em planilhas de papel do próprio serviço de inspeção oficial. Os dados fornecidos foram:

- Data abate
- Turno
- Lote
- Número da GTA
- Número de aves abatidas
- Mortalidade no caminhão
- Enfermidades do lote
- Medicamentos utilizados no lote
- Mortalidade do lote (em porcentagem)
- Planilha de condenação na pré-inspeção (total)
- Planilha de Condenação total (inspeção final)
- Planilha de Condenação parcial na inspeção final
- Contusão da asa
- Distância de ida e volta da propriedade
- Peso médio frango vivo
- Contaminação biliar
- Contaminação fecal
- Temperatura da entrada do *pré-chiller* 1
- Temperatura da entrada do *pré-chiller* 2
- Temperatura da saída do *pré chiller* 1

- Temperatura da saída do pré *chiller* 2
- Temperatura da entrada do *chiller* 1
- Temperatura da entrada do*chiller* 2
- Temperatura da saída do *chiller* 1
- Temperatura da saída do *chiller* 2
- Tempo de permanência no pré-*chiller* 1
- Tempo de permanência no pré-chiller 2
- Teste de Absorção
- Temperatura da carcaça no chiller 1
- Temperatura da carcaça no *chiller* 2
- Rede clorada
- Rede hiperclorada

A empresa B forneceu dados de controle de qualidade e inspeção oficial do matadouro-frigorífico. Os dados fornecidos foram do período de janeiro a agosto de 2006.

- Controle de absorção de carcaças e temperatura de *chillers*.
- Planilha de Condenação Total na pré-inspeção mensal.
- Planilha de Condenação Total na inspeção final mensal.
- Planilha de Condenação parcial na inspeção final mensal.

No decorrer do projeto, adquiriram-se alguns dados sobre matadouro-frigorífico de suínos em uma Empresa C. Os dados foram coletados pela empresa em 2004 e eram referentes a projetos que a empresa estava desempenhando. Decidiu-se investir na hipótese de que a inteligência artificial pudesse ser utilizada com sucesso em um matadouro-frigorífico de suínos. Os dados fornecidos para construção dos modelos da empresa C, de suínos foram:

- Peso Quente da Carcaça Suína
- Peso Frio da Carcaça Suína
- Quebra de Resfriamento (%)
- Porcentagem de quebra de resfriamento (%)
- Espessura de toucinho

- Temperatura interna do pernil
- Tempo no choque térmico
- Temperatura do pernil na saída do choque térmico
- Tempo de permanência no choque térmico
- Tempo de jejum alimentar
- Peso vivo do suíno
- Rendimento de carcaça (%)

#### 3.2 Análise estatística dos dados:

A análise estatística descritiva e as diferenças entre as médias dos dados (teste t-student) foram calculadas através do programa computacional SPSS 12.0. e Microsoft Office Excell 2003.

#### 3.3 Redes Neurais Artificiais:

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

Para a construção das RNAs foi utilizado o programa computacional *NeuroShell® Predictor*, desenvolvido 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.

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 as predições são obtidas.

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.

Na figura 1 está representado esquematicamente a arquitetura da rede neural com as variáveis de entrada, a camada oculta e as variáveis de saída.

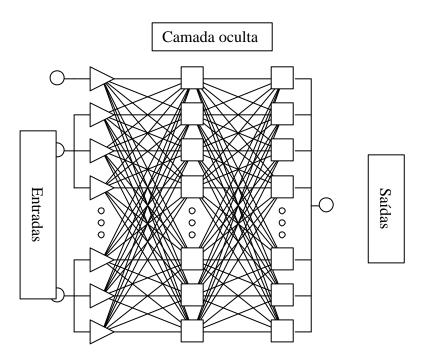


Figura 1 – Exemplo esquemático da arquitetura de rede neural.

Os modelos de redes neurais artificiais das variáveis preditas (saídas), são comparados e selecionados como melhores, baseados no Coeficiente de Determinação Múltipla (R²), no Quadrado Médio do Erro (QME), bem como pela análise de gráficos. O R² foi calculado através da fórmula R² = 1-(SSE/SSyy), onde SSE =  $\Sigma$  (valor real - valor predito)² e SSyy =  $\Sigma$  (valor real - 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].

# 4. RESULTADOS E DISCUSSÃO:

Os resultados do presente trabalho estão divididos em seis partes, sendo que cada uma apresenta um modelo distinto. Em razão da grande quantidade de dados e tabelas gerados neste trabalho, optou-se por unir resultados e discussões, para que a discussão discorra imediatamente após a apresentação de cada modelo. Ainda em virtude da quantidade de modelos, apresentar-se-ão seis modelos e os restantes estarão contidos nos apêndices presentes no final desta dissertação.

Na Tabela 1 são apresentadas conjuntamente às características dos modelos gerados na fase de treinamento das redes neurais artificiais para o gerenciamento de um matadouro-frigorífico avícola e suídeo. A visualização do conjunto demonstra que as redes neurais foram bem ajustadas e apresentaram um Coeficiente de Determinação Múltipla (R²) elevado. Acrescente-se que o R² perfeito é 1 e um coeficiente bom está próximo de 1.

Tabela 1- Modelos escolhidos para explicar diferentes parâmetros analisados em matadouro-frigorífico da empresa A, B e C (suínos).

Empre sa	Parâmetro (saída)	Número de entradas	R <sup>2</sup>	Erro Médio	Correlação
A	Condenação parcial	12	1	3,13 E-13	1
В	Peso da carcaça saída do chiller (kg)	5	0,99	0,01	0,99
В	Teste deAbsorção na saída <i>chiller</i>	6	0,99	0,07	0,99
В	Condenação por falha operacional	3	1	3,2 E-14	1
C suínos	Quebra de resfriamento (em porcentagem)	7	0,99	0,02	0,99
C suínos	Peso vivo dos suínos (kg)	2	0,99	1,35	0,99
A	Condenação Totalinspeção final	18	1	1,82E-13	1
A	Condenação total pré- inspeção	9	1	0,000168	1

R²- Coeficiente De Determinação Múltipla; QME- Quadrado Médio do Erro; RQME-Raiz Quadrada média do Erro.

# 4.1 – Modelo de rede neural artificial para o estudo das causas de condenação parcial na inspeção final da empresa A.

Através dos dados da empresa A, com 2910 linhas de dados, que equivalem ao número de lotes abatidos em 2005, foi possível treinar três modelos que explicam as saídas: "Condenação Parcial na Inspeção Final", "Condenação Total na Inspeção Final" e "Condenação Total na Pré-Inspeção".

Os três modelos são um estudo de correlações lineares e como já era esperado apresentaram uma Correlação e Coeficiente de Determinação Múltipla igual a 1.

O modelo de redes neurais para a saída "Condenação Parcial na Inspeção Final" utilizou 2910 lotes, destes 2600 foram utilizados no treinamento e 310 na validação da rede.

As variáveis de entrada utilizadas no modelo foram:

- Abscesso
- Artrite
- Celulite
- Contaminação
- Contusão
- Cozido
- Dermatose
- Aerossaculite
- Magreza
- Má sangria
- Ascite metabólica
- Outras causas

## A variável de saída escolhida foi:

 Condenação Parcial na Inspeção Final (número de aves com condenação parcial).

A Tabela 2 apresenta um resumo das informações obtidas com o treinamento da rede neural para a saída "Condenação Parcial na Inspeção Final" na empresa A. As estatísticas obtidas refletem um modelo bem ajustado, com Correlação e Coeficiente

de Determinação Múltipla (R²) igual a 1, como era esperado, por ser uma correlação linear.

Tabela 2 - Característica do modelo de rede neural artificial para a predição da saída "Condenação Parcial na Inspeção Final".

	Estatística de predição	Valores	
R <sup>2</sup>		1	
Erro médio		3,13E-13	
Correlação		1	
QME		2,63E-25	
RQME		5,13E-13	

R<sup>2</sup>- Coeficiente de Determinação Múltipla; QME- Quadrado Médio do Erro; RQME- Raiz Quadrada média do Erro.

A Tabela 3 e a Figura 2 apresentam a importância relativa de cada variável analisada, ou seja, mostra as principais causas de condenações parciais no relatório de inspeção final do matadouro-frigorífico da empresa A.

Tabela 3 - Importância relativa das variáveis de entrada para a saída "Condenação Parcial na Inspeção Final" na empresa A.

Variável de entrada	Importância relativa
Contaminação	0,307
Artrite	0,227
Abscesso	0,199
Contusão	0,101
Cozido	0,065
Dermatose	0,031
Má sangria	0,027
Celulite	0,020
Ascite metabólica	0,010
Aerossaculite	0,010
Outras causas	0,001
Magreza	0,001

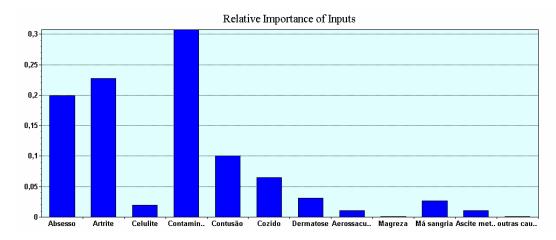


Figura 2- Gráfico da importância relativa das variáveis de entrada para a variável de saída "Condenação Parcial na Inspeção Final".

Para a validação do modelo estudado acima foram utilizados 310 lotes abatidos na empresa A em 2005. As predições obtidas revelaram as estatísticas da Tabela 4, apresentando uma predição muito satisfatória, sustentada por um Coeficiente de Determinação Múltipla (R²) e Correlação igual a 1 e por Quadrado Médio do Erro (QME) e Erro médio mínimos, como era esperado, por se tratar de uma análise de correlação linear.

Tabela 4 – Validação do modelo de redes neurais para a predição de condenação parcial

na inspeção final em 310 lotes abatidos em 2005 na empresa A.

Estatís	tica de predição	Valores	
R <sup>2</sup>		1	
Erro médio		2,72 E-13	
Correlação		1	
QME		1,5E-25	
RQME		3,93E-13	

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

Na Tabela 5 estão relacionadas predições, com os valores reais e valores preditos no modelo de rede neural artificial para a variável de saída Condenação Parcial na Inspeção Final" da empresa A. Em razão da grande quantidade de lotes validados e para que a tabela seja confeccionada em uma única página, serão apresentados somente 50 dos 310 lotes, escolhidos aleatoriamente.

Tabela 5 - Resultados reais e valores preditos de 'Condenação Parcial na Inspeção Final' para lotes abatidos em 2005 na empresa A, escolhidos aleatoriamente.

Lote	Valor Real	Valor Predito	Lote	Valor Real	Valor Predito
	(número	(número		(número	(número
	carcaça)	carcaça)		carcaça)	carcaça)
2601	57	57	2626	199	199
2602	61	61	2627	95	95
2603	127	127	2628	59	59
2604	22	22	2629	91	91
2605	47	47	2630	48	48
2606	55	55	2631	93	93
2607	28	28	2632	69	69
2608	52	52	2633	136	136
2609	68	68	2634	62	62
2610	42	42	2635	46	46
2611	40	40	2636	68	68
2612	165	165	2637	42	42
2613	84	84	2638	97	97
2614	77	77	2639	114	114
2615	45	45	2640	139	139
2616	46	46	2641	151	151
2617	29	29	2642	153	153
2618	41	41	2643	91	91
2619	36	36	2644	46	46
2620	94	94	2645	170	170
2621	74	74	2646	101	101
2622	126	126	2647	178	178
2623	98	98	2648	54	54
2624	134	134	2649	54	54
2625	107	107	2650	25	25

Ao serem avaliados os resultados reais *versus* preditos para a variável de saída "Condenação Parcial na Inspeção Final" para lotes abatidos em 2005 na empresa A, verificou-se que as diferenças existentes foram nulas, como já era esperado, pelo modelo acima ser uma correlação linear.

Na Figura 3 apresenta-se graficamente uma visão conjunta da totalidade dos 310 lotes validados.

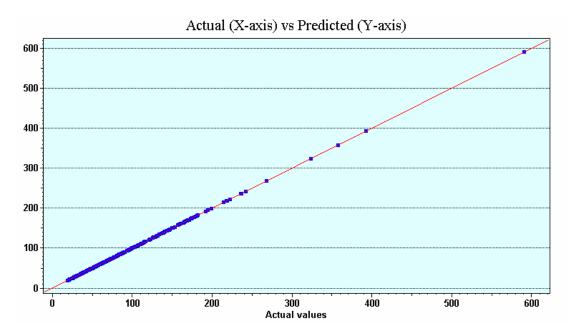


Figura 3 - Valores reais (X) *versus* preditos (Y) da variável de saída "Condenação Parcial na Inspeção Final" para os 310 lotes abatidos utilizados na validação da rede.

Os resultados da Tabela 5 demonstraram que o modelo de rede neural aplicado realizou predições idênticas ao valor real, como já era esperado, por ser uma correlação linear, com o Coeficiente de Determinação Múltipla e Correlação igual a 1. Podemos observar isto graficamente na Figura 3.

A obtenção deste resultado, que parece óbvio, reforça a credibilidade desta tecnologia em calcular e predizer resultados futuros. A vantagem de utilizar a rede neural é a rapidez que ela gera todos esses dados estatísticos e constrói o gráfico de importância relativa de cada variável que influencia no processo, como mostrado na Tabela 3 e Figura 2 deste modelo. Acrescenta-se ainda que resultados de modelos mais simples e muitas vezes óbvios servem como exemplo para modelos mais complexos, que possuem diversas variáveis influenciando no processo, e que não conseguiriam ser calculados com tamanha precisão através da estatística convencional.

Na Figura 2 ficam evidentes graficamente as diferentes variáveis que influenciam na Condenação Parcial na Inspeção Final do matadouro-frigorífico. A Tabela 3, por sua vez, quantifica a importância relativa de cada variável no processo. Atualmente os matadouros-frigoríficos utilizam este tipo de informação diariamente, porém realizando análises estatísticas convencionais e histogramas, porém as RNAs

trazem a informação de importância relativa de cada variável, tanto numericamente como graficamente. Estas análises são realizadas pelos técnicos das empresas para conhecer quais são as condenações que mais afetam o processo de produção e acarretando perdas econômicas. Sabemos pelo gráfico na Figura 2 e pela importância relativa da tabela 3, por exemplo, que a contaminação da carcaça, com importância relativa de 0,307, é o que mais condena carcaças parcialmente, logo, devemos dar maior atenção a estas causas de contaminação de carcaças dentro da produção. As condenações por contaminação, abscesso e artrite são as responsáveis por mais de 70% da condenação parcial desta empresa, como pode ser observado graficamente na Figura 2 e numericamente na Tabela 3. Ficam evidentes os pontos a serem trabalhados para redução da condenação parcial no matadouro-frigorífico. Já a variável que menos influencia no processo de Condenação Parcial na Inspeção Final é a Magreza, com uma importância relativa de 0,001 no processo. Tal modelo poderia ser enriquecido caso obtivéssemos informações reais do lote (mortalidade, enfermidades e medicamentos), anteriores ao abate.

## 4.2 Modelo de rede neural artificial para a variável de saída "Peso da Carcaça na Saída do *Chiller*" na Empresa B.

Na empresa B, acessamos dois bancos de dados distintos. A partir do banco de dados de 4588 linhas, treinamos dois modelos com as variáveis de saídas: "Peso da Carcaça Na Saída do Chiller" e "Teste de Absorção". Ambos modelos apresentaram Coeficiente de Determinação Múltipla e Correlação muito próximo a 1 e Erro Médio mínimo. Na mesma empresa foi possível construir uma rede com 166 linhas de dados, mesmo sabendo-se que para utilização de RNAs devemos dispor de um grande número de dados para treinarmos a rede e construirmos um modelo preciso.

O modelo gerado para variável de saída "Peso da Carcaça Na Saída do Chiller" utilizou 4588 lotes abatidos, destes, 4000 foram utilizados para treinar a rede e 588 foram utilizados para a validação. As variáveis de entrada escolhidas foram: "Temperatura Da Entrada No Pré-Chiller", "Temperatura Da Saída No Pré-Chiller", "Temperatura Da Saída No Chiller" e "Peso Inicial da Carcaça Antes de Entrar no Chiller" (Kg). A variável de saída a ser predita escolhida foi "Peso da Carcaça na Saída do Chiller" (Kg).

A Tabela 6 apresenta um resumo das informações obtidas com o treinamento da rede neural para a saída "Peso da Carcaça Na Saída do *Chiller*". As estatísticas obtidas refletem um modelo bem ajustado, com alto Coeficiente de Determinação Múltipla (R²) e Correlação, e baixo Erro médio e Quadrado Médio do Erro (QME).

Tabela 6 - Característica do modelo de redes neurais artificiais para predição de peso da carcaça na saída do *chiller* na empresa B.

	Estatística de predição	Valores	
R <sup>2</sup>		0,99	
Erro médio		0,01	
Correlação		0,99	
QME		0,000311	
RQME		0,017641	

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

A Tabela 7 e a Figura 4 apresentam a importância relativa de cada variável analisada para a saída "Peso da Carcaça Na Saída do *Chiller*" da empresa B.

Tabela 7 - Importância relativa das variáveis de entrada para a variável de saída "Peso da Carcaça Na Saída do Chiller".

Importância relativa	
0,950	
0,027	
0,015	
0,007	
0,001	
	0,950 0,027 0,015 0,007

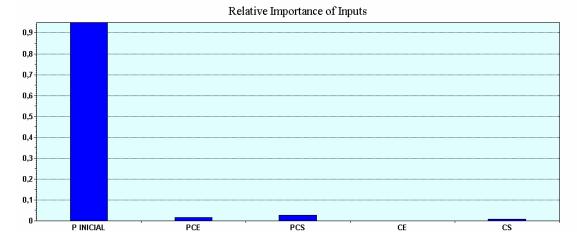


Figura 4- Gráfico da importância relativa das variáveis de entrada para a saída "Peso Final da Carcaça Na Saída do Chiller".P INICIAL: Peso antes de entrar no *chiller*, PCE: temperatura de entrada do pré-*chiller*, PCS: temperatura de saída do pré-*chiller*; CE: temperatura de entrada do *chiller*; CS: temperatura de saída do *chiller*.

A Tabela 8 apresenta um resumo das informações estatísticas obtidas com a validação dos 588 lotes para a saída "Peso na saída do *chiller*". As estatísticas obtidas refletem uma boa predição com alto Coeficiente de Determinação Múltipla (R²) e Correlação, ambos muito próximos a 1, e um baixo Erro médio e Quadrado Médio do Erro (QME).

Tabela 8 - Característica do modelo de redes neurais artificiais para predição de peso da carcaça na saída do *chiller*.

	Estatística de predição	Valores	
R <sup>2</sup>		0,99	
Erro médio		0,01	
Correlação		0,99	
QME		0,000299	
RQME		0,017	

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

Na Tabela 9 estão relacionados predições, com os valores reais e valores preditos. Em razão da grande quantidade de lotes validados e para que a tabela seja confeccionada em uma única página, serão apresentados, aleatoriamente, somente 50 dos 588 lotes.

Tabela 9- Resultados reais e valores preditos da variável de saída "Peso da carcaça na saída do chiller" das carcaças utilizadas na validação da rede neural artificial da empresa B.

Lote	Valor Real	Valor Predito	Lote	Valor Real	Valor Predito
	(kg)	(kg)		(kg)	(kg)
4001	1,82	1,815379	4026	1,8	1,807354
4002	1,66	1,654873	4027	2	1,98018
4003	1,92	1,916092	4028	2,02	2,000546
4004	1,9	1,926178	4029	1,8	1,831221
4005	2,1	2,108134	4030	2,3	2,304425
4006	2,2	2,209501	4031	2,1	2,118998
4007	1,96	1,966548	4032	2	2,005813
4008	1,89	1,885849	4033	1,86	1,872258
4009	1,9	1,927365	4034	2,2	2,211688
4010	1,75	1,745598	4035	1,95	1,954415
4011	1,7	1,705325	4036	1,96	1,97497
4012	2,44	2,425235	4037	2,22	2,232293
4013	2,26	2,282688	4038	1,63	1,616344
4014	2,3	2,333582	4039	1,99	2,016963
4015	2,12	2,120014	4040	1,7	1,70934
4016	2	2,028674	4041	1,93	1,927309
4017	2,1	2,109859	4042	1,79	1,778496
4018	2	1,99826	4043	1,76	1,758717
4019	1,9	1,90895	4044	1,79	1,768605
4020	1,99	1,98018	4045	2	2,02694
4021	1,99	2,020918	4046	1,96	1,917364
4022	1,95	1,949642	4047	1,9	1,907421
4023	2,06	2,071873	4048	1,83	1,82801
4024	2,18	2,18408	4049	2,2	2,200369
4025	1,9	1,90895	4050	1,86	1,856295

Ao serem avaliados os resultados reais *versus* preditos para a variável de saída "Peso da Carcaça Na Saída do Chiller" da empresa B, verificou-se que as diferenças existentes foram mínimas.

Na Figura 5 apresenta-se uma visão gráfica conjunta da totalidade das 588 carcaças utilizadas na validação.

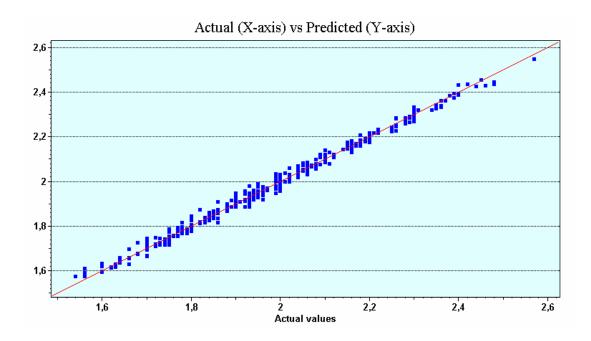


Figura 5- Valores reais (X) *versus* preditos (Y) do peso da carcaça na saída do chiller para as 588 carcaças utilizadas na validação da rede.

Os resultados demonstraram que o modelo de rede neural aplicado realizou predições muito próximas ao valor real para a saída "Peso da Carcaça na Saída do *Chiller*". Nota-se através da Tabela 7 e Figura 4 que as variáveis que podem ser gerenciadas (temperatura do *chiller*), podem influenciar no máximo em 5% do peso final. Isto se deve também a falta de alguns registros por parte da empresa, elementos essenciais que influenciariam no peso da carcaça na saída do *chiller*. Então, podemos dizer que dentro das variáveis aqui estudadas, o peso inicial da carcaça é o fator que contribuirá com seu peso final na saída do *chiller*.

Em trabalho realizado por Klassen (2004) foi descrito o uso de inteligência artificial para descrever o funcionamento do sistema de carcaças por imersão. As variáveis de entrada foram diversas: peso carcaça, temperatura da carcaça antes do resfriamento, temperatura da camisa de propilenoglicol, vazão de água em cada módulo do tanque, tempo de resfriamento e temperatura da água de renovação. A variável de saída escolhida no trabalho foi "Temperatura do Frango Na Saída do Último *Chiller*". O autor chegou a um modelo com Erro Médio de 3,52%, que é um erro baixo, e um gráfico de dispersão do treinamento e validação dos valores reais e preditos muito bons, porém as comparações de Coeficiente de Determinação Múltipla e Correlação não serão possíveis de realizar, nem mesmo quais variáveis influenciaram no processo, pois o autor tinha como objetivo gerar um modelo com o

menor Erro médio possível, e não necessariamente estudar os fatores que influenciaram na temperatura final da carcaça.

Além das variáveis utilizadas por Klassen (2004) temos ainda outras variáveis que influenciam no processo de resfriamento das carcaças e sua absorção de água: "Velocidade do Abate", "Tempo Carcaça No Interior Chiller", "Borbulhamento No Chiller", e outras variáveis ambientais e construtivas, como por exemplo, "Umidade do Ambiente", "Corrente de Ar", "Espessura dos Isolamentos", "Área de Lâmina de Água", entre outros. Isso mostra a complexidade fenomenológica do processo de resfriamento de carcaças.

Infelizmente a empresa B, fornecedora dos dados, não possuía o controle de temperatura da carcaça associada à coleta de dados do chiller. Essa coleta se dava em horários diferenciados e registros não associados. Utilizou-se então um modelo cuja saída era o "Peso Final da Carcaça". Este modelo apresentou-se bem ajustado, porém com poucas variáveis estudadas, dentre a quantidade de variáveis que poderiam estar mensuradas e registradas na rotina diária da empresa. Isto demonstra a fragilidade de um processo tão importante como o resfriamento de carcaça, responsável pela questão microbiológica e de combate à fraude de frango com excesso de água.

# 4.3 Modelo de redes neurais artificiais para a variável de saída "Teste de Absorção" em carcaças da empresa B.

O modelo gerado para a variável de saída "Teste de Absorção das Carcaças", utilizou 4588 lotes, destes 4000 foram utilizados no treinamento da rede e 588 lotes utilizados na validação.

As variáveis de entrada foram: "Temperatura da Entrada do Pré-Chiller", "Temperatura da Saída do Pré-Chiller", "Temperatura da Entrada do Chiller", "Temperatura da Saída do Chiller", "Peso Inicial da Carcaça Antes de Entrar no Chiller" e "Peso da Carcaça Na Saída do Chiller". A variável de saída foi "Teste de Absorção" (quantidade de água absorvida na carcaça em percentagem).

Na Tabela 10 apresentar-se-á a característica do modelo de redes neurais para a saída "Teste de absorção". Verifica-se que o Coeficiente de Correlação e Coeficiente de Determinação Múltipla (R²) são altos, próximos a 1 e o Erro médio e Quadrado Médio do Erro (QME) são baixos.

Tabela 10 - Característica	do modelo	de redes	neurais	artificiais	para predição	de teste
de absorção da	carcaça na	saída do	chiller.			

	Estatística de predição	Valores	
R <sup>2</sup>		0,99	
Erro médio		0,07	
Correlação		0,99	
QME		0,00122	
RQME		0,011025	

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

A Tabela 11 e a Figura 6 apresentam a importância relativa de cada variável analisada para a variável saída teste de absorção da carcaça.

Tabela 11 - Importância relativa das variáveis de entrada para a saída "Teste de Absorção".

Variáveis	Importância Relativa	
Peso final	0,519	
Peso inicial	0,481	
Temperatura entrada pré-chiller	0,000	
Temperatura saída pré-chiller	0,000	
Temperatura entrada chiller	0,000	
Temperatura saída chiller	0,000	

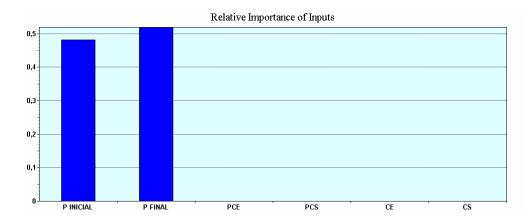


Figura 6 - Gráfico da importância relativa das variáveis de entrada para a saída "Teste de Absorção". P INICIAL: "Peso inicial", PCE: "Temperatura Entrada do Pré-Chiller", PCS: "Temperatura de Saída do Pré-Chiller"; CE: "Temperatura Entrada Chiller"; CS: "Temperatura de Saída do Chiller".

Para a validação do modelo estudado acima foram utilizadas 588 carcaças. As predições obtidas revelaram as estatísticas da Tabela 12.

Tabela 12 - Característica do modelo de redes neurais artificiais para predição de teste de absorção.

	Estatística de predição	Valores	
R <sup>2</sup>		0,998	
Erro médio		0,025	
Correlação		0,99	
QME		0,01	
RQME		0,03	

R<sup>2</sup>- Coeficiente de Determinação Múltipla; QME- Quadrado Médio do Erro; RQME- Raiz Quadrada média do Erro.

Na Tabela 13 estão relacionados predições, com os valores reais e os valores preditos. Em razão da grande quantidade de lotes validados e para que a tabela seja confeccionada em uma única página serão apresentados, aleatoriamente, somente 50 dos 588 lotes.

Tabela 13 - Resultados reais e preditos do teste de absorção de carcaças abatidas em 2006.

Carcaça	Valor Real	Valor Predito	Carcaça	Valor Real	Valor Predito
	(%)	(%)		(%)	(%)
4001	7,06	7,052791	4026	6,51	6,532943
4002	7,79	7,719837	4027	7,53	7,527736
4003	6,67	6,676716	4028	7,45	7,448658
4004	4,97	4,983351	4029	5,26	5,269647
4005	5,53	5,516905	4030	5,99	5,86693
4006	5,26	5,228038	4031	5,53	5,447021
4007	5,95	5,953924	4032	6,38	6,361048
4008	6,78	6,786529	4033	6,29	6,297021
4009	4,97	5,007572	4034	5,77	5,668506
4010	7,36	7,329131	4035	6,56	6,552821
4011	6,92	6,895538	4036	5,95	5,921055
4012	6,09	6,06568	4037	5,71	5,605077
4013	4,63	4,597345	4038	8,67	8,699762
4014	4,07	4,006886	4039	4,74	4,758111
4015	6	6,02065	4040	6,92	6,933604
4016	4,71	4,732693	4041	6,63	6,637549
4017	5,53	5,544044	4042	7,83	7,817636
4018	6,38	6,407104	4043	7,32	7,313671
4019	6,15	6,165855	4044	8,48	8,462002
4020	6,99	6,995735	4045	4,71	4,730108
4021	4,74	4,72622	4046	8,89	8,952507
4022	6,56	6,569761	4047	6,15	6,1622
4023	5,64	5,634058	4048	7,02	7,023685
4024	5,83	5,798005	4049	5,77	5,749211
4025	6,15	6,165855	4050	6,9	6,903178

Ao serem avaliados os resultados reais *versus* preditos para a saída "Teste de Absorção" para carcaças abatidas em 2006 da empresa B, verificou-se que as diferenças existentes foram mínimas.

A Figura 7 apresenta graficamente uma visão conjunta da totalidade dos 588 lotes validados.

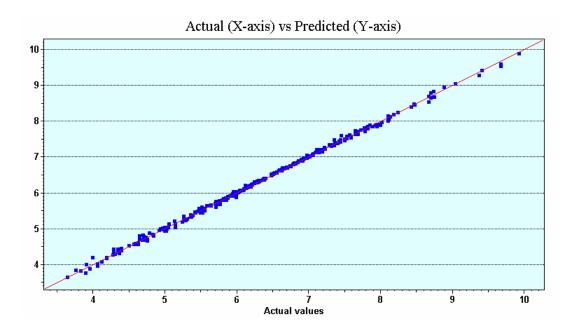


Figura 7 - Valores reais (X) *versus* preditos (Y) da saída "Teste De Absorção" (%) para as 588 carcaças utilizadas na validação da rede.

Os resultados demonstraram que o modelo de rede neural aplicado realizou predições próximas ao valor real para a saída "Teste de Absorção". Na Tabela 13 e Figura 7 podemos observar um modelo muito ajustado, com valores preditos muito próximos ao real.

Neste modelo, podemos observar novamente, através da Tabela 12 e Figura 6 que as variáveis de temperatura do *pré-chiller* e *chiller*, não influenciaram no teste de absorção. Mais uma vez, salientando o descrito na discussão do item 4.2 deste trabalho, por falta de dados primordiais na construção deste tipo de modelo, observase que a importância relativa para "Teste de Absorção" se concentrou em "Peso Inicial" e "Peso Final", e variáveis que poderiam contribuir na construção do modelo, como por exemplo "Temperatura da carcaça", "Velocidade do Abate", "Tempo Carcaça No Interior *Chiller*", "Borbulhamento No *Chiller*", e outras variáveis ambientais e construtivas, como por exemplo, "Umidade do Ambiente", "Corrente de Ar", "Espessura dos Isolamentos", "Área de Lâmina de Água", entre outros, não tinham registros na empresa.

## 4.4 Modelo de redes neurais artificiais para a variável de saída "Condenação Por Falha Operacional".

O modelo gerado para a variável de saída "Condenação Por Falha Operacional" utilizou 166 linhas, sendo que destas 140 para o treinamento da rede e 26 para a validação.

As variáveis de entrada para a construção do modelo foram: "Escaldagem excessiva", "Mal sangrados" e "Evisceração retardada". A variável de saída escolhida foi "Condenação Por Falha Operacional" (número de carcaças condenadas por falha operacional).

A Tabela 14 apresenta um resumo das informações obtidas com o treinamento da rede neural para a variável de saída "Condenação Por Falha Operacional". As estatísticas obtidas refletem um modelo bem ajustado, com Coeficiente de Determinação Múltipla (R²) e Correlação igual a 1, como já era esperado por ser uma correlação linear.

Tabela 14 - Característica do modelo de redes neurais artificiais para predição de condenação por falha operacional.

	Estatística de predição	Valores	
R <sup>2</sup>		1	
Erro médio		3,2 E-14	
Correlação		1	
QME		2,9E -27	
RQME		5,39E -14	

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

A Tabela 15 e a Figura 8 apresentam a importância relativa de cada variável analisada para a variável de saída "Condenação Por Falha Operacional" no abate.

Tabela 15 - Importância relativa das variáveis de entrada para a variável de saída "Condenação Por Falha Operacional" na empresa B.

Variável entrada	Importância relativa	
Escaldagem Excessiva	0,531	
Mal Sangrados	0,415	
Evisceração Retardada	0,054	

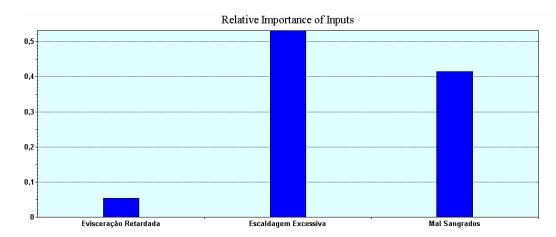


Figura 8 - Gráfico da importância relativa das variáveis de entrada para a saída "Condenação Por Falha Operacional".

Para a validação do modelo estudado acima foram utilizados 26 dias de abate. As predições obtidas revelaram as estatísticas da Tabela 16.

Tabela 16 - Característica do modelo de redes neurais artificiais para predição de condenação por falha operacional.

	Estatística de predição	Valores	
R <sup>2</sup>		1	_
Erro médio		2,66 E-14	
Correlação		1	
QME		1,2 E-27	
RQME		3,46 E-14	

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

Na Tabela 17 estão relacionados predições, com os valores reais e valores preditos das 26 linhas utilizadas para a validação da rede.

Tabela 17- Resultados reais e valores preditos da variável de saída "Condenação Por Falha Operacional".

Dia de abate	Valor atual	Valor predito
	(número carcaça)	(número carcaça)
141	18	18
142	7	7
143	2	2
144	4	4
145	8	8
146	11	11
147	16	16
148	13	13
149	38	38
150	10	10
151	122	122
152	4	4
153	3	3
154	12	12
155	18	18
156	18	18
157	4	4
158	7	7
159	11	11
160	8	8
161	89	89
162	10	10
163	13	13
164	18	18
165	18	18
166	7	7

Ao serem avaliados os resultados reais *versus* preditos para a variável de saída "Total de Condenações Por Falha Operacional" da empresa B, verificou-se que as diferenças existentes foram nulas, como já era esperado, por ser uma correlação linear.

A Figura 9 apresenta graficamente uma visão conjunta da totalidade dos 26 dias de abate validados.

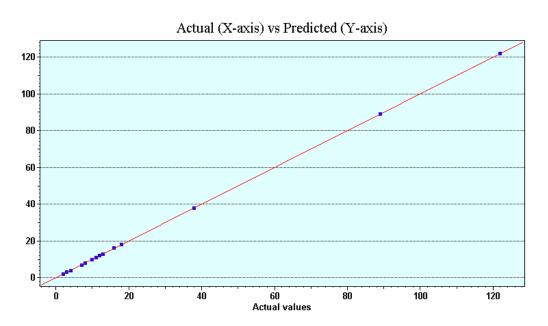


Figura 9 - Valores reais (X) *versus* preditos (Y) da saída "Condenação Por Falha Operacional" para os 26 dias de abate utilizados para validação da rede.

Os resultados demonstraram que o modelo de rede neural aplicado realizou predições exatas ao valor real para a saída "Condenação Por Falha Operacional". Este tipo de análise pode ser realizada perfeitamente pelo programa computacional Excell, mas desconhecia-se a utilidade da rede neural para esse tipo de análise, fornecendo inclusive importância relativa de cada variável. Foi realizada a validação com um número menor de linhas, pois não foi possível o acesso a um número maior de dados na empresa.

Um técnico da empresa com este modelo pode mensurar os dois maiores problemas operacionais no abate que acarretam condenações: "Escaldagem Excessiva" e a "Má Sangria". Ambos são responsáveis por 90% dos problemas operacionais. Já a evisceração retardada, é um problema operacional menor, acarretando menores perdas na condenação em relação aos outros. Com esta ferramenta, o técnico pode tomar decisões e mudanças de estratégia no matadouro-frigorífico. Este tipo de controle se realiza com planilhas de Excell ou uma simples calculadora, agora se conhece uma nova metodologia, muito eficiente para este tipo de controle.

Outros dados que poderiam ser registrados e incluídos neste modelo seriam peso, sexo e linhagem da aves, devido ao ajuste das máquinas para determinadas faixas de peso, número de funcionários na linha, pois muitas vezes erros operacionais

ocorrem pela sobrecarga de trabalho e número de funcionários novos trabalhando, pelo maior incidência de erros durante o treinamento dos mesmos.

## 4.5 Modelo de redes neurais artificiais para a variável de saída "Quebra de Resfriamento" em carcaças suínas na empresa C.

A empresa C forneceu dados de suínos de dois projetos distintos. O primeiro incluía o estudo de alguns fatores que influenciavam a quebra de resfriamento de suínos e o segundo tinha por objetivo solucionar o problema de pesagem do suíno vivo, substituído por única pesagem da carcaça.

Um dos problemas que ocorrem nas carnes resfriadas é a perda ou quebra de peso por evaporação, durante o processo de resfriamento. As carcaças perdem peso porque, inicialmente a temperatura de sua superfície é muito mais elevada que a da câmara fria. A perda de peso é importante quando a empresa comercializa de acordo com seu peso frio ou direto ao consumidor. Sua importância é menor quando a carne resfriada se transforma em produtos cárnicos no próprio estabelecimento e nas receitas se estimam as perdas pelo frio. Também é importante prever o tempo de armazenamento e qual a finalidade da carne. Por exemplo, se a carne será espostejada no dia seguinte ao sacrifício e se, com ela, serão elaborados produtos cárnicos. Assim sendo, será suficiente armazená-la a temperatura de 10°C. Mas, se ela será armazenada por mais dias, será necessário colocá-la em temperaturas oscilando entre 0°C - 4C°(Prandl *et al.*, 1994).

O modelo gerado para saída "Quebra de Resfriamento" na empresa C, utilizou para treinamento da rede 1300 carcaças e para validação 334 carcaças. Salienta-se que a empresa referida abate suínos e que estes dados foram aproveitados no presente trabalho, devido ao interesse em estudar fatores que envolvam matadouros-frigoríficos, não somente em aves, mas também em suínos.

Variáveis de entrada:

- Peso Quente da Carcaça Suína
- Peso Frio da Carcaça Suína
- Espessura de Toucinho
- Temperatura do Pernil
- Temperatura do Pernil Na Saída do Choque Térmico

- Tempo de Permanência No Choque Térmico
- Tempo de Jejum Alimentar

#### Variável de saída:

• Quebra de Resfriamento (%).

A Tabela 18 apresenta um resumo das informações obtidas com o treinamento da rede neural para a saída "Quebra de Resfriamento". As estatísticas obtidas refletem um modelo bem ajustado, com Coeficiente de Determinação Múltipla (R²) e Correlação próximo a 1.

Tabela 18 - Característica do modelo de redes neurais artificiais para predição de "Ouebra de Resfriamento" em carcaca suína.

	Estatística de predição	Valores	
R <sup>2</sup>		0,99	
Erro médio		0,0028	
Correlação		0,99	
QME		0,00002	
RQME		0,0044	

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

A Tabela 19 e a Figura 10 apresentam a importância relativa de cada variável analisada para a variável de saída "Quebra de Resfriamento" em suínos.

Tabela 19 - Importância relativa das variáveis de entrada para a saída "Quebra de Resfriamento" em suínos na empresa C.

Importância relativa
0,505
0,465
0,022
0,008
0,001

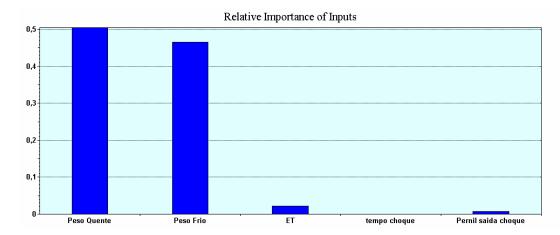


Figura 10- Gráfico da importância relativa de cada variável para a variável de saída "Quebra de Resfriamento" em suíno na empresa C.

Para a validação do modelo estudado acima foram utilizadas 334 carcaças. As predições obtidas revelaram as estatísticas da Tabela 20.

Tabela 20- Característica do modelo de redes neurais artificiais para predição de quebra de resfriamento.

Estatística de predição	Valores	
R <sup>2</sup>	0,99	
Erro médio	0,02	
Correlação	0,99	
QME	0,005	
RQME	0,07	

R<sup>2</sup>- Coeficiente de Determinação Múltipla; QME- Quadrado Médio do Erro; RQME- Raiz Quadrada média do Erro.

Na Tabela 21 estão relacionados predições, com os valores reais e valores preditos de 50 carcaças, escolhidas aleatoriamente, para a saída "Quebra de Resfriamento".

Tabela 21 - Resultados reais e preditos do modelo de redes neurais para a saída "Quebra de Resfriamento".

Lote	Valor Real	Valor Predito	Lote	Valor Real	Valor Predito
	(%)	(%)		(%)	(%)
1301	2,572347	2,584821	1326	2,291105	2,292112
1302	2,195122	2,197037	1327	2,063107	2,065916
1303	1,585205	1,617588	1328	2,631579	2,638678
1304	1,597444	1,577139	1329	2,341137	2,345595
1305	1,726264	1,735384	1330	2,983539	3,010699
1306	1,540284	1,54264	1331	2,463054	2,461459
1307	2,115159	2,116338	1332	1,898734	1,90888
1308	2,435897	2,43172	1333	1,908802	1,897408
1309	1,930502	1,942334	1334	2,03666	2,02478
1310	2,953587	2,905442	1335	2,380952	2,380014
1311	1,546392	1,572321	1336	1,984733	2,031663
1312	1,84182	1,831225	1337	2,435897	2,43172
1313	1,343284	1,452237	1338	2,722063	2,69006
1314	1,846966	1,866694	1339	2,176871	2,184772
1315	4,05562	4,029499	1340	1,928021	1,93973
1316	1,965065	1,95887	1341	2,195122	2,197037
1317	2,521008	2,509508	1342	2,27027	2,27289
1318	1,556886	1,561748	1343	2,020202	2,048729
1319	3,125	3,028819	1344	2,187902	2,191468
1320	2,014389	2,04276	1345	1,628664	1,613019
1321	1,967213	1,961187	1346	2,369668	2,371636
1322	2,378378	2,384475	1347	1,845444	1,843099
1323	2,054795	2,070752	1348	2,173913	2,171795
1324	1,72973	1,715743	1349	2,248521	2,24662
1325	2,192448	2,19437	1350	2,434077	2,438471

Ao serem avaliados os resultados reais *versus* preditos para a saída "Quebra de Resfriamento" na empresa C, verificou-se que as diferenças existentes foram mínimas.

A Figura 11 apresenta graficamente uma visão conjunta da totalidade dos 334 carcaças utilizadas na validação.

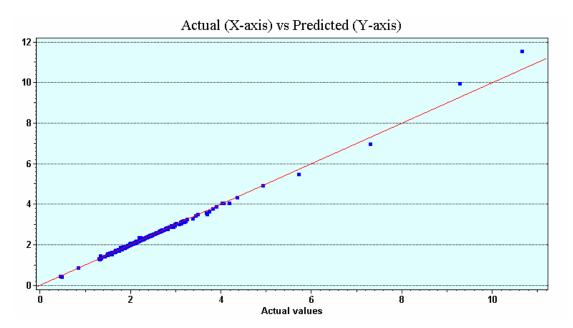


Figura 11- Valores reais (X) *versus* preditos (Y) da saída "Quebra de Resfriamento" para as 334 carcaças utilizadas na validação da rede.

O modelo utilizado para a variável de saída "Quebra de Resfriamento" utilizou 1634 linhas de dados. O treinamento do modelo apresentou Coeficiente de Determinação Múltipla e a Correlação altos, próximos a 1 e Erro médio baixo. Na validação do modelo foi possível observar a capacidade de predizer, com precisão, os acontecimentos futuros. Este resultado ultrapassou a expectativa do presente trabalho, que inicialmente estudaria apenas matadouro-frigorífico de aves.

Observamos que as variáveis que mais contribuíram para a quebra de resfriamento foram "Peso Quente" e "Peso Frio", com 90% de importância relativa somando-se as duas. Já a "Espessura de Toucinho", "Tempo Permanência do Choque" e "Temperatura do Pernil Na Saída do Choque Térmico" apresentaram menor importância relativa.

A temperatura do choque térmico seria um dado de grande importância, porém não haviam registros associados. Verifica-se que o choque térmico, justamente tem a função de baixar a temperatura da carcaça mais rapidamente, pois ele trabalha com temperaturas próximas a -20°C, enquanto que na câmara de resfriamento a temperatura fica em torno de 0°C.

Os resultados demonstraram que o modelo de rede neural aplicado realizou predições muito próximas ao valor real para a saída "Quebra de Resfriamento". Não foram encontradas referências bibliográficas semelhantes utilizando RNAs em

matadouro-frigorífico de suínos para realizarmos as desejáveis e cabíveis comparações.

## 4.6 Modelo de redes neurais artificiais para a variável de saída "Peso Vivo de Suínos" na empresa C.

O modelo gerado para saída "Peso Vivo de Suínos", utilizou para treinamento da rede 750 carcaças e para sua validação 226 carcaças.

As variáveis de entrada utilizadas para construção do modelo foram: "Peso da Carcaça Quente" e "Rendimento" no abate da carcaça. A variável de saída a ser predita escolhida foi "Peso Vivo".

A Tabela 22 apresenta um resumo das informações obtidas com o treinamento da rede neural para a saída "Peso Vivo". As estatísticas obtidas refletem um modelo bem ajustado, com Coeficiente de Determinação Múltipla (R²) e Correlação altos.

Tabela 22 - Característica do modelo de redes neurais para predição de peso vivo de suínos.

	Estatística de predição	Valores	
R <sup>2</sup>		0,99	
Erro médio		1,35	
Correlação		0,99	
QME		3,72	
RQME		1,65	

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

A Tabela 23 e a Figura 12 apresentam a importância relativa de cada variável analisada para a saída "Peso Vivo".

Tabela 23 - Importância relativa das variáveis de entrada para a saída "Peso Vivo" do suíno na empresa C.

Variável	Importância relativa
Peso da carcaça quente	0,859
Rendimento da carcaça	0,141

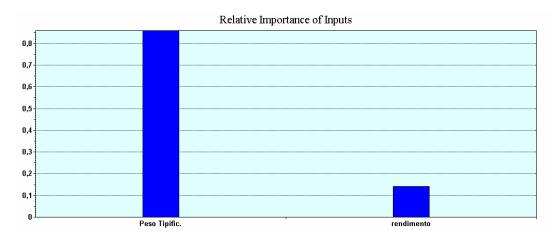


Figura 12 - Gráfico da importância relativa de cada variável para a saída "Peso Vivo" de suíno. Peso Tipif: "Peso da Carcaça Quente".

Para a validação do modelo estudado acima foram utilizadas 226 carcaças. As predições obtidas revelaram as estatísticas da Tabela 24.

Tabela 24 - Característica do modelo de redes murais para predição de peso vivo do suíno.

Estatística de predição		Valores	
R <sup>2</sup>		0,97	
Erro médio		1,31	
Correlação		0,98	
QME		2,72	
RQME		1,65	

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

Na Tabela 25 estão relacionados predições, com os valores reais e valores preditos de 50 carcaças suínas para saída "Peso Vivo", escolhidas aleatoriamente.

Tabela 25-Resultados reais e valores preditos para a variável de saída "Peso Vivo" de suínos.

Carcaça	Valor Real	Valor Predito	Carcaça	Valor Real	Valor Predito
	(Kg)	(Kg)		(Kg)	(Kg)
751	118,5	118,0964	776	90,6	91,87049
752	103	103,565	777	106,5	103,1543
753	101	100,3849	778	101,5	100,2044
754	110	109,1996	779	115,5	112,5015
755	91	90,32021	780	113,5	112,2849
756	104,5	106,1201	781	97,8	99,74261
757	116	114,948	782	99,2	100,1696
758	107,5	106,7721	783	117,5	114,8942
759	101	99,81154	784	103,5	102,4687
760	98,6	97,3957	785	102,5	102,9402
761	110	109,671	786	105	104,227
762	117,5	116,1111	787	98,4	95,99819
763	96,4	97,12536	788	97,6	98,72856
764	115	116,4272	789	96,8	99,25116
765	127,5	124,7895	790	110	108,1317
766	116	114,5863	791	88,2	88,69435
767	106	105,4777	792	111,5	108,8138
768	83,4	82,582	793	109	108,0639
769	105,5	102,382	794	87,4	88,02395
770	115	115,0069	795	88,6	88,33455
771	97,2	98,44997	796	109	107,7097
772	98,4	98,95039	797	111	111,9799
773	103,5	102,7002	798	107	107,8858
774	96,6	94,79568	799	116,5	117,8457
775	105,5	102,2629	800	87,6	89,81609
	7-	,		, -	,

Ao serem avaliados os resultados reais *versus* preditos para a saída "Peso Vivo" de suínos na empresa C, verificou-se que as diferenças existentes foram mínimas.

A Figura 13 apresenta graficamente uma visão conjunta da totalidade das 226 carcaças utilizadas na validação.

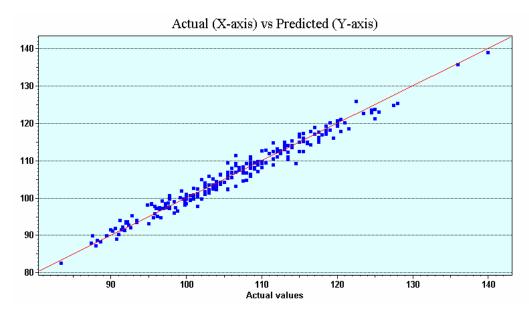


Figura 13 - Valores reais (X) *versus* preditos (Y) da saída "Peso Vivo" para as 226 carcaças utilizadas na validação da rede.

A empresa pesava duas vezes seus animais, uma na recepção dos animais e outra no abate junto com a pistola de tipificação. Este projeto teve por objetivo predizer o peso vivo do suíno apenas a partir de seu rendimento e peso da carcaça quente (pesado na balança junto com a pistola de tipificação e espessura de toucinho). A empresa desejava não precisar pesar seus animais na entrada do frigorífico, evitando desgaste para os animais quando são descarregados do caminhão, promovendo bem estar animal, diminuindo o custo com funcionário operando a balança e podendo pagar para o produtor o preço justo do suíno, baseado no peso quente e no rendimento. O modelo foi então construído a partir de 975 linhas de dados. A Correlação e o Coeficiente de Determinação Múltipla foram muito próximos a 1 e o Erro Médio foi baixo.

O Erro médio do modelo presente apresentou-se mais alto (1,31) que os modelos anteriores. O motivo para essa variação é que se trata do peso de um suíno , que possui peso médio de 100 kg. Assim, 1,31 não é um Erro médio alto, quando comparado ao peso médio de 100 kg de um animal.

Não foram encontradas outras referências bibliográficas, utilizando RNAs com o mesmo fim, impossibilitando uma discussão com as comparações.

O emprego de redes neurais artificiais para este tipo de predição apresentou um modelo ajustado para o pagamento do suíno ao produtor baseado em critérios objetivos, podendo deslocar um funcionário para outras funções, promover bem estar animal e contentar o produtor e a empresa.

Os resultados demonstraram que o modelo de rede neural aplicado realizou predições próximas ao valor real para a saída peso vivo, possibilitando a predição do mesmo.

#### 4.7 Considerações finais:

A literatura atual de redes neurais artificiais em avicultura não é vasta. Trabalhos com propostas semelhantes a esta não foram encontrados, em nenhuma consulta bibliográfica realizada. O Centro de Diagnósticos e Pesquisa em Patologia Aviária (CDPA) já havia demonstrado que esta metodologia poderia ser utilizada para o gerenciamento de reprodutoras pesadas (Guahyba, 2001; Salle et al., 2001; Salle et al., 2003), no gerenciamento de frangos de corte (Reali, 2004) e no gerenciamento de um incubatório (Salle, 2004). Na literatura consultada foram encontradas publicações que utilizaram as redes neurais artificiais em matadouro-frigorífico, porém não com o mesmo objetivo. Foram utilizadas redes neurais artificiais, para a criação de modelos para predição de ascite em frangos (Roush et al., 1997; Roush et al., 1996; Roush et al., 2000; Roush et al., 2001, Cravener, 1999) e para a inspeção de carcaças nos matadouros-frigoríficos utilizando a tecnologia das redes neurais, juntamente com tecnologia de digitalização de imagens (Park et al.. 1998; Park et al.. 2001; Park et al.. 2003;). As desejáveis comparações dos resultados obtidos com os trabalhos de outros autores não puderam ser realizadas.

Quando comparamos este trabalho com os outros realizados por Guahyba, (2001) em reprodutoras pesadas, Reali (2004) em frango de corte, Salle, (2004) em incubatório, observamos que os modelos deste trabalho são mais simples, com o estudo de variáveis que influenciam em um determinado fator, e menores predições "desconhecidas". Isto se deve ao fato do banco de dados disponibilizados de cada segmento avícola possuírem forma de registros distintos e, muitas vezes, não possuírem determinadas variáveis de extrema importância, mensuradas e registradas, para construção de um determinado modelo. Porém, as redes neurais artificiais foram capazes, em todos eles, de construir modelos bem ajustados e predições confiáveis. Isto vem demonstrar a boa perspectiva do emprego desta nova metodologia no gerenciamento do processo produtivo da cadeia avícola.

Os resultados obtidos neste trabalho demonstraram que a inteligência artificial pode ser utilizada como ferramenta nas decisões de um gerenciamento de um

matadouro-frigorífico avícola e por ocasião, matadouro-frigorífico de suínos. Assim, foi plenamente atingido o objetivo que motivou a realização deste estudo.

Os dados fornecidos pelas três empresas neste trabalho foram utilizados para a construção de oito modelos. Na fase de treinamento dos modelos, as redes apresentaram valores de Correlação e de Coeficiente de Determinação Múltiplo (R²) muito altos, próximos a 1 e Erro médio e Quadrado Médio do Erro (QME) mínimos, o que significa que foram valores muito bons.

Os modelos desta dissertação demonstraram que as redes neurais podem ser utilizadas como uma ferramenta essencial na tomada de decisão do gerenciamento de um matadouro-frigorífico, realizando predições de acontecimentos e realizando um estudo das variáveis que mais influenciam em um determinado fator.

É importante ressaltar que com a utilização das redes neurais artificiais o que se pretende é implementar uma ferramenta de auxílio à tomada de decisões, e não um programa que substitua o conhecimento científico e técnico.

Salienta-se que os modelos aqui gerados servem somente para as empresas que os geraram.

No decorrer deste trabalho a utilização de rede neural artificial para as predições em matadouro-frigorífico foi muitas vezes prejudicada pela informação e registros obtidos na empresa. Em nenhuma das empresas, infelizmente, foi criada uma proposta de como deveriam ser coletados os dados para que se conseguisse um modelo específico. Todas essas informações obtidas são analisadas de outra forma na empresa, e, muitas vezes, não é a ideal para se chegar ao modelo desejado. Portanto, para esta dissertação, diversos outros modelos foram inviabilizados devido à forma como a informação é registrada. Este fato é totalmente compreensível em razão das diversas formas como as empresas analisam atualmente seus dados. Por outro lado, a metodologia que emprega a inteligência artificial, apesar de estar se tornando rotina na Universidade, é um campo ainda a ser descoberto pelas agroindústrias.

Visto que as RNAs podem ser utilizadas com sucesso na avicultura, e no matadouro-frigorífico de suínos, apresentado em pequena amostra no presente trabalho, deve-se instigar a Universidade a iniciar em outros segmentos, que não a avicultura, a aplicação das redes neurais artificiais.

#### 5. CONCLUSÃO

As redes neurais artificiais foram capazes de explicar fenômenos de gerenciamento de matadouro-frigorífico avícola, e também para matadouro-frigorífico de suínos.

A técnica proposta no presente trabalho disponibiliza critérios objetivos, gerados cientificamente, que oferecerão subsídios para as tomadas de decisões dentro de um matadouro-frigorífico. Também apresenta a importância relativa de cada variável de entrada para a saída analisada e ainda permite a realização de simulações para predizer resultados futuros.

Com a criação de um sistema de registros delineado para a utilização de redes neurais artificiais, as combinações de dados de entradas e dados de saídas serão sensivelmente melhoradas, possibilitando seu maior aproveitamento.

#### REFERÊNCIAS BIBLIOGRÁFICAS

- ARGOV, S. Diagnostic potential of fourier-transform infrared microspectroscopy and advanced computacional methods in colon cancer patients. **J.Biomed.Opt.**, v. 7, n. 2, 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.
- BASSOI L.J. Tratamento de águas residuárias. In: FACTA. **Abate e processamento de frango.** Campinas: 1994. p. 1-12.
- BAXT, W. G.; SHOFER F.S.; SITES, F. D.;HOLLANDER, J. E. A neural network aid for the early diagnosis of cardic ischemia in patients presenting to the emergency departament with chest pain. **Ann.Emerg.Med.**, v. 40, n. 6, p. 575-583, 2002.
- BERAQUET N.J. Abate e evisceração. In: FUNDAÇÃO APINCO DE CIÊNCIA E TECNOLOGIA AVÍCOLAS. **Abate e processamento de frangos.** Campinas: Fundação Apinco de Ciência e Tecnologia Avícolas, 1994. Cap. 3, p. 19-24.
- BICCIATO, S. Pattern identification and classification in gene expression data using an autoassociative neural network model. **Biotechnol.Bioeng.**, v. 81, n. 5, p. 595-606, 2003.
- BOCANEGRA C.W.R. **Dissertação de Mestrado.** Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes. 2002. Escola de Engenharia de São Carlos-USP, 2002.
- BREMNER, A. S. **Higiene e Inspección de Carne de Aves.** Zaragoza: Editorial Acribia, 1981. Bremner,1981.
- BUZATU, D. A. The determination of cardic 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., & GWOZDZ, F. B. (2002). On-line inspection of poultry carcasses by a dual-camera system. **Journal of Food Engineering** 51, 185-192.
- CHENG, B.; TITTERINGTON, D. M. Neural Networks: a review from a statistical perspective. **Statistical Science,** v. 9, n. 1, p. 2-54, 1994.
- CHETAM, S. M.; BARKER, T. M.; STAFFORD, W. Neural networks in cardiac electrophysiological signal classification. **Australas Phys.Eng.Science Medicine**, 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
- CURNOW R.N. A smooth population response curve based on an abrupt threshould and plateau model for individuals. **Biometrics**, v. 29, n. 1, p. 1-10, 1986.
- DAWSON, A. E.; AUSTIN, R. E.; WEINBERG JR.D.S. Nuclear granding of breast carcinoma by image analysis.classification by multivariate and neural network analysis. **American Journal Clinical Pathology**, 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.
- DOUGHERTY M.A. A rewiew of neural network applications in transportation engineering. **Transportation Research**, 3. Parte C, 247-260.1995.
- FIALHO, F. B. & LEDUR M.C. **Modelo matemático para curvas de produção de ovos.** Comunicado Técnico n.256 Embrapa Suínos e Aves. 256, 1-3. 2000a
- FIALHO, F. B. & LEDUR, M. C. **Estimador da produção de ovos.** Comunicado Técnico n.257 Embrapa Suínos e Aves 257, 1-2. 2000b.
- FREITAS A.R. Estimativa do peso de frangos macho e fêmeas através de modelos matemáticos. In Embrapa Suínos e Aves (Ed.), (pp. 1-4).1983.
- GUAHYBA A.S. **Tese doutorado**. Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento de reprodutoras pesadas.. Porto alegre: UFRGS, Faculdade de veterinária, PPGCV, 2001.
- HAN, M. Evaluation of articial neural networks for the prediction of pathologic stage in prostate carcinoma. **Cancer**, v. 91, n. 8, p. 1661-1666, 2001.
- IVEY F.J. Desenvolvimento e aplicação de modelos de crescimento para frango de corte. In (pp. 22-35). Concordia- Santa Catarina.1999.
- KING R.D. Description of a growth simulation model for predicting the effect of diet on broiler composition and growth. **Poultry Science.**, v. 80, n. 3, p. 245-253, 2001.
- KIRBY ET AL. Evaluation of logistic versus linear regression models for predcting pulmonary hypertension sydrome using cold exposure or pulmonary artery clamp models in broilers. **Poultry Science**, **76**, 392-399.1997.
- KLASSEN T.. Modelagem do sistema de resfriamento de carcaças de frangos com redes neurais artificiais. Universidade Estadual do Oeste do Paraná. 1-30. Paraná. 2004.
- LEE A.; CLAUDIA ULBRICHT; H.L.DE S.MORAES. Application of artificial neural networks for detection of abnormal fetal heart rate pattern: A comparsion with

- conventional algorithms. **Journal of obstetrics and gynaecology,** v. 19, n. 5, p. 482-485, 1999.
- LEMOS ET AL **Inteligência artificial e consciência.**: 2006. Disponível em: <a href="http://www.geocities.com/Athens/Sparta/1350/ia/finais.html">http://www.geocities.com/Athens/Sparta/1350/ia/finais.html</a>. Acesso 15/11/2006.
- LOCH, T. Improvement of transrectal ultrasound. Artificial neural network analysis (ANNA) in detection and ataging of prostatic carcinoma. **Urologe A.,** v. 39, n. 4, p. 341-347, 2000.
- LOKHORST C. Mathematical curves for the description of input and output variables of the daily production process in aviary housing systems for systems for laying hens. **Poultry Science**, v. 75, n. 7, p. 838-848, 1996.
- MINISTÉRIO DA AGRICULTURA E DO ABASTECIMENTO. **Regulamento técnico da inspeção tecnológica e higiênico sanitária de carne de aves.** Portaria 210. de 10/11/1998.
- MUIR W.M. Genetic Selection Strategies : computer modeling. **Poultry Science.,** v. 76, n. 8, p. 1066-1070, 1997.
- PARK B. AND CHEN, Y. R Matrix texture features of multi-spectral images on poultry carcasses. **J.agric.Engng.Res.**, 78, 127-139.2001.
- PARK, B. & CHEN, Y. R.. Co-ocurrence matrix texture features of multi-spectral images on poultry carcasses. J.agric.Engng.Res. 78, 127-139. 2003.
- PARK, B., CHEN, Y. R., & NGUYEN, M.. Multi-spectral image analysis using neural network algorithm for inspection of poultry carcasses. **J.agric.Engng.Res**. 69, 351-363. 1998.
- PRANDL, O.; FISCHER A.; SCHMIDHOFER T.; SINELL H. Tecnologia e higiene de la carne. In: S.A.EDITORIAL ACRIBIA. **Tecnologia e higiene de la carne.** Zaragoza-España:1994. p. 79-91.
- RAMOS J.P.S. Redes Neurais Artificiais na classificação de frutos: cenário bidimensional. **Ciências Agrotécnicas**, 27, 356-362.2003.
- REALI E.H. **Dissertação de Mestrado**.Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento da produção de frangos de corte. 2004. UFRGS-Universidade Federal do Rio Grande do Sul, Faculdade de Veterinária, Programa de Pós Graduação em Ciências Veterinárias., 2004.
- ROCHA A.C.G.P. **Tese de doutorado.** Utilização de Inteligência Artificial para a Classificação de Patogenicidade de Amostras de *Escherichia coli* Isoladas de Frangos de Corte. 2006. Universidade Federal do Rio Grande do Sul, Faculdade de Veterinária, Programa de Pós-Graduação em Ciências Veterinárias, Porto Alegre, BRRS, 2006.

- RONDÓN E.O. (2002). Modelagem Computacional para produção e pesquisa em avicultura. **Revista Brasileira de Agrociência**, *4*, 199-207.2002.
- ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, 65, 386-408.1958.
- ROUSH, W. B.; KIRBY, Y. K.; CRAVENER, T. L.; WIDEMAN, R. F., Jr. Artificial neural network prediction of ascites in broilers. **Poult.Sci.**, v. 75, n. 12, p. 1479-1487, 1996.
- ROUSH, W. B.; CRAVENER, T. L.; KIRBY, Y. K.; WIDEMAN, R. F., Jr. 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, R. F., Jr. 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, R. F., Jr.; 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., SOARES R.C.B., CÉ M.C., SILVA A.B.DA, MORAES H.L.S., NASCIMENTO V.P. Modelos matemáticos para avaliar resposta imune de aves à doença de Newcastle. **A Hora Veterinária**, 102, 41-44.1998a.
- SALLE, C. T. P., CÉ, M. C., LORENZINI, G., SFOGGIA, M. V. B., GUAHYBA, A. D. S., MORAES, H. L. D. S. Correlation between aflatoxin and ocratoxin levels with production parameters in a poultry company. In (pp. 131). Melbourne Australia.1998b.
- SALLE, C. T. P., CÉ, M. C., SANTOS, C. H. C., GUAHYBA, A. D. S., & NASCIMENTO, V. P. D. Use of statistical technique on the interpretation of routine serologic data produced by poultry industry. In (pp. 148). Melbourne Australia.1998c.
- SALLE, C. T. P., CÉ, M. C., LORENZINI, G., SFOGGIA, M. V. B., GUAHYBA, A.D. S., MORAES, H. L. D. S. ET AL.. Correlation between aflatoxin and ocratoxin levels with production parameters in a poultry company. In (pp. 130). Vancouver Canada.1999<sup>a</sup>.
- SALLE, C. T. P., CÉ, M. C., SANTOS, C. H. C., GUAHYBA, A. D. S., & NASCIMENTO, V. P. D.. Use of statistical techniques on the interpretation of routine serological data produced by a poultry industry. In (pp. 130). Vancouver Canada.1999b
- SALLE, C. T. P., SOARES, R. C. B., CÉ, M. C., MORAES, H. L. D. S., NASCIMENTO, V. P. D., & GUAHYBA, A. D. S.. Immune response assessment in

- turkey breeders vaccinated against Newcastle disease using mathematical models. In (pp. 129). Vancouver Canada.1999c.
- SALLE, C. T. P.; SILVA, A. B. d. Prevenção de Doenças / Manejo Profilático / Monitorização. In: A.BERCHIERI JUNIOR; M. MACARI (Eds.). **Doenças das Aves.** 2000. p. 03-12.
- SALLE, C. T.; 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.
- SALLE, F. O. **Dissertação de mestrado.** Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento do incubatório de uma empresa avícola do sul do Brasil. 2005. UFRGS, 2005.
- SNOW, P. B.; KERR, D. J.; BRANDT, J. M.;RODVOLD, D. M. Neural network and regression predictions of 5 years survival after colon carcinoma treatment. **Cancer**, v. 91, n. 8, p. 1673-1678, 2001.
- SOARES, R. C. B. **Dissertação de mestrado.** Avaliação da resposta imunológica em reprodutoras de perus (Meleagridis gallopavo) diante do vírus vacinal da doença de Newcastle através de modelos matemáticos. 1995. Porto Alegre: UFRGS, Faculdade de Veterinária, PPGCV, 1995.
- ZIADA, A. M. Impact of different variables on the outcome of patients with clinically confined prostate carcinoma: prediciton of pathologic stage and biochemical failure using an artifical neural network. **Cancer**, v. 91, n. 8, p. 1653-1660, 2001.

### APÊNDICE A- Modelo de redes neurais artificiais para a variável de saída "Condenação Total De Carcaça Na Inspeção Final" da empresa A.

- Número de lotes abatidos utilizados: 2910
- Lotes utilizados para treinamento: 2600
- Lotes utilizados para validação: 310

#### Variáveis de entrada:

- Abscesso
- Celulite
- Artrite
- Colibacilose
- Caquexia
- Salpingite
- Contaminação
- Contusão
- Cozido
- Dermatose
- Aerossaculite
- Coligranulomatose
- Septicemia
- Má sangria
- Mau aspecto
- Ascite
- Tumores
- Síndrome Hemorrágica

#### Variável de saída:

• Condenação Total na Inspeção Final (número de carcaças condenadas).

#### TREINAMENTO DA REDE NEURAL ARTIFICIAL:

Tabela 1- Característica do modelo de redes neurais artificiais para predição da Condenação Total na Inspeção Final da empresa A.

	Estatística de predição	Valores	
R <sup>2</sup>		1	
Erro médio		1,82E-13	
Correlação		1	
QME		2,37E-25	
RQME		4,86E-13	

R<sup>2</sup>- Coeficiente De Determinação Múltipla; QME- Quadrado Médio do Erro; RQME- Raiz Quadrada média do Erro.

#### IMPORTÂNCIA RELATIVA DAS ENTRADAS ESTUDADAS:

Tabela 2- Importância relativa das entradas estudadas na empresa A para a saída "Condenação Total na Inspeção Final".

Entrada	Importância relativa	
Cozido	0,270	
Contaminação	0,166	
Sindrome Hemorrágica	0,096	
Caquexia	0,092	
Mau aspecto	0,089	
Absesso	0,047	
Ascite	0,047	
Má sangria	0,045	
Aerossaculite	0,042	
Dermatose	0,041	
Artrite	0,020	
Contusão	0,013	
Colibacilose	0,012	
Celulite	0,007	
Salpingite	0,005	
Coligranulomatose	0,003	
Tumores	0,003	
Septicemia	0,001	

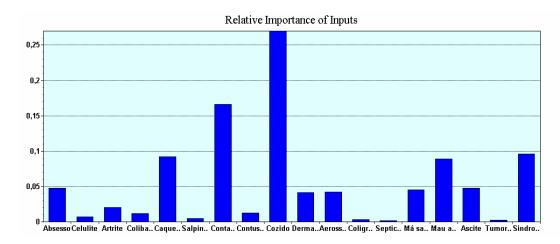


Figura 1-Gráfico da importância relativa de cada variável de entrada para a saída Condenação Total na Inspeção Final.

### TESTE E VALIDAÇÃO DA REDE NEURAL ARTIFICIAL PARA OS 310 LOTES:

Tabela 3- Validação do modelo de redes neurais artificiais para a predição Condenação Total na Inspeção Final dos 310 lotes abatidos em 2005 da empresa A.

	Estatística de predição	Valores
R <sup>2</sup>		1
Erro médio		1,38E -13
Correlação		1
QME		3,96E-26
RQME		1,99E-13

R²- Coeficiente De Determinação Múltipla; QME- Quadrado Médio do Erro; RQME-Raiz Quadrada média do Erro

Tabela 4- Resultados reais e predições de 50 dos 310 lotes abatidos em 2005.

LOTE	REAL	predições de 50 d PREDITO	LOTE	REAL	PREDITO
LOIL	(nº carcaça)	(nº carcaça)	LOIL	(nº carcaça)	(nº carcaça)
2601	2	2	2651	24	24
2602	7	7	2652	36	36
2603	0	2,28E-14	2653	56	56
2604	3	3	2654	10	10
2605	0	2,28E-14	2655	9	9
2606	2	2	2656	0	2,28E-14
2607	5	5	2657	9	9
2608	6	6	2658	7	7
2609	2	2	2659	10	10
2610	0	2,28E-14	2660	14	14
2611	22	22	2661	5	5
2612	8	8	2662	1	1
2613	7	7	2663	3	3
2614	4	4	2664	3	3
2615	1	1	2665	7	7
2616	8	8	2666	10	10
2617	3	3	2667	7	7
2618	15	15	2668	3	3
2619	8	8	2669	5	5
2620	7	7	2670	7	7
2621	5	5	2671	5	5
2622	3	3	2672	2	2
2623	0	2,28E-14	2673	2	2
2624	1	1,0	2674	3	3
2625	8	8	2675	5	5

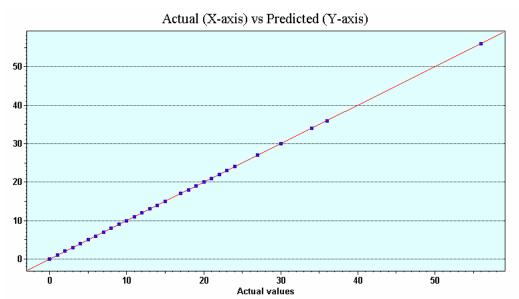


Figura 2- Valores reais (X) *versus* preditos (Y) da saída condenação total na préinspeção para os 310 lotes abatidos utilizados na validação da rede.

### APÊNDICE B-Modelo de redes neurais artificiais para variável de saída "Condenação Total Na Pré-Inspeção" na Empresa A.

Número de lotes abatidos utilizados: 2910

• Lotes utilizados para treinamento: 2600

Lotes utilizados para validação: 310

#### Variáveis de entrada:

- Cozido
- Caquexia
- Má sangria
- Ascite
- Artrite
- Coriza
- Abscesso
- Contusão
- Desidratação

#### Variável de saída:

• Condenação na pré-inspeção (número carcaça).

Tabela 1- Característica do modelo de redes neurais artificiais para predição de condenação total na pré-inspeção.

	Estatística de predição	Valores	
R <sup>2</sup>		1	
Erro médio		0,000168	
Correlação		1	
QME		0,000017	
RQME		0,004142	

R²- Coeficiente De Determinação Múltipla; QME- Quadrado Médio do Erro; RQME- Raiz Quadrada média do Erro.

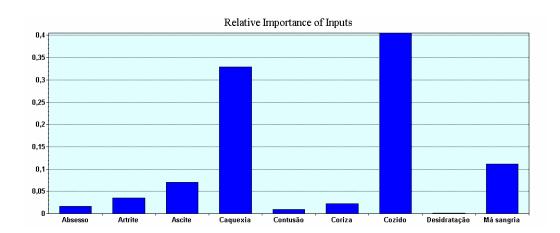


Figura 1- Gráfico da importância relativa das variáveis de entrada para a saída "Condenação Total Na Pré-Inspeção".

Tabela 2- Importância relativa das variáveis de entrada para a saída condenação total na pré-inspeção.

Variáveis de entrada	Importância relativa	
Cozido	0,405	
Caquexia	0,329	
Má sangria	0,111	
Ascite	0,035	
Artrite	0,035	
Coriza	0,022	
Absesso	0,016	
Contusão	0,010	
Desidratação	0,001	

### **VALIDAÇÃO:**

Tabela 3- Característica do modelo de redes neurais artificiais para predição de condenação total na pré-inspeção .

	Estatística de predição	Valores
R <sup>2</sup>		1
Erro médio		0,00009
Correlação		1
QME		9,81E-09
RQME		0,000099

R<sup>2</sup>- Coeficiente De Determinação Múltipla; QME- Quadrado Médio do Erro; RQME-Raiz Quadrada média do Erro.

Tabela 4- Resultados reais e predições de 50 dos 310 lotes abatidos em 2005.

Lote	Valor Real	Valor	Lote	Valor Real	Valor
	(nº carcaça)	Predito		(nº carcaça)	Predito
		(nº carcaça)			(nº carcaça)
2601	56	55,9999	2641	54	53,9999
2602	22	21,99994	2642	63	62,99989
2603	13	12,99994	2643	103	102,9998
2604	25	24,99994	2644	52	51,99986
2605	60	59,99981	2645	44	43,99989
2606	16	15,99995	2646	25	24,99989
2607	28	27,99998	2647	15	14,9999
2608	18	17,99991	2648	3	2,999937
2609	18	17,99994	2649	25	24,99992
2610	21	20,99993	2650	12	11,99991
2611	9	8,999928	2651	15	14,99991
2612	31	30,9999	2652	22	21,99989
2613	37	36,99988	2653	8	7,999919
2614	15	14,99991	2654	3	2,999924
2615	26	25,99991	2655	6	5,999923
2616	30	29,99987	2656	35	34,99986
2617	21	20,9999	2657	12	11,9999
2618	21	20,99993	2658	5	4,999919
2619	15	14,99994	2659	5	4,999919
2620	40	40,00008	2660	14	13,99992
2621	35	34,99998	2661	10	9,999908
2622	19	18,99998	2662	6	5,999918
2623	32	32,00003	2663	12	11,9999
2624	16	15,99995	2664	5	4,999919
2625	51	50,9999	2665	62	61,99986

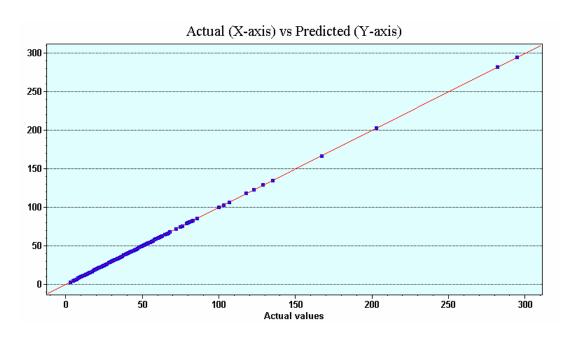


Figura 2 - Valores reais (X) *versus* preditos (Y) da saída "Condenação Total Na Pré-Inspeção" para os 310 lotes abatidos utilizados na validação da rede.