

**GERY ANTÔNIO DARTORA**

**REDES NEURAS ARTIFICIAIS: APLICAÇÃO NA  
TIPIFICAÇÃO DE CARÇA DE SUÍNOS**

**FLORIANÓPOLIS – SC**

**2003**

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**

**GERY ANTONIO DARTORA**

**REDES NEURAIS ARTIFICIAIS: APLICAÇÃO NA  
TIPIFICAÇÃO DE CARÇA DE SUÍNOS.**

Dissertação submetida à Universidade Federal de Santa Catarina como requisito final para a obtenção do grau de Mestre em Ciência da Computação.

**PROF. DR. PAULO SÉRGIO SILVA BORGES  
ORIENTADOR**

**FLORIANÓPOLIS, FEVEREIRO DE 2003.**

**UNIVERSIDADE FEDERAL DE SANTA CATARINA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA**  
**COMPUTAÇÃO**

**GERY ANTONIO DARTORA**

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação Área de Concentração (Sistemas de Conhecimento) e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.

Banca Examinadora

---

Prof. Dr. Fernando Álvaro Ostuni Gauthier  
Coordenador do Curso

---

Prof. Dr. Paulo Sérgio da Silva Borges  
Orientador

---

Prof. Dr. Luiz Fernando Jacintho Maia

---

Prof. Dr. Jorge Muniz Barreto

## Epígrafe

Conhecimento Nunca é demais e tendo em vista a eternidade podemos aprender qualquer coisa desde que queiramos e tenhamos fé para tanto, pois somos filhos de Deus e como tais podemos ser como nosso Pai é em todos os sentidos.

## Página de Oferecimento

A todos aqueles que se empenham e fazer ciência e promover um mundo melhor através de melhorar a qualidade em tudo e de todos os sentidos possíveis, principalmente a qualidade de vida, que é a que tanto buscamos em nosso planeta e em nossos afazer e no dia-a-dia.

## Página de Agradecimento

A Deus que sempre nos ampara em todos os momentos e é nosso Pai Celestial, a minha querida esposa Edília Dartora e familiares que sempre me deram forças e incentivo para continuar, ao Professor Paulo S. S. Borges que orientou este trabalho para que existisse, ao Waldomiro Barioni Júnior que me ajudou na sugestão de temas, ao Antonio Guidoni, que não mediu esforços em abrir portas para que pudesse ter acesso as informações necessárias, bem como ao Gerônimo Fávero, ao Belo, e, enfim todo o pessoal da Embrapa, e todos aqueles que de um modo ou de outro me ajudaram nesta árdua tarefa.

## SUMÁRIO

SUMÁRIO.....	VII
LISTA DE FIGURAS.....	IX
LISTA DE TABELAS.....	XI
LISTA DE ABREVIACES.....	XIII
RESUMO.....	XV
ABSTRACT.....	XVII
CAPTULO 1 - INTRODUO.....	17
1.1 Relevncia do Problema.....	18
1.2 Objetivos da Pesquisa .....	21
1.2.1 Objetivo Geral .....	21
1.2.2 Objetivos Especficos.....	21
1.3 Organizao do Trabalho.....	22
CAPTULO 2 - A TIPIFICAO DE CARAAS DE SUNOS .....	23
2.1 Avaliao e tipificao de caraas de sunos .....	25
2.2 A Composio da Caraa dos Sunos .....	26
2.3 A Tipificao de Caraas de Sunos no Brasil.....	30
2.4 A Tipificao de Caraas de Sunos em Outros Pases.....	37
2.5 Tipificao como Comercializao de Produtos .....	45
2.6 Tipificao Para Garantir Especificao na Caraa Inteira e suas Partes.....	49
CAPTULO 3 – REVISO DOS CONCEITOS BSICOS DE RN’S.....	58
3.1 Principais componentes dos neurnios.....	58
3.2 Histrico das Redes Neurais Artificiais.....	59
3.3 Neurocomputao.....	65
3.4 Redes Neurais Artificiais.....	66
3.4.1 Neurnio Artificial e a Rede Neural.....	67
3.4.2 O Neurnio Artificial.....	68
3.4.3 A Rede Neural Artificial (Perceptron Multi-Camada e Redes Diretas Multicamadas).....	69
3.5 Classificao de Redes Neurais Artificiais.....	71
3.6 Topologias de Redes Neurais Artificiais.....	72

3.6.1 Disposição dos Neurônios.....	72
3.6.1.1 Redes Diretas.....	74
3.6.1.2 Redes com Ciclos.....	74
3.6.1.3 Redes Simétricas.....	74
3.7 Processos de Aprendizado de uma Rede Neural Artificial.....	75
CAPÍTULO 4 – ANÁLISE DOS EXPERIMENTOS.....	78
4.1 Dados.....	78
4.2 Modelo Proposto.....	82
4.3 Modelo Linear de Regressão Múltipla.....	88
4.4 Avaliação do Modelo Proposto.....	89
4.5 Resultados Obtidos.....	90
CAPÍTULO 5 – CONCLUSÕES FINAIS.....	96
REFERÊNCIAS BIBLIOGRÁFICAS.....	99
ANEXO I.....	104

## LISTA DE FIGURAS

Figura 1.1 – Divisão de carcaça de suínos com possibilidades de especificação antecipada na linha de abate do peso e % de carne ou gordura da carcaça inteira e de suas partes.....	24
Figura 2.1 – Locais das medidas de espessura de toucinho e profundidade de músculo Longissimus dorsi utilizadas pelo MLC na Inglaterra (Adaptado de <i>Meat and Livestock Commission</i> , 1995).....	39
Figura 3.1 - Esquema dos constituintes da célula neural.....	59
Figura 3.2 - Neurônio artificial projetado por McCulloch.....	62
Figura 3.3 - Rede de perceptrons proposta por Roseblatt.....	63
Figura 3.4 - Redes ADALINE e MADALINE.....	63
Figura 3.5 - Estrutura do método <i>Retropropagação</i> .....	64
Figura 3.6 - Modelo de McCulloch e Pitts.....	68
Figura 3.7 - Esquema de um neurônio artificial.....	68
Figura 3.8 - Organização em camadas. ....	70
Figura 3.9 - Modelos de Rummelhart e Hopfield.....	72
Figura 3.10 - Rede Direta.....	74
Figura 3.11 - Rede Simétrica.....	74
Figura 4.1 – Peso da carcaça quente (kg). ....	79
Figura 4.2 – Espessura do toucinho (mm). ....	79
Figura 4.3 – Profundidade do músculo (mm). ....	80
Figura 4.4 – Percentagem de carne da carcaça resfriada . ....	80
Figura 4.5 – Gráfico de correlação entre as variáveis ....	81
Figura 4.6 – Arquitetura de RNA proposta para a predição da porcentagem de carne na carcaça resfriada. ....	84
Figura 4.7 – Script da função para criação e treinamento da rede.....	85
Figura 4.8 – Script da função para normalização do conjunto de dados.....	86

Figura 4.9 – Script da função para divisão do conjunto de dados em treinamento e teste .....	86
Figura 4.10 – Desempenho da rede treinamento/teste.....	92
Figura 4.11 – Comparação do desempenho da RNA com o método dos mínimos quadrados.....	92
Figura 4.12 – Gráfico de dispersão dos erros cometidos pelos dois modelos.....	93
Figura 4.13 – Análise de regressão dos valores previstos pelo método dos mínimos quadrados para os dezesseis animais do conjunto de teste e os valores desejados correspondentes.....	94
Figura 4.14 – Análise de regressão dos valores previstos pela RNA para os dezesseis animais do conjunto de teste e os valores desejados correspondentes.....	94

## LISTA DE TABELAS

Tabela 1.1 - Composição da carcaça de um suíno abatido com 105 kg de peso vivo...	27
Tabela 1.2 - Frequência de carcaças de suínos com peso quente de 60 a 80 kg em um abatedouro, no mês de Junho de 1995, com respeito à espessura de toucinho.....	29
Tabela 1.3 – Peso da Carcaça Quente em Kg.....	30
Tabela 1.4 - Modelo de tabela de tipificação de carcaças de suínos, com índices de bonificação e penalização baseados no peso da carcaça quente e no rendimento estimado de carne na carcaça.....	32
Tabela 1.5 - Correlações entre peso de carcaça, espessura de toucinho e profundidade de músculo, medidas com régua e com pistola, entre a última e a penúltima costelas, e entre a 3 <sup>a</sup> e 4 <sup>a</sup> costelas antes da última, com a quantidade e o rendimento de carne, gordura, ossos e pele dissecadas de 25 carcaças com 60 a 80 kg.....	33
Tabela 1.6 - Valores de R <sup>2</sup> e desvio-padrão residual para quantidade e rendimento de carne na carcaça de suínos, estimados com diferentes combinações de medidas de espessura de toucinho, profundidade de músculo e peso da carcaça quente.....	35
Tabela 1.7 - Estimativas de aumento na quantidade e no rendimento de carne em carcaças de suínos com peso quente, sem cabeça, de 60 a 80 kg, à medida que se diminui a espessura de toucinho em 1 mm, ou se aumenta a profundidade do músculo Longissimus dorsi em 1 mm.....	36
Tabela 1.8 - Classificação de carcaças utilizada na Comunidade Européia, e distribuição das carcaças de suínos classificadas pelo MLC, Inglaterra, 1994.....	39
Tabela 1.9 - Valores estimados do desvio-padrão residual e erros-padrão, em g/kg de carne, obtidos pela regressão da proporção de carne na carcaça e nos cortes principais, em um ou mais locais de medidas na carcaça.....	40
Tabela 1.10 - Distribuição da frequência de carcaças de suínos, na Espanha por classe de espessura de toucinho, em 1986.....	41

Tabela 1.11 - Desvios-padrão residuais para a predição da proporção de carne na carcaça, em g/kg, com uso da régua e com equipamentos automáticos...	42
Tabela 1.12 - Peso das carcaças, espessura de toucinho, profundidade de músculo e rendimentos médios de carne obtidos em dissecações de carcaças efetuadas em diferentes épocas na França.....	43
Tabela 1.13 - Efeito de raça e de sexo em medidas de carcaça e de rendimento de carne (médias e erros-padrão).....	44
Tabela 2.1 - Índice de bonificação empírico gerado em função do peso da carcaça quente (Pcarq) e porcentagem de carne estimada na carcaça resfriada (pcmf).....	48
Tabela 2.2 - Importância relativa do ajuste da meia carcaça não dissecada pela meia carcaça dissecada.....	52
Tabela 2.3 - Resumo sobre Peso, quantidade e % de carne em carcaças quentes e resfriadas, calculados, preditos ou ajustados com base numa amostra de carcaças dissecadas.....	53
Tabela 2.4 - Erro cometido para predizer Qcarf e Pcmf direta e indiretamente, numa dissecação.....	54
Tabela 2.5 - Erro cometido para predizer o Peso, quantidade de carne e gordura do pernil resfriado.....	56
Tabela 2.6 - Simulação para predizer o peso, quantidade de carne e gordura do pernil resfriado. ....	56
Tabela 3.1 - Quadro comparativo entre cérebro e o computador.....	65
Tabela 3.2 - Quadro comparativo entre computadores e neurocomputadores.....	65
Tabela 4.1 - Matriz de correlação entre as variáveis.....	81
Tabela 4.2 – Quanto ao número de neurônios da camada interna.....	84
Tabela 4.3 – Medidas de desempenho utilizadas.....	90
Tabela 4.4 – Comparação dos resultados obtidos.....	91
Tabela 4.5 – Medidas descritivas dos erros cometidos pelos dois modelos no teste de previsão.....	93

## LISTA DE ABREVIACES

<b>ME</b>	Erro Mdio
<b>MAE</b>	Erro Absoluto Mdio
<b>MSE</b>	Erro Quadrtico Mdio
<b>NRMSE</b>	Erro Quadrtico Mdio Normal Absoluto
<b>MAPE</b>	Erro Percentual Mdio Absoluto
<b>U<sub>2</sub></b>	Estatstica U <sub>2</sub> de Theil
<b>MLP</b>	Perceptron Mltiplas Camadas
<b>RBF</b>	<i>Radial Basis Function</i>
<b>RNA</b>	Rede Neural Artificial
<b>PCMF</b>	Porcentagem de carne da carcaa resfriada
<b>DARPA</b>	(Defense Advanced Research Projects Agency)
<b>ESP</b>	Espessura de toucinho
<b>MUS</b>	Profundidade de msculo
<b>QCARF</b>	Quantidade de carne dissecada da carcaa resfriada
<b>MLC</b>	Adaptado de <i>Meat and Livestock Commission</i>
<b>PCARFESQ</b>	Peso meia carcaa esquerda resfriada
<b>PCARFDIR</b>	Peso meia carcaa direita resfriada
<b>QCARFDIR</b>	Quantidade de carne dissecada da carcaa resfriada direita

<b>QCAFESQ</b>	Quantidade de carne dissecada da carcaça resfriada esquerda
<b>INMETRO</b>	Instituto Nacional de Metrologia, Normalização e Qualidade Industrial
<b>RENDARQ</b>	Rendimento da Carcaça Quente
<b>PVIVO</b>	Peso do Porco Vivo
<b>ISO</b>	<i>International Organization for Standardization</i> ou Organização internacional de normalização
<b>PCARQ</b>	Peso (KG) da carcaça quente
<b>IA</b>	Inteligência Artificial

## RESUMO

As redes neurais artificiais em IA têm se mostrados muito eficientes na resolução e aprimoramento de soluções em muitas áreas. Esta dissertação tem por objetivo aplicar RNA, na tipificação de carcaça de suínos, e confrontar as técnicas que estão sendo usadas no momento, com os resultados que se pretendem obter, e verificar se oferece melhor desempenho. E se assim for o caso, fornecer mais uma ferramenta de apoio, para bonificar melhor o produtor de suínos que fornece carcaças com maior rendimento e melhor qualidade de carne para a indústria frigorífica, e isto sem aumento de custos do sistema industrial, e também:

- Selecionar as carcaças mais adequadamente, destinando-as para melhor aproveitamento industrial;
- Obter uma melhoria na padronização dos produtos para atender as exigências dos consumidores;
- Lançar produtos naturais ou industrializados com diferentes especificações de quantidades de carne ou gordura com opções e variedades para o consumidor;
- Utilizar Redes Neurais Artificiais também na tipificação de bovinos, aves e muitas outras carnes, gerando assim ainda mais aplicações para IA.

## ABSTRACT

The artificial neural networks in AI have been showing itself very efficient in the resolution and upgrading of solutions in a lot of areas. This dissertation has for objective to apply RNA, in the typefication of swine carcass, and to confront the techniques which are being used at the moment, with the results which are intend to obtain, and to verify if it offers better performance. And If this is the case, to supply one more support tool, to better bonus the swine producer who supplies carcasses with larger revenue and better meat quality for the refrigerating industry, and that without increasing industrial system costs, and also:

- To select the carcasses more appropriately, destining them for better industrial use;
- To obtain an improvement in the standardization of the products to assist the consumers' demands;
- To launch natural or industrialized products with different specifications of amounts of meat or fat with options and varieties for the consumer;
- To also, use Artificial Neural Networks in the bovine, birds and many other meats typefication, generating in this way more applications to AI.

## CAPÍTULO 1 - INTRODUÇÃO

Segundo Barreto 1997, o estudo das possibilidades de RNAs na solução de problemas implica na existência de computadores usando estas redes. Chama-se neurocomputador um computador em que o funcionamento interno é feito por redes neurais munido de dispositivos de entrada e saída. Esta definição está de acordo com a tendência atual em neurofisiologia (onde a RNAs tiram sua inspiração) que é considerar o sistema nervoso juntamente com os sensores e atuadores correspondentes. Por exemplo, não se estuda o sistema de orientação visual, sem incluir o olho e os músculos além do sistema nervoso.

E embora apesar da neurocomputação ter praticamente nascido juntamente com a computação programada nas décadas de 40 e 50, deve-se salientar que a implementação de uma rede neural naquela época era inviável, pois a fase de aprendizado, a fase mais difícil e demorada no desenvolvimento de uma rede, dependia (e ainda depende) de complicados algoritmos e de um número grande de iterações, e na época não se conhecia algoritmo para treinar rede com 3 camadas.

Todas as informações aqui expostas nos levam a crer que o campo de redes neurais artificiais é acima de tudo extremamente vasto e promissor. Por ser um assunto que surgiu a muito tempo atrás, ganhou muita credibilidade, e devido á novas descobertas relacionadas a ela a cada instante, tornou-se bastante atrativo para profissionais de domínios distintos, tornando-se um assunto interdisciplinar. Os conhecimentos obtidos até hoje atraem o interesse de profissionais tais como psicólogos, neurofisiologistas, engenheiros, cientistas cognitivos, e cientistas da computação, que buscam, cada um em sua área, novos caminhos através da computação neural

A tipificação de carcaças de suínos no Brasil foi iniciada no decorrer dos anos 80, e somente no decorrer dos anos 90 é que começou a ser intensificada.

As formas de tipificação no Brasil evoluíram da medida simples de espessura de toucinho obtida com régua milimétrica, à utilização, até o momento, de pistolas com sensores óticos que usam refletância de luz. Esses equipamentos são os mesmos utilizados em outros países, e tem proporcionado precisão adequada da estimativa do rendimento de carne. Os pontos de medida dos preditores do rendimento de carne feitos pela pistola, restringem-se à medida da espessura de toucinho e da profundidade de lombo entre a última e a penúltima costela, e entre a 3<sup>a</sup>. e 4<sup>a</sup>. costelas antes da última. O primeiro local de medida é normalmente recomendado, por proporcionar, com boa exatidão, as estimativas do rendimento de carne, por facilitar a localização do ponto da medida e, por permitir medidas mais precisas em linhas de abate relativamente velozes.

A tipificação de carcaças de suínos está altamente associada à melhoria do rendimento de carne nas carcaças de suínos. O alcance deste objetivo não depende tanto do equipamento utilizado na tipificação das carcaças, como da adoção desse processo pelas indústrias frigoríficas, com bonificação para as carcaças de melhor qualidade, e da utilização de genótipos, rações e práticas de manejo que resultem em carcaças com mais carne e menos gordura.

### **1.1 Relevância do Problema**

Neste estudo através do software Matlab e suas aplicações de Inteligência Artificial usando Redes Neurais, pretende-se verificar se verdadeiramente é uma ferramenta que apresentará resultados relevantes para predizer a percentagem de carne resfriada da carcaça quente, no momento do abate, o que vai selecionar as carcaças mais adequadamente, destinando-as para melhor aproveitamento industrial; e, obter uma melhoria na padronização dos produtos para atender as exigências dos consumidores, lançar produtos naturais ou industrializados com diferentes especificações de quantidades de carne ou gordura com opções de qualidade variada para o consumidor, e isto pode ser feito sem um aumento de custos do sistema industrial tradicional já implantado, desde que ele contenha um processo adequado de tipificação de carcaça.

Assim sendo será possível, no momento da tipificação, predizer com mais exatidão através de Redes Neurais Artificiais a quantidade e/ou porcentagem de carne e gordura da carcaça inteira e de suas partes, como: copa, paleta e subdivisões, barriga e subdivisões (bacon e fragmentos), costela, dorso e subdivisões (carrê, e fragmentos), filé, pernil e subdivisões (parma, fragmentos, etc); enfim tantas divisões quantos forem os cortes de interesse do frigorífico, isso vai depender de sua linha de produtos.

Entretanto ao se usar a tipificação eletrônica usando Inteligência artificial apenas como meio de bonificar carcaças significa ignorar todo o potencial de uma tecnologia acessível, que não foi criada apenas para essa finalidade. (E com uma melhor classificação através da tipificação oferecer destino diversificado de modo que um mesmo produto possa ser lançado ao mercado com diferentes especificações, modificando dessa forma a estratégia de marketing, onde a linha “light”, “presunto light de suínos”, “copa light de suínos”, “bacon light de suínos”, etc.), passa a figurar como mais uma das opções de comercialização, independente da linhagem que provém a carcaça. Em se tratando de especificações, haverá necessidade de oferecer garantias, que atendam as leis em defesa do consumidor. E isto o Programa Matlab através das Redes Neurais Artificiais tem feito muito bem, sendo superior ao que atualmente tem sido utilizado. Uma vez que todo esse processo se baseia em predições é necessário que este trabalho de tese de sua contribuição sendo defendido para que possam ser satisfeitas tais reivindicações.

Também pretende-se verificar se o modelo proposto, uma RNA direta irá mostrar-se superior ao método até então utilizado (Mínimos quadrados), e se é mais fácil de se implementar.

A obtenção da equação de regressão, pelo critério dos mínimos quadrados, depende de um entendimento profundo do problema, além de poder ter alta complexidade, dependendo do número de variáveis consideradas.

Outro fator que se espera comprovar favorável às RNAs é que está relacionado com o fato de não haver para estas grande limitação no número de variáveis de entrada.

Uma rede é capaz de extrair automaticamente as características necessárias para representar a informação fornecida através dos exemplos. Porém, deve-se ter cuidado na preparação do conjunto de treinamento, na definição da arquitetura da rede, na definição dos parâmetros do algoritmo de treinamento e principalmente, na escolha das medidas de desempenho que serão utilizadas para medir e comparar o resultado da rede com o de outros métodos.

A arquitetura direta, totalmente conectada, será utilizada na resolução do problema por ser a mais indicada para predição. Outro tipo de rede, o modelo RBF, também utilizado para predição, apesar de convergir mais rápido para uma solução ótima e ser mais fácil de ajustar que o modelo MLP, não será utilizado por apresentar perdas em termos de generalização.

Dois fatores que serão decisivos para o sucesso deste trabalho: A escolha da arquitetura da rede com base no resultado das várias medidas de exatidão utilizadas, e não, com base no erro minimizado obtido durante o treinamento; E a montagem do conjunto de treinamento através da aleatorização dos dados disponíveis, o que garantirá que padrões não importantes para a resolução do problema não serão aprendidos pela rede, e assim sendo mais uma vez ficará comprovado de que a Inteligência artificial através das redes neurais dentro do software Matlab será uma ferramenta cientificamente comprovada e eficiente nas resoluções de problemas não lineares, o que trará mais um benefício para todos nós.

“Apesar de terem sido pesquisados e simuladas várias topologias de Redes, dada a vasta gama de alternativas e de técnicas disponíveis no campo das RNs, ainda há espaço para pesquisas futuras, tais quais a experimentação com diferentes combinações de topologia e algoritmo de treinamento através de uma amostra maior de dados, já que o paradigma conexionista é totalmente baseado em dados. Obtendo uma amostra maior, poder-se-ia re-treinar a rede em busca de melhores resultados. Poder-se-ia também, testar outras variações dos algoritmos de treinamento de retropropagação como os algoritmos Quickprop, Levenberg-Marquardt, Momentum de Segunda Ordem, Newton e Rprop.

No entanto se os resultados que se pretende alcançar forem satisfatórios, demonstrando melhor desempenho dos atualmente utilizados, e sendo assim veremos

mais uma vez a Ciência da Computação através da aplicação de Redes Neurais Artificiais (Inteligência Artificial) do software Matlab, proporcionando melhorias de produtos resultados e de qualidade de vida.

## **1.2 Objetivos da Pesquisa**

### **1.2.1 Objetivo Geral**

Propor, validar e verificar um modelo de Rede Neural Artificial (RNA) para tipificação de carcaças de suíno, comparando-as com os modelos estatísticos já existentes e verificar qual o mais eficiente.

### **1.2.2 Objetivos Específicos**

- Verificar como a tipificação de carcaças de suínos é realizada atualmente;
- avaliar os modelos estatísticos utilizados atualmente para a tipificação de carcaças;
- analisar os dados que poderão ser utilizados na modelagem da rede neural artificial;
- propor um modelo de redes neurais artificiais para o resolução do problema em questão;
- comparar o desempenho do modelo de redes neurais artificial proposto, em termos de: convergência, generalização e escalabilidade, com o desempenho do método de tipificação de carcaças de suínos mínimos quadrados, atualmente utilizado;
- levantar os aspectos positivos e negativos do modelo para a tipificação de carcaça de suínos;

- fazer recomendações, sugestões e proposições mediante os estudos realizados;
- e sugerir se for o caso trabalhos futuros a serem desenvolvidos na mesma área ou em áreas correlatas.

### **1.3 Organização do Trabalho**

O restante desta dissertação está estruturada da seguinte forma:

No Capítulo 2 são explanados os meios atualmente utilizados na tipificação de carcaças de suínos, bem como a composição do suíno num todo e em partes, as fórmulas e cálculos aplicados até o momento para estabelecer as especificações do animal, tabelas e índices de bonificações, os ajustes entre carne de carcaças quentes e carcaças frias, correções de erros, equações de predição de peso, quantidade de carne e gordura, e aspectos com a representatividade da amostra de carcaças dissecadas, isto no Brasil e em outros países.

Ou seja, é trazido á tona o conhecimento ou o que se têm, e o que se está utilizando até então para se tratar do problema.

No Capítulo 3 descreve os conceitos básicos de Redes Neurais Artificiais, seus principias componentes, classificação, topologias, disposições de dos neurônios e seus processos de aprendizagem.

O Capítulo 4 por sua vez descreve o estudo de caso realizado, bem como os dados coletados, a proposição do modelo e sua avaliação, bem como os resultados obtidos através do estudo.

E para finalizar vem no Capítulo 5 a conclusão, onde se faz um comentário dos fatos bem como recomendações para trabalhos futuros.

## **CAPÍTULO 2 – A TIPIFICAÇÃO DE CARÇAÇAS DE SUÍNOS ATUALMENTE**

Segundo Guidoni, a suinocultura industrial vem melhorando continuamente a qualidade de seus produtos, apesar de sua convivência com o teor de gordura nas carcaças, relutância que está diminuindo mas sem previsões para a estabilidade, devido a variabilidade intrínseca dos fenômenos biológicos que continuará existindo. A estratégia industrial, além de oferecer produtos naturais, tem sido a criação de cortes especiais, alimentos semipreparados, lançamento de produtos industrializados, etc.

Entretanto alternativas ainda poderão ser oferecidas, como: lançar um mesmo produto, natural ou industrializado, com diferentes especificações de carne ou gordura, com opções de qualidade variada para o consumidor e com isso agregar maiores lucros à atividade. Uma vantagem dessa diversificação é que ela poderá ser implementada sem grandes aumentos nos custos do sistema industrial tradicional já implantado, desde que ele contenha um processo adequado de tipificação de carcaças.

Com isso é possível, no momento da tipificação, predizer a quantidade e/ou porcentagem de carne e gordura da carcaça inteira resfriada e de suas partes, como: copa, paleta e subdivisões, barriga e subdivisões (bacon e fragmentos), costela, dorso e subdivisões (carrê, e fragmentos), filé, pernil e subdivisões (parma, fragmentos, etc); enfim tantas divisões quantos forem os cortes de interesse do frigorífico, isso vai depender de sua linha de produtos.

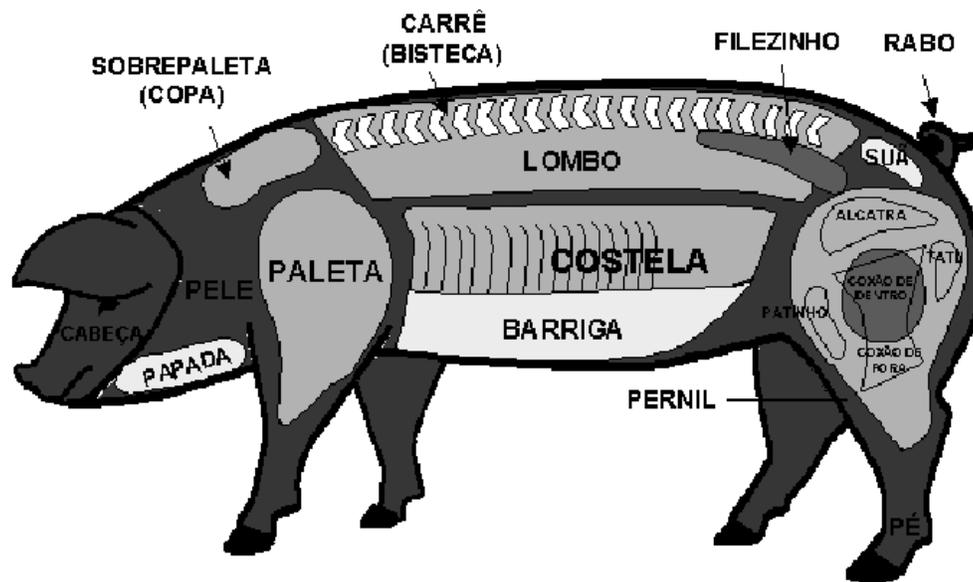


Figura 1.1 — Divisão de carcaça de suínos com possibilidades de especificação antecipada na linha de abate do peso e % de carne ou gordura da carcaça inteira e de suas partes. A figura 1.1 ilustra o que é possível antecipar na linha de abate, para facilitar o destino industrial.

Apesar da tipificação eletrônica de carcaças de suínos no Brasil ter sido adaptada de outros países (Irgang, 1996), ela é uma realidade apenas nos frigoríficos de médio e grande porte, mas usada principalmente para a compra do suíno vivo (Guidoni, 1999). Entretanto ao se usar a tipificação eletrônica apenas como meio de bonificar carcaças significa ignorar todo o potencial de uma tecnologia acessível, que não foi criada apenas para essa finalidade. (Com uma dissecação de carcaças realizada a priori pode-se selecionar carcaças quentes, ainda na linha de abate, e oferecer destino diversificado de modo que um mesmo produto possa ser lançado ao mercado com diferentes especificações, modificando dessa forma a estratégia de marketing, onde a linha “*light*”, “presunto *light* de suínos”, “copa *light* de suínos”, “bacon *light* de suínos”, etc.), passa a figurar como mais uma das opções de comercialização, independente da linhagem que provém a carcaça. Em se tratando de especificações 2, haverá necessidade de oferecer garantias, que atendam as leis em defesa do consumidor. Uma vez que todo esse

processo se baseia em predições é necessário planejar uma dissecação de carcaças que possa satisfazer tal reivindicação. Dessa forma, a tipificação pode ser usada com duas finalidades:

- Para auxiliar na comercialização de suínos entre produtores e frigoríficos que praticam a bonificação;
- Para garantir ao consumidor especificações diferenciadas de cortes e produtos de suínos.

### **2.1 Avaliação e tipificação de carcaças de suínos.**

Segundo Irgang a tipificação de carcaças de suínos é um processo de classificação com três objetivos principais: bonificar o produtor de suínos que fornece carcaças com maior rendimento e melhor qualidade de carne para a indústria frigorífica; selecionar as carcaças, destinando-as para melhor aproveitamento industrial; e, padronizar os produtos para atender as exigências dos consumidores.

Dependendo do processo de tipificação, incluem-se como qualidade de carcaça o rendimento ou a quantidade de carne na carcaça, a qualidade visual, as medidas de tamanho da carcaça, e a qualidade da carne, principalmente quanto a cor, pH e capacidade e retenção de água. Nesse último critério, são consideradas indesejáveis para a indústria frigorífica as carcaças com carne pálida, mole e exudativa (PSE).

A tipificação de carcaças de suínos foi instituída oficialmente no Brasil pelo Ministério da Agricultura em 1981 Correio do Povo, 1981. A classificação de carcaças suínas foi utilizada inicialmente pela Cooperativa Central Oeste Catarinense, Chapecó, SC., e, a seguir, por outros abatedouros de suínos da região Sul. Antes disso, em 1965, foi desenvolvido o Método Brasileiro de Classificação de Carcaças MBCC, Associação Brasileira de Criadores de Suínos, 1973. Os dois métodos baseiam-se em medidas objetivas da carcaça. No primeiro, obtêm-se o peso da carcaça e a espessura de toucinho subcutâneo, utilizando-se as medidas em uma tabela para definição do índice de classificação das carcaças. O MBCC consiste em medir a espessura de toucinho em diferentes locais da carcaça, o comprimento corporal, a área de lombo do músculo *Longissimus dorsi* e a cobertura de gordura, e em pesar o pernil. Pela complexidade das

medidas e tempo necessário para sua obtenção, o MBCC não tem sido utilizado para tipificar carcaças.

A tipificação das carcaças é; um dos instrumentos mais importantes para que a suinocultura brasileira alcance um dos seus principais objetivos, que é o de aumentar o rendimento de carne nas carcaças.

Isso dependerá da capacidade de se substituir grande parte da gordura presente nas carcaças por carne de boa qualidade. A qualidade genética dos reprodutores em uso nos plantéis, os níveis nutricionais e sistemas de alimentação utilizados na criação, e os índices de bonificação de carcaça recebidos pelos produtores de suínos, terão uma função definitiva no alcance desse objetivo.

A tipificação de carcaças tem sido motivo de muitas reuniões entre criadores, técnicos em suinocultura, governo e indústrias frigoríficas, mas foi a tomada de decisão pelas indústrias que tornou o processo uma realidade. Certamente para a suinocultura, os últimos anos deste século XXI serão marcados pela tipificação de carcaças. Espera-se que seus aspectos favoráveis alcancem também os consumidores de carne suína.

A seguir são discutidos alguns detalhes da tipificação e classificação de carcaças suínas, com ênfase no aumento do rendimento de carne nas carcaças.

## **2.2 A Composição da Carcaça dos Suínos**

Os suínos são compostos de partes industrializáveis e úteis para o consumo humano, e por órgãos que lhes dão sustentação e condições para se desenvolverem, nem todos comestíveis. É interessante observar, porém, que muitos consumidores e até produtores de suínos imaginam que a carcaça seja formada apenas por carne e gordura, induzidos, talvez, pelo fato de que a carne seja o principal componente aproveitável, e de que a gordura deva ser eliminada ao máximo de sua dieta alimentar (Uttaro, 1995) utilizaram as informações de carcaça de um suíno com 105 Kg de peso vivo, para ilustrar a composição dos animais (Tabela 1.1).

Tabela 1.1 - Composição da carcaça de um suíno abatido com 105 kg de peso vivo.

<b>Parte</b>		<b>Kg</b>	<b>KG</b>	<b>%</b>
Suíno vivo		105,0	105,0	100,0
Carcaça quente		83,1	83,1	79,1
Carcaça fria		74,6	74,6	71,0
Cabeça		5,9		
Rins		0,3		
Unto		1,0		
Perda umidade		1,3	8,5	8,1
Perdas	Intestino, Urina, Estômago, etc	11,3	11,3	10,8
Produtos Comestíveis	Fígado Coração Outros	1,9 0,4 2,1	4,4	4,2
Produtos não Comestíveis	Esôfago Pêlos Sangue Glândulas Estômago Pulmão Outros	0,3 0,4 3,3 0,1 0,6 1,4 0,1	6,2	5,9
Cortes Comerciais	Pernil, carne Lombo, carne Barriga, carne Paleta, carne Copa	12,8 11,4 7,2 5,5 5,1	42,0	40,0
Outros	Maxilar Ossos Ps, patas	3,0 7,0 2,3		

	Membros ant.	2,2		
	Rabo	0,2	32,6	31,0
	Pele	4,5		
	Gordura	5,3		
	Costelas	3,7		
	Retalhos	4,4		
	<b>Total</b>	<b>105,0</b>		<b>100,0</b>

*Fonte: Uttaro e Ball, 1995.*

Verifica-se no exemplo da Tabela 1.1 que apenas 40% do suíno vivo constituído de carne, o que representa 50,54% do peso da carcaça quente, 56,30% do peso da carcaça fria, após a remoção da cabeça, rins, gordura perirenal e perda de umidade durante a refrigeração.

Um breve panorama do rendimento de carne na suinocultura brasileira.

As estimativas de rendimento de carne em carcaças de suínos abatidos no Brasil ainda são raras. Em um trabalho de dissecação de carcaças de suínos criados em 1980, e que pesaram vivos em média 80,5; 102,8; 122,9; e 143,2Kg, (Irgang, 1986) obtiveram, respectivamente, 48,8; 46,3; 44,6 e 43,4% de rendimento de carne em relação ao peso da carcaça fria, sem cabeça, e 36,3; 35,2; 34,8; e 34,6% em relação ao peso vivo dos animais.

Estimativas mais recentes, de suínos abatidos com peso vivo entre 90 e 100 kg, indicam rendimentos médios de carne entre 49 e 50% em 1990, e de 52% em 1995, em relação ao peso da carcaça quente. Isto demonstra um progresso razoável na composição das carcaças, especialmente nos últimos cinco anos, resultante de melhorias de genótipos e de nutrição dos animais, e que tem permitido um melhor aproveitamento industrial dos animais.

No entanto, amostras de carcaças de abatedouros indicam que o país precisa percorrer ainda um longo caminho até atingir um nível alto de rendimento de carne. Na Tabela 1.2 são apresentadas a distribuição de carcaças com 60 a 80 kg de peso quente de uma amostra de suínos abatidos em um frigorífico em Junho de 1995, com respeito à espessura de toucinho.

Tabela 1.2 - Frequência de carcaças de suínos com peso quente de 60 a 80 kg em um abatedouro, no mês de Junho de 1995, com respeito à espessura de toucinho.

Espessura de toucinho, mm	Número de carcaças	Frequência de carcaças (%)
10-14	740	6,8
15-19	2.719	25,0
20-24	3.537	32,5
25-29	2.120	19,5
30-34	1.105	10,1
35-39	413	3,8
40-50	263	2,4
Total	10.897	100,0

*Fonte: Irgang 1996, dados não publicados.*

Verifica-se na Tabela 1.2 que, se por um lado há um percentual de carcaças excelentes, com espessura de toucinho inferior a 15 mm, que apresentam alto rendimento de carne, em torno de 57 a 58% Irgang e Guidoni, 1996, há um percentual similar de carcaças de baixa qualidade, com 40 a 50 mm de espessura de toucinho e rendimento de carne inferior a 40%. A espessura de toucinho média situa-se entre 20 e 24 mm, havendo uma boa tendência para carcaças com espessura de toucinho entre 15 a 19 mm, que apresentam aproximadamente 54 a 55% de carne, considerado bastante razoável.

Na Inglaterra, em 1994, 29,0% das carcaças de suínos apresentam 60% ou mais de carne na carcaça, 56,9% dos suínos abatidos apresentam entre 55 e 59% de carne na carcaça, 12,3% apresentaram entre 50 e 54% de rendimentos de carne, e apenas 1,7% dos suínos abatidos apresentaram menos de 50% de carne na carcaça Meat and Livestock Commission, 1995; na Dinamarca, segundo o Dansk e Slagterier 1993, apenas em torno de 10% dos suínos abatidos em 1992 apresentaram rendimento de carne igual ou inferior a 55% e 90% das carcaças apresentaram 56% a mais de carne nas carcaças.

Para o Brasil, portanto, é fundamental aumentar rapidamente o rendimento de carne na carcaça dos suínos. A maior eficiência de produção e o custo mais baixo de carne de frango, que tem levado a grande maioria da população a optar pelo consumo daquele produto, a existência de tabus na população quanto aos problemas sanitários da carne suína, e as contínuas recomendações de que a carne de suínos faz mal a saúde humana, são razões adicionais que justificam se intensificar a produção de suínos com maior rendimento de carne.

### 2.3 A Tipificação de Carcaças de Suínos no Brasil

As primeiras tipificações foram feitas pela Cooperativa Central Oeste Catarinense, Chapecó, e baseavam-se no peso da carcaça e medida da espessura de toucinho, feita com régua milimétrica. Este processo foi utilizado também, temporariamente, por outras indústrias frigoríficas. Com as duas medidas, as carcaças passavam a ser classificadas, utilizando-se índices de bonificação Tabela 2.1, semelhante ao apresentado na Tabela 1.3.

Tabela 1.3 – Peso da carcaça quente em kg

Esp. Touc. Mm	50-54	55-59	60-64	65-69	70-74	75-79	80-89	90 e +
At 14	100	105	110	113	112	110	107	104
15-19	100	104	108	110	109	108	106	101
20-24	99	102	106	108	107	106	103	100
25-29	98	100	103	104	105	104	100	99
30-34	96	98	100	100	102	100	99	98
35-39	93	94	97	98	99	99	98	97
40-44	88	91	92	93	94	93	93	92
45-49	86	88	89	90	91	92	90	88
50 e +	84	85	87	87	87	86	85	85

Fonte: Emater / Acaresc – Serviço de Extensão Rural. “Tipificação de Carcaças”.

A classificação de carcaças pela Tabela 1.3 foi bastante utilizada no passado. A tabela sugeria bonificação de até 12 a 13% para carcaças com peso quente de 65 a 74 Kg, com máximo de 14 mm de espessura de toucinho, e bonificação inclusive para carcaças com 30 a 34 mm de espessura de toucinho, 70 a 74 Kg de carcaça quente. A tabela sugeria também que carcaças leves (menos de 55Kg) ou mais de 30 mm de espessura de toucinho, não deveriam receber bonificação, ou então, que deveriam ser penalizadas.

Certamente o critério de classificação utilizado na tabela em questão se relacionava com o rendimento de carne na carcaça.

A tipificação de carcaças de suínos no Brasil é feita independente e variada pelas indústrias. Algumas das características em comum são as tipificações das carcaças sem a cabeça, pés, e patas. O processo inicia pelo jejum dos animais na granja, seguido da identificação do criador por meio de tatuagem dos animais, feita ou no momento do carregamento dos animais na granja, ou no momento do descarregamento, no abatedouro.

Após o descanso no abatedouro, segue-se a sangria, depilação e evisceração das carcaças, corte da cabeça, separação da carcaça ao meio, medida da espessura do toucinho e profundidade de lombo, e pesagem das duas meias-carcaças.

Nos casos em que se dispõem de equipamentos como as pistolas eletrônicas, com sensores óticos para a tomada das medidas de espessura de toucinho e de profundidade de lombo e de um processo automatizado para cálculo do rendimento estimado de carne, as carcaças são classificadas imediatamente após sua pesagem, podendo ser destinadas para diferentes câmaras de resfriamento.

A tipificação das carcaças, com índices de bonificação pode ser definida a partir dos valores de rendimento estimado de carne. No exemplo da Tabela 1.4, sugere-se bonificar principalmente as carcaças com mais de 50% de carne, com índices maiores para carcaças mais pesadas, e desestimular a produção de carcaças pesadas, com menos de 48% de carne. Nesse caso, o critério de tipificação consiste no fato de que carcaças

mais pesadas, com alto rendimento de carne, proporcionam maior volume de carne por unidade de abate, e menores custos de processamento industrial, do que carcaças mais leves, enquanto que carcaças mais pesadas, com baixo rendimento de carne, têm menor valor industrial, devido ao seu maior conteúdo de gordura, do que carcaças mais leves.

Tabela 1.4 - Modelo de tabela de tipificação de carcaças de suínos, com índices de bonificação e penalização baseados no peso da carcaça quente e no rendimento estimado de carne na carcaça.

PESO DA CARCAÇA QUENTE, Kg									
Rend. Carne %	50-55	56-60	61-65	66-70	70-75	76-80	81-85	86-90	+ 90
Mais de 56	101	103	105	110	112	112	112	114	114
53 a 56	100	101	103	104	106	108	110	112	114
50 a 52	99	100	100	101	101	102	104	106	110
48 a 49	96	98	99	100	100	100	101	102	104
46 a 47	94	94	94	94	92	92	90	90	88
Menos de 46	92	92	92	92	90	90	88	88	86

A tipificação de carcaças com régua milimétrica é uma alternativa para tipificação de carcaças quando a escala de abate é muito pequena. Em outras situações, tem se observado uso crescente de pistolas com sensores óticos.

As primeiras pistolas utilizadas no país traziam embutidas em seu “software” equações desenvolvidas na Europa para estimar rendimento de carne. Apesar de alguns abatedouros ainda utilizarem tais equações, outros tem desenvolvido equações próprias, que lavam em conta a distribuição de carcaças no abatedouro.

As pistolas permitem obter medidas de espessura de toucinho e de profundidade do músculo *Longissimus dorsi* em diferentes pontos da carcaça. A definição dos locais e do número de medidas feitas na carcaça é fundamental no processo de tipificação, tendo em vista a necessidade de utilizar-se equações que permitam estimar o rendimento de carne com a maior precisão possível.

Para conhecer as relações entre as medidas obtidas com régua milimétrica e pistolas que utilizando sensores óticos, com a quantidade e o rendimento de carne na carcaça, foram analisados dados de 25 meias-carcaças, peso quente total, sem cabeça, de 60 a 80 Kg.

As medidas de espessura de toucinho e de profundidade do músculo *Longissimus dorsi* obtidas com pistola, foram feitas lateralmente, a 6 cm de distância da linha mediana da carcaça, entre a última e a penúltima costela, e entre a 3<sup>a</sup> e 4<sup>a</sup> costelas antes da última. A espessura de toucinho medida com a régua foi tomada na altura da última costela. A quantidade de carne, gordura, ossos e pele foram obtidos por dissecação mecânica das meias-carcaças esquerdas. Os resultados são apresentados na Tabela 1.5.

Tabela 1.5 - Correlações entre peso de carcaça, espessura de toucinho e profundidade de músculo, medidas com régua e com pistola, entre a última e a penúltima costela, e entre a 3<sup>a</sup> e 4<sup>a</sup> costelas antes da última, com a quantidade e o rendimento de carne, gordura, ossos e pele dissecados de 25 carcaças com 60 a 80 kg.

		Peso carc.	ETrgua	ETupc	ET34c	PMupc	PM34c
Carne	Kg %	0,43*	-0,38 <sup>+</sup>	-0,57 **	-0,48 **	0,67 **	0,63 **
		-0,22 <sup>ns</sup>	-0,75 ***	-0,91 ***	-0,84 ***	0,46 *	0,56 **
Gordura	Kg %	0,56 **	0,86 ***	0,95 ***	0,93 ***	-0,16 <sup>ns</sup>	-0,36 <sup>+</sup>
		0,23 <sup>ns</sup>	0,82 ***	0,94 ***	0,88 ***	-0,36 <sup>+</sup>	-0,49 *
Ossos	Kg %	0,38 <sup>+</sup>	-0,33 <sup>+</sup>	-0,48 *	-0,37 <sup>+</sup>	0,21 <sup>ns</sup>	0,11 <sup>ns</sup>
		-0,28 <sup>ns</sup>	-0,65 ***	-0,75 ***	-0,68 ***	-0,09 <sup>ns</sup>	-0,02 <sup>ns</sup>
Pele	Kg %	0,49 *	0,21 <sup>ns</sup>	0,36 <sup>+</sup>	0,38 <sup>+</sup>	-0,04 <sup>ns</sup>	0,17 <sup>ns</sup>
		-0,12 <sup>ns</sup>	-0,11 <sup>ns</sup>	0,10 <sup>ns</sup>	0,09 <sup>ns</sup>	-0,30 <sup>ns</sup>	-0,30 <sup>ns</sup>

Fonte: Irgang e Guidoni, 1996.

Etrégua: espessura do toucinho medida com régua milimétrica.

Etup, Pmupc, ET34c e PM34c: respectivamente, espessura de toucinho e profundidade de músculo entre a última e a penúltima e entre a 3<sup>a</sup> e a 4<sup>a</sup> costelas antes da última.

<sup>ns</sup>, <sup>+</sup>, \*, \*\*, \*\*\*: respectivamente não significativo, P 0, 10, P 0, 05, P 0,01 e P0,001.

Verifica-se na Tabela 1.5 que as quantidades de carne, gordura, pele e ossos aumentam com o peso da carcaça. O coeficiente de correlação estimado entre a quantidade de gordura e o peso da carcaça é maior do que a estimativa entre a quantidade de carne e o peso da carcaça. Já as proporções de carne, ossos e pele diminuem enquanto que a proporção de gordura aumenta com o peso das carcaças.

A quantidade de carne na carcaça aumenta com a redução da espessura de toucinho e com o aumento da profundidade de músculo, enquanto que a quantidade de gordura diminui com a redução da espessura de toucinho e o aumento da profundidade de músculo. As estimativas envolvendo a quantidade de ossos na carcaça indicam que há aumento da mesma à medida que se reduz a espessura do toucinho e se aumenta a profundidade de lombo. A quantidade de pele é reduzida quando se diminui a espessura de toucinho.

As correlações entre o rendimento de carne e as medidas de espessura de toucinho são altamente negativas. As correlações calculadas com os dados obtidos com a régua milimétrica são menores do que as correlações com a pistola. A medida efetuada com a pistola entre a última e a penúltima costela, porém, é a que mais se correlaciona com o rendimento de carne e com o rendimento de gordura. As estimativas de correlação entre o rendimento de carne e a profundidade de músculo são positivas, e são negativas com o rendimento de gordura, porém ambas são bem mais baixas do que as estimativas de correlação com a espessura de toucinho.

O rendimento de ossos correlaciona-se negativamente com a espessura de toucinho e com a profundidade de músculo, enquanto que o rendimento de pele apresenta associações bastante baixas com as duas medidas obtidas com a pistola.

Na Tabela 1.6 são apresentados valores de  $R^2$  e de desvio padrão residual para quantidade e rendimento de carne estimado com diferentes combinações de medidas de espessura de toucinho e profundidade de músculo obtidas com a pistola eletrônica.

Tabela 1.6 - Valores de  $R^2$  e desvio-padrão residual para quantidade e rendimento de carne na carcaça de suínos, estimados com diferentes combinações de medidas de espessura de toucinho, profundidade de músculo e peso da carcaça quente.

Medidas obtidas com a pistola eletrônica e peso da carcaça	Quantidade de carne		Rendimento de carne	
	$R^2$ (%)	DPR(%)	$R^2$ (%)	DPR(%)
ETupc	32,7	1,54	82,3	2,02
ET34c	22,6	1,65	70,7	2,61
ETupc PMupc	62,3	1,18	87,9	1,72
ET34c PA34c	49,0	1,37	82,4	2,07
ETupc PMupc Peso	86,2	0,73	87,9	1,76
ET34c PM34c Peso	83,9	0,79	82,9	2,09
ETupc ET34c PMupc	63,5	1,19	87,9	1,76
ETupc ET34c PMupc PM34c	66,3	1,17	90,7	1,58
ETupc ET34c PMupc PM34c Peso	89,4	0,67	90,7	1,58

Fonte: Irgand e Guidoni, 1996

DPR: Desvio-padrão residual

ETupc, ET34c, Pmupc e PM34c; respectivamente, espessura de toucinho e profundidade de músculo entre a última e a penúltima e entre a 3ª e a 4ª costelas antes da última.

Observa-se na Tabela 1.6 que as medidas de espessura de toucinho e profundidade de músculo efetuado com a pistola entre a última e a penúltima costela, proporcionaram maior explicação da variação do rendimento de carne ( $R^2$ ) e menor desvio-padrão residual, do que as mesmas medidas efetuadas entre a 3ª e a 4ª costelas antes da última. Maior precisão na estimativa do rendimento de carne seria possível com a realização das medidas de espessura de toucinho e profundidade de músculo nos dois locais da carcaça. A decisão entre a realização das medidas em um ponto ou nos dois pontos da carcaça depende da velocidade de deslocamento das carcaças na linha de

abate, das instalações onde se processa a tipificação, e da qualidade da mão-de-obra dos operadores da pistola.

A definição dos índices de tipificação está altamente associada ao valor econômico das carcaças. Além da participação dos cortes na composição da carcaça e da qualidade industrial da carne, a quantidade total de carne nas carcaças, ou o rendimento de carne, em conjunto com o peso da carcaça quente, e a proporção ou quantidade de gordura, são fatores importantes na valorização econômica das carcaças. Comparando-se o valor econômico da gordura de suínos (banha), estimado em R\$ 0,43 a R\$ 0,50 por Kg Instituto CEPA/SC, 1995, com o valor econômico da carne de suínos, estimado pela mesma fonte em R\$ 3,00 a 3,65 por kg, constata-se da importância de se aumentar o rendimento de carne nas carcaças de suínos. Ganhos estimados na quantidade e no rendimento de carne nas 25 carcaças, com peso quente variável de 60 a 80 kg, à medida que se diminui a espessura de toucinho em 1 mm, ou quando se aumenta a profundidade de músculo em 1 mm, são apresentados na Tabela 1.7.

Tabela 1.7 - Estimativas de aumento na quantidade e no rendimento de carne em carcaças de suínos com peso quente, sem cabeça, de 60 a 80 kg, à medida que se diminui a espessura de toucinho em 1 mm, ou se aumenta a profundidade do músculo *Longissimus dorsi* em 1 mm.

Ganho estimado em	ETupc	ET34c	PMupc	PM34c
Quantidade carne, g	322 +- 96 **	238 +- 92**	314 +- 72****	476 ae 124****
Rendimento carne, %	0,66 +- 0,06**	0,54 +- 0,07**	0,27 +- 0,11*	0,55 ae 0,17**

Fonte: Irgang e Guidoni, 1996.

Etupc, ET34c, Pmupc e PM34c: respectivamente, espessura de toucinho e profundidade de músculo entre a última e a penúltima e entre a 3<sup>a</sup>. e a 4<sup>a</sup>. costelas antes da última

As estimativas apresentadas na Tabela 1.6 indicam que para cada 1 mm a menos de deposição de gordura subcutânea, em carcaças de suínos com peso quente, sem cabeça, entre 60 e 80 kg, obtêm-se um aumento de 238 ou 322 g na quantidade de carne na carcaça, ou um aumento de 0,54 a 0,66% no rendimento de carne, dependendo do

local da carcaça onde for feita a medida. Estes valores são semelhantes aos obtidos por Mcphee 1977, que estimou que a substituição de 1 kg de gordura por 1 kg de carne na carcaça é equivalente a uma redução de 3,6 mm na espessura de toucinho.

## **2.4 A Tipificação de Carcaças de Suínos em Outros Países**

### **A) Tipificação de Carcaças de Suínos na Dinamarca**

A Dinamarca produz aproximadamente 18 milhões de suínos por ano, em pouco mais de 25.000 granjas, em um sistema totalmente cooperativo.

O sistema de tipificação inclui todos os animais abatidos no país, e se baseia em medidas de ultra-sonografia em 14 pontos diferentes da carcaça, proporcionando grande precisão na estimativa do rendimento de carne nas carcaças.

Segundo Roach 1993, o ponto de decisão para bonificação ou penalização das carcaças situa-se em 59% de rendimento de carne na carcaça. Para cada 1 ponto percentual acima de 59% de carne, os produtores recebem o equivalente a 1% a mais por kg de carcaça até 65% de rendimento de carne, e um desconto equivalente para carcaças com menos de 59% de carne.

Conforme Daumas 1995, a Dinamarca é um dos países que mais evoluiu na melhoria do rendimento de carne em carcaças de suínos. Em 1988, a média situava-se em 55,59% em 1989, em 57,84% em 1989, em 58,50% em 1990, em 59,00% em 1991, em 59,40% em 1992, e em 59,8% em 1993, ou seja, mais de 2% no período.

### **B) Tipificação de Carcaças de Suínos na Inglaterra**

O *Meat and Livestock Commission* (MLC) classificou 10,3 milhões de carcaças de suínos em 1994, o que representou 72,3% dos abates efetuados na Inglaterra naquela

ano. Quatro métodos de tipificação de carcaças são aprovados pelo MLC, os quais variam, basicamente, em relação à distância da linha dorsal mediana da carcaça onde deve ser feita a medida de espessura de toucinho e de profundidade de músculo Meat and livestock Commuission, 1995. As carcaças são tipificadas inteiras, com cabeça. Entre os equipamentos aprovados encontram-se os “*optical probes*”, utilizados para medir apenas a espessura de toucinho nos pontos P1 E P3, ou P2, na altura da cabeça da última costela, as pistolas eletrônicas “Fat-O-Meater” ou “*Hennessy Grading Probe*”, utilizadas para medir a espessura de toucinho na altura da cabeça da última costela, e para medir a espessura de toucinho e a profundidade do músculo *Longissimus dorsi*, entre a 3<sup>a</sup>. e 4<sup>a</sup>. costelas antes da última (Figura 2.1), e equipamentos baseados em medidas de ultra-som, mas não utilizados até 1995.

O MLC recomenda os seguintes passos na classificação de carcaças:

- Identificação da carcaça.
- Verificação do método de preparo da carcaça para dissecação.
- Pesagem correta da carcaça, levando em conta o intervalo de tempo entre a sangria e a pesagem da carcaça.
- Uso de equipamento adequado para medir espessura de toucinho e profundidade de lombo, e tomada das medidas por operadores rigorosamente treinados.
- Cálculo do rendimento estimado de carne na carcaça, ou da classificação da carcaça conforme procedimentos europeus (Tabela 1.8), no documento apropriado, ou nas carcaças exportadas para outros países da Comunidade Européia.
- Avaliação visual da carcaça para defeitos e conformação.
- Identificação de carcaças de machos inteiros.
- Informação, ao produtor dos índices de tipificação de carcaça de seus animais.

Tabela 1.8 - Classificação de carcaças utilizada na Comunidade Européia, e distribuição das carcaças de suínos classificadas pelo MLC, Inglaterra, 1994.

Classe de carcaça	Rendimento de carne, %	Distribuição das carcaça
S	60 e mais	29,0
E	55-59	56,9
U	50-54	12,3
R	45-49	1,4
O	40-44	0,2
P	Menos de 40	0,1

Fonte: *Meat and Livestock Commission*, 1995.

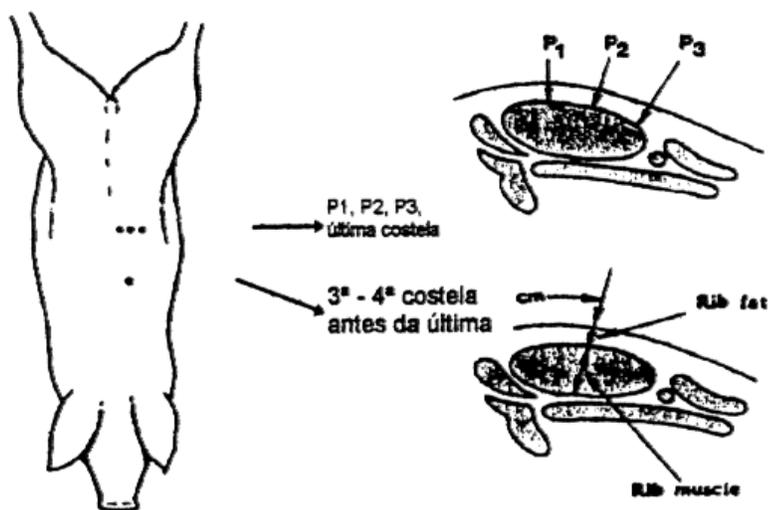


Figura 2.1 – Locais das medidas de espessura de toucinho e profundidade de músculo *Longissimus dorsi* utilizadas pelo MLC na Inglaterra (Adaptado de *Meat and Livestock Commission*, 1995).

### C) Tipificação de Carcaças de Suínos na Holanda

A Holanda tem apresentado um aumento contínuo no rendimento de carne na carcaça dos suínos nos últimos anos. Dados compilados por (Daumas 1995) indicam aumento de 2 pontos percentuais no período de 1988 a 1993, tendo partido de 53,1% e alcançado 55,1% no último ano.

A classificação de carcaças na Holanda baseia-se em uma única medida de espessura de toucinho e de profundidade de músculo, entre a 3<sup>a</sup> e a 4<sup>a</sup> costelas antes da última, a 6 cm da linha mediana dorsal, com pistola eletrônica, e na avaliação visual da conformação da carcaça (Hulsegge, Sterrenburg & Merkus, 1994). Há porém, um interesse crescente em se definir um método para selecionar os cortes principais (paleta, pernil, lombo e barriga), baseado no seu rendimento estimado de carne.

Os autores mencionados realizaram um estudo com 200 meias-carcaças e 50 carcaças inteiras, dissecadas, com o objetivo de determinar a precisão de preditores simples e múltiplos na estimativa do rendimento de carne na carcaça e nos cortes principais. Os resultados são apresentados na Tabela 1.9.

Tabela 1.9 - Valores estimados do desvio-padrão residual e erros-padrão, em g/kg de carne, obtidos pela regressão da proporção de carne na carcaça e nos cortes principais, em um ou mais locais de medidas na carcaça.

Corte	1 local de medida		2 locais de medida		3 locais de medida		4 locais de medida	
	DPR	EP	DPR	EP	DPR	EP	DPR	EP
Carcaça	21,8	1,4	20,9	1,4	20,4	1,4	20,1	1,4
Pernil	21,7	1,1	20,5	1,0	19,7	1,0	19,3	1,0
Paleta	23,2	1,2	22,3	1,1	21,8	1,1	21,5	1,1
Lombo	24,2	1,2	23,9	1,2	23,6	1,2	23,5	1,2
Barriga	32,7	1,6	31,4	1,6	30,5	1,3	29,9	1,3

Fonte: Hulsegge et al., 1994.

As fórmulas para estimar rendimento de carne em carcaças de suínos são aprovadas pela Comunidade Européia quando o desvio-padrão residual é inferior a 25 g por kg. No estudo conduzido por (Hulsegge Sterrenburg & Merkus 1994), verificou-se que, com medidas feitas em apenas um local da carcaça, a estimativa para o rendimento de carne na carcaça e em todos os principais cortes, com exceção da barriga, proporcionou desvios-padrão residuais inferiores a 25 g/kg. As medidas que proporcionaram estes resultados foram feitas entre a 13<sup>a</sup> e a 14<sup>a</sup> costelas.

Os autores concluíram que medidas de espessura de toucinho e de profundidade de músculo feitas em apenas um local podem proporcionar estimativas adequadas da proporção de carne na carcaça, bem como nos principais cortes industriais.

#### **D) Tipificação de Carcaças de Suínos na Espanha**

A classificação comercial de carcaças de suínos na Espanha tem se baseado nos padrões de classificação e tipificação de carcaça da Comunidade Européia, que contemplava, além de medidas objetivas, medidas subjetivas de conformação da carcaça (Diestre, Gispert e Oliver, 1989).

A distribuição nacional de carcaças por classes de espessura de toucinho na Espanha era a seguinte em 1986 (Tabela 1.10).

Tabela 1.10 - Distribuição da freqüência de carcaças de suínos, na Espanha por classe de espessura de toucinho, em 1986.

<b>Espessura de toucinho (mm)</b>	<b>Freqüência de carcaças (%)</b>
<10	1
10 a 15	24
15 a 20	47
20 a 25	21
>25	6

*Fonte: Diestre, Oliver e Gispert, 1987.*

Os autores mencionados desenvolveram um estudo para calcular a precisão de medidas de espessura de toucinho obtidas na altura da última costela e entre a 3<sup>a</sup> e a 4<sup>a</sup> costela antes da última, e da profundidade de músculo nesta última posição, todas a 6 cm da linha dorsal mediana da carcaça. Foram utilizados três equipamentos, além de medidas feitas com régua no mesmo local de inserção dos equipamentos (Tabela 1.11).

Tabela 1.11 - Desvios-padrão residuais para a predição da proporção de carne na carcaça, em g/kg, com uso da régua e com equipamentos automáticos.

Preditores	Manual com régua	Equipamentos automáticos		
		Fat-o-Meater	Hennesy	Destron GP
ET, última costela (1)	23,8	29,7	29,0	30,6
ET, 3 <sup>a</sup> - 4 <sup>a</sup> costela antes última (2)	28,2	29,1	29,5	25,3
PM, 3 <sup>a</sup> - 4 <sup>a</sup> costela antes última (3)	40,5	41,2	41,8	42,7
(2) + (3)	25,7	24,8	26,3	23,1
(1) + (2) + (3)	21,3	22,3	24,5	22,5

Fonte: Diestre, Gispert e Oliver, 1989.

ET = Espessura de toucinho; PM = Profundidade de músculo.

Os valores de desvio-padrão residuais obtidos com os três equipamentos e com a medida manual foram todos menores do que 25 g/kg, sendo atualmente os três equipamentos e as medidas (1), (2) e (3) da Tabela 1.11, recomendados para coletar informações para estimar rendimento de carne na Espanha.

### E) Tipificação de Carcaças de Suínos na França

A classificação objetiva de carcaças de suínos é praticada na França desde 1986 (Daumas, 1986). A primeira fase da tipificação baseava-se em equações com três preditores e dois pontos de medida nas carcaças, e durou até 1993. Na Segunda fase, as equações levavam em conta dois preditores medidos em um único local da carcaça. Na

Tabela 1.12 são apresentados valores médios e desvios-padrão para as diferentes medidas e rendimentos de carne obtidos nas dissecações efetuadas em diferentes anos.

Tabela 1.12 - Peso das carcaças, espessura de toucinho, profundidade de músculo e rendimentos médios de carne obtidos em dissecações de carcaças efetuadas em diferentes épocas na França.

	1982 (n = 344)		1987 (n = 168)		1990 (n = 32)		
	Média	D.P.	Média	D.P.	Mé dia	Mínimo	Máximo
Carcaça quente, kg*	84,0	8,1	82,8	5,5	39,9	31,0	46,6
ET, ¾ costela, 8 cm, mm	26,5	6,4	19,6	4,5	-	-	-
ET, ¾ costela, 6cm.mm	23,2	5,7	18,2	4,5	16,8	10	25
PM ¾ costela, 6cm,mm **	54,5	7,6	81,3	-	52,7	42	62
Carne dissecada, %	48,9	5,7	51,4	4,6	53,8	43,7	62,1
Carne estimada, %	48,9	5,3	51,4	-	54,2	46,7	60,0

Fonte: Daumas e Dhorme, 1986.

\* Em 1990, representa o peso de uma meia-carcaça.

\*\* Em 1987 representa a espessura total da carcaça.

ET = espessura de toucinho; PM = Profundidade de músculo.

A partir do segundo semestre de 1986, uma nova fase será iniciada, com equações para fêmeas e para machos castrados, que serão calculadas a partir da dissecação dos quatro principais cortes comerciais de aproximadamente 300 a 400 carcaças de cada sexo. Essa metodologia deverá resultar num referencial de rendimento de carne diferente daquele obtido para a carcaça inteira.

O objetivo dos franceses, segundo (Daumas 1986), é o de utilizar um método que contribua para a harmonização dos métodos de tipificação utilizados na Europa, e que proporcione maior precisão das estimativas.

## F) Tipificação de Carcaças de Suínos no Canadá

O sistema de tipificação de carcaças de suínos do Canadá evoluiu de medidas de espessura de toucinho feitas manualmente na paleta e lombo (Canadian Pork Council, 1979), para o uso de equipamentos que utilizam refletância de luz, com medidas de espessura de toucinho e de profundidade de músculo feitas entre a 3ª e a 4ª costelas antes da última (Sather et al., 1991 b).

(Sather et al. 1991) avaliaram o efeito de raça e de sexo em medidas de carcaça e de rendimento de carne. Alguns de seus resultados são apresentados na Tabela 1.13.

Tabela 1.13 - Efeito de raça e de sexo em medidas de carcaça e de rendimento de carne (médias e erros-padrão).

Medida comercial	Raça			Sexo		
	Lacombe	Yorkshire	N.S.	Castrados	Fêmeas	N.S.
Carcaça quente kg	80,8+/- 0,43	80,7+/-0,49	0,82	81,1 ae 0,41	80,4+/-0,51	0,28
Espessura toucinho,mm	20,8+/-0,26	18,8+/-0,30	0,0001	21,4 ae 0,25	18,2+/-0,31	0,0001
Profundidade de músculo,mm	35,6+/-0,56	40,6+/-0,62	0,0001	38,0 ae 0,53	38,2+/-0,66	0,76
Rend. Carne Estimado, g/kg	489+/-1,0	499 ae 1,1	0,0001	488 ae 1,0	500+/-1,2	0,0001
Rend. Carne Medido, g/kg	482+/-1,8	505+/-2,0	0,0001	484 ae 1,7	316+/-3,5	0,0001
Estimado – medido	6,3 0,43 3	-5,2 1,6 2	0,0001	4,3+/-1,4 2	-3,2+/-1,7 1	0,0005
Composição dos Cortes						
Carne, g/kg	563+/-2,8	576+/-3,1	0,0001	539+/-2,7	573+/-3,3	0,0001
Gordura, g/kg	358+/-2,9	312 ae 3,3	0,0001	354+/-2,8	316+/-3,5	0,0001
Ossos, g/kg	106+/-0,7	112 ae 0,7	0,0001	107 ae 0,6	11+/-0,8	0,0001
Número de suínos	130	96		139	87	

Fonte: Sather et al., 1991.

N.S. = Nível de significância

1 P 0,05, 2 P 0,001, 3 P 0,0001

## 2.5 Tipificação Como Comercialização de Produtos

No Brasil,  $\text{Receita} = (\text{Preço})[(\text{Pcarq} \div \text{Rendcarq}) * (\text{Bonificação})]$ , equação (1), é a fórmula usada para o pagamento de carcaças tipificadas, em que: Receita é o valor que o produtor recebe por cada carcaça quente tipificada no momento do abate;

Preço é o preço unitário do kg de suíno vivo que oscila de acordo com a conjuntura do mercado; Pcarq é o peso da carcaça quente no momento do abate; Rendcarq é um valor fixado, para representar o rendimento da carcaça quente no momento do abate, que seria obtido através da relação entre Pcarq e o peso do suíno vivo no momento do abate (Pvivo), isto é ( $\text{Rendcarq} = \text{Pcarq} \div \text{Pvivo}$ ); Bonificação é um fator de ponderação maior que zero que diferencia cada carcaça quente individualmente pelo critério de qualidade estabelecido, dado pela % de carne na carcaça resfriada. Se a Bonificação for menor que 1, maior que 1 ou igual a 1 então a carcaça quente sofre, respectivamente, penalização, premiação, ou não é penalizada e nem premiada. Na equação 1, fixando-se a bonificação=1 tem-se a compra de carcaça quente sem bonificação.

Assim, a equação atual de pagamento de carcaças tipificadas requer que o peso do suíno vivo e os correspondentes índices de bonificação sejam conhecidos.

### A) Peso do Suíno Vivo: Necessidade de Uma Equação Para Estimá-lo.

O termo  $\text{Rendcarq} = \text{Pcarq} \div \text{Pvivo}$ , usado na equação 1 com valor fixado dentro de cada agroindústria compradora de suínos, indica que o sistema de pagamento de carcaças tipificadas introduzido no Brasil não eliminou a necessidade da pesagem do suíno vivo e portanto o processo atual de pagamento na verdade compra a carcaça quente expressa em equivalente ao suíno vivo, oferecendo uma bonificação adicional pela qualidade da carcaça. A diferença reside no fato que este é um processo tendencioso em relação ao sistema tradicional que compra o suíno vivo. Tendencioso porque existe um desvio entre o verdadeiro rendimento de carcaça de cada animal e o valor fixado.

Além disso, o fato de cada empresa compradora usar um valor fixado diferenciado para Rendcarq, possibilita transformar tal flexibilidade numa distorção do sistema de comercialização do suíno vivo bonificado.

Embora, pareça lógico, que no futuro a remuneração ao produtor poderá ser baseada apenas no peso da carcaça quente tipificada, essa premissa além de ir em desentendimento aos interesses dos produtores, se for implantada, precisa ser checada se não irá ferir princípios de biossegurança e bioética (Fontes, 1999); (Garrafa, 1999). É importante antecipar esta questão porque dentro do segmento agroindustrial brasileiro tem havido manifestações de algumas correntes que o pagamento deveria ser feito sobre a carcaça quente (carcaça eviscerada, sem: cabeça, pés dianteiros, papada, rabo e gordura perineral), sob a alegação que o restante é aproveitado, mas principalmente como subproduto 3 . Por outro lado, carcaça quente tipificada já é alimento, porque sofreu todo um processamento no sistema de abate enquanto que o suíno vivo não o é, e é isso que o produtor vende. É claro que questionamento dessa natureza tem tudo a ver com temas como biossegurança e bioética.

A bonificação é apenas um componente indexador da equação de pagamento que cuida do quesito qualidade da carcaça, expresso pela % de carne na carcaça resfriada. De qualquer forma, ficou demonstrado que até então o pagamento com a prática da bonificação será imparcial somente se o peso do suíno vivo for conhecido. Isso requer a pesagem individualizada de cada suíno vivo no momento do abate.

Uma forma de contornar este problema, (Guidoni, 2000), consiste em fazer um experimento devidamente planejado para estimar uma equação preditora do peso do suíno vivo no momento do abate em função do peso da carcaça quente, evitando-se dessa forma a pesagem individualizada do animal vivo antes de entrar na linha de abate, que seria um transtorno, além de evitar a possibilidade de eventuais problemas adicionais que poderão interferir na qualidade da carcaça processada (Warris, 2000), uma vez que a pesagem do suíno vivo individualizado faria parte do grupo de eventos durante as 24 horas antes do abate mais importantes de todo o ciclo de produção do suíno, responsável pela qualidade da carne (Peloso, 2000).

## B) Índice de Bonificação

A bonificação de carcaças no Brasil tem sido usada como estratégia comercial para incentivar a produção de carcaças com mais carne e menos gordura, mas como negócio é mais uma das transações entre produtores e frigoríficos, que obedecem as leis tradicionais de mercado.

Por isso, as empresas brasileiras compradoras de suínos têm praticado índices médios de bonificação variáveis, estima-se uma oscilação média entre 1 a 10 %. Entretanto, ao que tudo indica (Guidoni, 1999), parece haver concordância entre todos os frigoríficos que o índice de bonificação até o momento seja gerado em função do peso da carcaça quente ( $P_{carq}$ ) e da % de carne estimada na carcaça resfriada ( $P_{cmf}$ ). A tabela 1.1 é um exemplo de bonificação de carcaças quente gerado em função de  $P_{carq}$  e  $P_{cmf}$ .

A maioria das empresas brasileiras que praticam a bonificação, adotam modelos semelhantes aos da tabela 1.1. Um dos inconvenientes das tabelas é que elas proporcionam descontinuidades artificiais a um fenômeno que é estritamente contínuo.

A equação,  $Bonificação = 23,6 + 0,286 \cdot P_{carq} + P_{cmf}$ , equação 2, pode ser usada para reproduzir a tabela 1.1 sem qualquer descontinuidade e indica que  $P_{cmf}$  tem maior importância que  $P_{carq}$  para gerar o índice.

A equação 2 é um modelo linear com taxas de acréscimos marginais constantes, entretanto pode-se recorrer aos modelos não lineares com taxas de acréscimos marginais variáveis.

Os modelos,  $IndiceD = 210 - 145 \cdot (0,99192 (P_{carq} \cdot P_{cmf}))$ , equação 3,  $IndiceC = -137 + 208 \cdot (1,0037545 (P_{carq} \cdot P_{cmf}))$ , equação 4, são exemplos de modelos não-lineares com taxas de acréscimos decrescentes e crescentes, respectivamente. O modelo não-linear com taxa de acréscimo crescente deveria ser usado de forma generalizada para bonificação de carcaças, pelas vantagens que apresenta, conforme mostrado em (Guidoni 2000b).

Um ponto que pode ser questionado em relação aos modelos 2, 3 e 4, principalmente 3 Opiniões de representantes anônimos de agroindústrias em reuniões realizadas sobre o assunto.

Tabela 2.1 - Índice de bonificação empírico gerado em função do peso da carcaça quente (Pcarq) e porcentagem de carne estimada na carcaça resfriada (pcmf).

Pcmf (%)	Faixas de Peso da Carcaça Quente (Kg)														
	[40-45]	[45-50]	[50-55]	[55-60]	[60-65]	[65-70]	[70-75]	[75-80]	[80-85]	[85-90]	[90-95]	[95-100]	[100-105]	[105- ]	
(-35]	71	73	74	76	77	79	80	1	83	84	86	87	89	90	
(35-36]	72	74	75	77	78	80	81	82	84	85	87	88	90	91	
(36-37]	73	75	76	78	79	81	82	83	85	86	88	89	91	92	
(37-38]	74	76	77	79	80	82	83	84	86	87	89	90	92	93	
(38-39]	75	77	78	80	81	83	84	85	87	88	90	91	93	94	
(39-40]	76	78	79	81	82	84	85	86	88	89	91	92	94	95	
(40-41]	77	79	80	82	83	85	86	87	89	90	92	93	95	96	
(41-42]	78	80	81	83	84	86	87	88	90	91	93	94	96	97	
(42-43]	79	81	82	84	85	87	88	89	91	92	94	95	97	98	
(43-44]	80	82	83	85	86	88	89	90	92	93	95	96	98	99	
(44-45]	81	83	84	86	87	89	90	91	93	94	96	97	99	100	
(45-46]	82	84	85	87	88	90	91	92	94	95	97	98	100	101	
(46-47]	83	85	86	88	89	91	92	93	95	96	98	99	101	102	
(47-48]	84	86	87	89	90	92	93	94	96	97	99	100	102	103	
(48-49]	85	87	88	90	91	93	94	95	97	98	100	101	103	104	
(49-50]	86	88	89	91	92	94	95	96	98	99	101	102	104	105	
(50-51]	87	89	90	92	93	95	96	97	99	100	102	103	105	106	
(51-52]	88	90	91	93	94	96	97	98	100	101	103	104	106	107	
(52-53]	89	91	92	94	95	97	98	99	101	102	104	105	107	108	
(53-54]	90	92	93	95	96	98	99	100	102	103	105	106	108	109	
(54-55]	91	93	94	96	97	99	100	101	103	104	106	107	109	110	
(55-56]	92	94	95	97	98	100	101	102	104	105	107	108	110	111	
(56-57]	93	95	96	98	99	101	102	103	105	106	108	109	111	112	
(57-58]	94	96	97	99	100	102	103	104	106	107	109	110	112	113	
(58-59]	95	97	98	100	101	103	104	105	107	108	110	111	113	114	
(59-60]	96	98	99	101	102	104	105	106	108	109	111	112	114	115	
(60-61]	97	99	100	102	103	105	106	107	109	110	112	113	115	116	
(61-62]	98	100	101	103	104	106	107	108	110	111	113	114	116	117	
(62-63]	99	101	102	104	105	107	108	109	111	112	114	115	117	118	
(63-64]	100	102	103	105	106	108	109	110	112	113	115	116	118	119	
(64-...]	101	103	104	106	107	109	110	111	113	114	116	117	119	120	

Os 2 últimos, é que o produto  $P_{carq} * P_{cmf}$  equivale a quantidade de carne na carcaça morna. Isso parece ser uma grande incoerência introduzida no processo de bonificação de carcaças de suínos. Contudo a própria incoerência pode ser admitida como um critério usado para bonificar carcaças. Em se tratando de um negócio entre comprador e vendedor, qualquer que seja o acordo firmado entre as partes tem validade jurídica, ocorre que não é nessa linha de pensamento a intenção da discussão.

Apesar das agroindústrias brasileiras calcularem a bonificação de carcaças em função do peso da carcaça quente e % de carne na carcaça resfriada, o fato de se poder estimar equações de predição da % de carne na carcaça quente ou resfriada, pode-se então gerar equações empíricas de bonificação em função do peso e % de carne da carcaça quente ou resfriada. Em qualquer circunstância qualquer processo de bonificação deve passar por uma validação antes de sua implantação. A experiência tem mostrado que a simples geração de equações ou tabelas de bonificação não é suficiente, uma vez que o índice médio de bonificação além de depender de pressupostos técnicos e econômicos de cada empresa depende principalmente da concentração de animais em cada faixa de peso e % de carne.

Um avanço que poderá ser desencadeado no futuro em decorrência da estimação na linha de abate do peso e % de carne ou gordura das partes da carcaça é que carcaças de mesmo peso e % de carne na carcaça inteira com mesmo índice de bonificação poderão passar a ter bonificação diferenciada, pelo fato que a distribuição da % de carne nas partes não é a mesma e assim carcaças com maior concentração de carne nas partes especiais terão melhor bonificação.

## **2.6 Tipificação Para Garantir Especificação na Carcaça Inteira e suas Partes.**

Um dos pontos importantes na montagem do processo de tipificação é o planejamento da dissecação de carcaças. A meat and livestock commission 1995 oferece uma lista de sugestões interessante a ser seguida. O planejamento deve começar pela escolha do aparelho para quantificar as medidas preditoras de carne e gordura, tamanho e representatividade da amostra, conceituação de carcaça e cortes da mesma, conceituação de carne e gordura, definição das posições de avaliação dos preditores na

carcaça, escolha de balanças adequadas, treinamento dos operadores para garantir um mesmo padrão de qualidade em todas as etapas do trabalho de dissecação e na rotina da tipificação a ser usada no dia a dia, etc. Ao que tudo indica as dissecações realizadas no Brasil até o momento tem se preocupado basicamente em prever teor de carne na carcaça para obter o índice de bonificação e realizar a compra de suínos vivos para o abate.

Como a dissecação da meia carcaça esquerda deve permitir, também, prever carne e gordura nas partes da carcaça é necessário avaliar carne, gordura, ossos e pele de cada parte planejada.

Para realizar os cálculos, da quantidade ou % de carne resfriada na carcaça inteira é necessário fazer correções para erros de divisão da carcaça (Guidoni, 2000). Após essas correções parte-se para os ajustes de curvas preditoras de carne e gordura na carcaça inteira resfriada e suas partes.

### **A) Correção de Erros Na Divisão das Carcaças Dissecadas**

Na amostra de carcaças usada para a dissecação, apesar da dissecação ser realizada na meia carcaça esquerda resfriada a predição da % de carne deve ser feita para a carcaça inteira, porque é com base nessa porcentagem que é gerado o índice de bonificação para toda a carcaça. Se a divisão de carcaças for ao meio então a divisão entre a quantidade de carne e peso da meia carcaça esquerda representa sem erro a porcentagem de carne na carcaça inteira resfriada. Caso contrário algum ajuste é necessário. Propõe-se ajustar a quantidade de carne na meia carcaça direita não dissecada por:  $Q_{carfdir} = Q_{carfesq} + b (P_{carfesq} - P_{carfdir})$ , equação 5, onde:  $Q_{carfdir}$  é a quantidade de carne ajustada na meia carcaça direita resfriada;  $Q_{carfesq}$  é a quantidade de carne observada na meia carcaça esquerda resfriada;  $P_{carfesq}$  e  $P_{carfdir}$  representam, respectivamente, os pesos das meias carcaças esquerda e direita resfriadas;  $b$  é o coeficiente de regressão linear obtido ao ajustar, sem o intercepto,  $P_{carfdir}$  em função de  $P_{carfesq}$ . Conhecida a quantidade de carne na meia carcaça direita pode-se então obter a quantidade de carne na carcaça inteira resfriada, isto  $Q_{carf} = Q_{carfesq} + Q_{carfdir}$ , equação 6.

A tabela 2.1 mostra que diferença acentuada entre a meia carcaça esquerda e direita causa um viés importante na predição da % de carne resfriada na carcaça inteira.

Ademais, se o peso da meia carcaça esquerda for sistematicamente menor que o peso da meia carcaça direita a % de carne verdadeira na carcaça inteira é subestimada e favorece aos compradores de carcaça. Se o peso da meia carcaça esquerda for sistematicamente maior que o peso da meia carcaça direita a % de carne na carcaça inteira é superestimada e favorece aos produtores. A imparcialidade ocorre se não houver diferença entre as partes divididas. Dessa forma a tabela 2.1 sugere que apenas a Dissecção C não estaria cometendo erro e, portanto o ajuste é sempre providencial, porque este tipo de erro é transportado integralmente para a linha de abate e independe de erros operacionais na linha de abate. É óbvio que a dissecção da carcaça inteira eliminaria integralmente este tipo de erro, no entanto a dissecção C da tabela 2.1 sugere que diferenças máximas em torno  $\pm 1$  kg entre as duas partes da carcaça é um erro tolerável.

### **B) Carne na Carcaça Quente Ajustada por Carne na Carcaça Resfriada**

Os consumidores compram, carne resfriada ou produtos oriundos de carcaça que já sofreu resfriamento. Os produtores vendem aos frigoríficos carcaça quente, aliás vendem mesmo é o suíno vivo. Portanto, pode haver interesse no momento do abate, além do peso da carcaça quente que é fornecido estimar a correspondente quantidade ou % de carne nessa mesma carcaça quente ou até mesmo estimar o peso e a correspondente quantidade e % de carne na carcaça inteira resfriada. Como a dissecção é para obter a quantidade de carne na carcaça resfriada pode-se estimar a quantidade de carne na carcaça quente por:  $Q_{carq} = Q_{carf} + (P_{carq} - P_{carf}) \cdot k$ , equação 7, onde:  $Q_{carq}$  é a quantidade de carne estimada na carcaça inteira quente;  $Q_{carf}$  é a quantidade de carne estimada da carcaça resfriada obtida pela equação 6;  $P_{carq}$  e  $P_{carf}$  correspondem aos pesos observados das carcaças quente e resfriada, respectivamente;  $K \leq 1$  é uma fator de correção, e indica que da perda de peso ocorrida ao resfriar a carcaça,  $k$  % corresponde a perda na carne e os  $(1-k)$  % restante corresponde a perda na gordura, orifícios de ossos, além de outros líquidos que a carcaça quente possui naturalmente. O valor de  $K$  pode ser obtido experimentalmente, e varia de linhagem para linhagem. Na falta de dados pode-se usar  $K=0,80$ . Se  $k=1$  então toda a perda de peso da carcaça corresponde a perda de peso da carne.

Para prever  $P_{carf}$  na linha de abate pode-se com base na amostra de carcaças dissecadas estimar uma equação de regressão linear entre  $P_{carf}$  e  $P_{carq}$ , isto é  $P_{carf} = a + b \cdot P_{carq}$ , equação 8, em que  $a$  e  $b$  são estimados com a amostra de carcaças dissecadas. Sequencialmente, pode-se também estimar as % de carne na carcaça quente e resfriada, respectivamente, tais que:  $P_{cmf} = 100 \cdot (Q_{carf} \div P_{carf})$ , equação 9, e  $P_{cmq} = 100 \cdot (Q_{carq} \div P_{carq})$ , equação 10; em que  $P_{cmf}$  e  $P_{cmq}$  correspondem as % de carne nas carcaças quente e resfriada, respectivamente.

Pode-se estimar uma equação para prever  $P_{cmq}$  diretamente em função de  $P_{cmf}$ , isto é:  $P_{cmq} = a + b \cdot P_{cmf}$ , equação 11.

Tabela 2.2 - Importância relativa do ajuste da meia carcaça não dissecada pela meia carcaça dissecada.

Dissecação A: $\frac{1}{2}$ Carcaça esq. < $\frac{1}{2}$ Carcaça dir. $Q_{carfdir} = Q_{cafesq} - 1,045 \cdot (P_{cafesq} - P_{carfdir})$			
Variável	Média	Mínimo	Máximo
Peso meia carcaça esquerda resfriada ( $P_{cafesq}$ , (kg))	31,6	11,9	51,3
Peso meia carcaça direita resfriada ( $P_{carfdir}$ , (kg))	33,1	11,9	54,7
Diferença (esq-dir)	-1,5	-4,5	4,4
% de carne ajustada Ideal $100 \cdot (Q_{carfdir} + q_{cafesq}) / P_{carf}$	54,8	37,1	71,2
% de carne calculada $100 \cdot (Q_{cafesq}) / P_{cafesq}$	54,1	36,6	71,2
Diferença (calculada-Ideal) (%)	-0,7 %	-	-
Relação (Calculada/Ideal) (%)	98,7 %	-	-
Dissecação B: $\frac{1}{2}$ Carcaça esq. > $\frac{1}{2}$ Carcaça dir. $Q_{carfdir} = Q_{cafesq} - 0,983 \cdot (P_{cafesq} - P_{carfdir})$			
Variável	Média	Mínimo	Máximo
Peso meia carcaça esquerda resfriada ( $P_{cafesq}$ , (kg))	39,9	20,8	66,3
Peso meia carcaça direita resfriada ( $P_{carfdir}$ , (kg))	38,5	19,1	64,1
Diferença (esq-dir)	1,4	-1,9	7,9
% de carne ajustada Ideal $100 \cdot (Q_{carfdir} + q_{cafesq}) / P_{carf}$	53,8	44,7	63,3
% de carne calculada $100 \cdot (Q_{cafesq}) / P_{cafesq}$	54,3	45,3	62,7
Diferença (calculada-Ideal) (%)	0,5 %	-	-
Relação (Calculada/Ideal) (%)	100,9 %	-	-
Dissecação C: $\frac{1}{2}$ Carcaça esq. = $\frac{1}{2}$ Carcaça dir. $Q_{carfdir} = Q_{cafesq} - 0,997 \cdot (P_{cafesq} - P_{carfdir})$			
Variável	Média	Mínimo	Máximo
Peso meia carcaça esquerda resfriada ( $P_{cafesq}$ , (kg))	35,5	24,2	47,4
Peso meia carcaça direita resfriada ( $P_{carfdir}$ , (kg))	35,4	24,1	46,9
Diferença (esq-dir)	0,1	-0,6	0,8
% de carne ajustada Ideal $100 \cdot (Q_{carfdir} + q_{cafesq}) / P_{carf}$	55,3	46,2	65,2
% de carne calculada $100 \cdot (Q_{cafesq}) / P_{cafesq}$	55,3	46,2	65,2
Diferença (calculada-Ideal) (%)	0,0	-	-
Relação (Calculada/Ideal) (%)	100	-	-

A tabela 2.3 ilustra o que foi exposto, e mostra que as fórmulas empíricas apresentadas poderão ser validadas experimentalmente, desde que se faça um experimento para essa finalidade. Observe que com esses dados pode-se postular gerar o índice de bonificação em função do peso e % de carne na carcaça quente ou resfriada ou mesmo em função da quantidade de carne na carcaça quente ou resfriada, evitando-se ter que aceitar a suposta quantidade de carne morna =Pcarq\*Pcmf.

Tabela 2.3 - Resumo sobre Peso, quantidade e % de carne em carcaças quentes e resfriadas, calculados, preditos ou ajustados com base numa amostra de carcaças dissecadas.

Variável	Média	Desvio Padrão	Mínimo	Máximo
Peso da carcaça Quente (Pcarq, kg)	78,04	18,91	43,20	131,20
Peso da carcaça Resfriada (Pcarf kg) *	77,24	18,72	42,75	130,39
Relação(Pcarq/Pcarf), %	101,03	0,90	100,08	106,52
Quantidade de Carne Quente (Qcarq, kg)	42,09	9,31	25,34	65,80
Quantidade de carne Resfriada (Qcarf, kg)	41,45	9,14	25,23	65,15
Relação(Qcarq/Qcarf), %	101,54	1,32	100,10	109,59
% de carne Resfriada (Pcmf, %)	54,13	4,22	44,55	66,88
% de carne Quente (Pcmq, %) **	54,69	4,19	44,70	67,02
Relação(Pcmq/Pcmf), %	101,09	0,41	100,02	102,88

\*  $Pcarf = 0,029 + 0,989357 * pcarq$ ;  $R^2 = 99,82\%$ ;  $DPR = 0,8\text{ kg}$ ;  $CV = 1,1\%$ .

\*\*  $Pcmq = 0,725 + 0,9891464 * pcmf$ ;  $R^2 = 99,732\%$ ;  $DPR = 0,22\%$ ;  $CV = 0,4$ .

$R^2$ ,  $DPR$  e  $CV$ : coef. de determinação, desvio pad. do resíduo e coef. de variação, respectivamente.

### C) Eficiência da Predição Quantidade versus Porcentagem de Carne na Carcaça

Tradicionalmente os trabalhos realizados para estimar equações de predição de carne na carcaça têm ajustados equações para prever diretamente a % de carne na carcaça resfriada,  $Pcmf = Qcarf \div Pcarf$ , que é uma variável secundária resultante do quociente de duas variáveis altamente correlacionadas e que sabidamente seguem a distribuição normal de probabilidade. Enquanto, pode-se afirmar com certeza que Pcmf pode seguir qualquer distribuição, menos a distribuição normal. Como a teoria clássica de regressão foi criada originalmente para estimar equações de predição de variáveis com distribuição normal ou pelo menos aproximadamente normal é mais eficiente o

ajuste de equações de predição para quantidade de carne. A predição da porcentagem deve ser obtida em duas etapas, primeiras predizer a quantidade de carne e posteriormente calcular a porcentagem dividindo-se a quantidade de carne predita pelo correspondente peso da carcaça resfriada. Embora, o que foi dito é na verdade um teorema devidamente demonstrado há mais de um século, a seguir é apresentada uma comprovação com base numa amostra de carcaças dissecadas.

As equações estimadas com as respectivas estatísticas indicadoras de qualidade de ajuste são dadas por:

$$Q_{carf} = 7,38 - 0,487Esp + 0,059Mus + 0,525P_{carq}; DPR = 1,305kg; CV = 3,33\%; R^2 = 97,01\%.$$

$$P_{cmf} = 65,92 - 0,685Esp + 0,094Mus - 0,026P_{carq}; DPR = 1,5\%; CV = 2,69\% R^2 = 92,34\%.$$

Onde:

Esp e Mus são medidas obtidas com a pistola eletrônica da espessura de toucinho e profundidade de músculo avaliados a 6 cm da linha dorsal mediana entre a última e penúltima vértebra lombar.

Verifica-se que o  $R^2$  obtido para  $Q_{carf}$  é de 97 % e para  $P_{cmf}$  é de 92,3 %. A tabela 2.4 mostra que o erro médio absoluto na predição direta é de 2,3 % enquanto na estimação indireta é de apenas 1,5 %, comprovando a eficiência, apesar que o  $DRP = 1,5$  % para predizer  $P_{cmf}$  diretamente está bem abaixo dos 2,5 % tolerado pela comunidade européia (Irgang, 1996) . Observe que esse é um tipo de erro que pode ser evitado a custo zero.

Tabela 2.4 - Erro cometido para predizer  $Q_{carf}$  e  $P_{cmf}$  direta e indiretamente, numa dissecação.

Variável	Resíduo Média (min,max)	Erro relativo (média,min,max) %	Erro absoluto (média,min,max)
$Q_{carf}$	0 (-2,62 kg; 3,14 kg)	-0,05 (-8,3; 10,9) %	2,7 (0,3; 10,9) %
$P_{cmf}$ (predição direta)	0 (-2,66 kg; 2,84 kg)	-0,06 (-4,9; 5,7) %	2,3 (0,1; 5,7)
$P_{cmf}$ (predição indireta)	0 (-2,61 kg; 3,32 kg)	-0,05 (-5,9; 5,1)	1,5 (0,1; 5,1)

Resíduo=(observado-predito); Erro relativo=  $100 \times \text{resíduo} \div \text{observado}$ ; Erro absoluto=  $ABS(\text{Erro relativo})$

#### **D) Equações de Predição do Peso, quantidade de Carne e Gordura nas partes da Carcaça Resfriada.**

(Irgang 1996) mostra que além dos preditores avaliados na carcaça quente com a pistola eletrônica, o peso da carcaça quente ( $P_{carq}$ ) é um importante preditor da quantidade ou % de carne na carcaça resfriada, razão pela qual as equações ajustadas em 3.3 incluíram  $P_{carq}$ . Ademais, (Guidoni 1999) ao estudar quatro amostras de diferentes composições raciais de carcaças dissecadas concluiu que é melhor fazer a estimativa em dois estágios, isto é estimar primeiramente equações para prever a % de carne na carcaça resfriada ( $P_{cmf}$ ) pelo método indireto e posteriormente estimar uma equação para prever o peso e quantidade de carne da parte em função de  $P_{carq}$  e  $P_{cmf}$ . O mesmo raciocínio se aplica para prever gordura, se for de interesse. Com base numa das amostras de carcaças dissecadas, referenciadas anteriormente, foram estimados as seguintes equações, para prever o peso, a quantidade de carne e gordura do pernil resfriado.

$Peso/Pernil = - 2,25 + 0,1538 \cdot P_{carq} + 0,0447 \cdot P_{cm}$ ;  $mdia = 11,5kg$ ;  $DPR = 353g$ ;  $CV = 3,1\%$ ;  $R^2 = 96,9\%$ .

$Q_{Carne}/Pernil = - 7,53 + 0,0909 \cdot P_{carq} + 0,1396 \cdot P_{cm}$ ;  $mdia = 6,8kg$ ;  $DPR = 261g$ ;  $CV = 3,9\%$ ;  $R^2 = 95,8\%$ .

$Q_{Gordura}/Pernil = - 3,02 + 0,0428 \cdot P_{carq} + 0,0999 \cdot P_{gord}$ ;  $Mdia = 3,2kg$ ;  $DPR = 195g$ ;  $CV = 6,1\%$ ;  $R^2 = 96,1\%$ .

A Tabela 2.5 mostra os erros cometidos pelos modelos estimados para prever o peso, quantidade de carne e gordura do pernil resfriado. Uma simulação realizada para predição do peso, quantidade de carne e gordura do pernil resfriado é apresentada na tabela 2.6.

Verifica-se que todos os parâmetros estimados das três equações são significativamente diferentes de zero e os modelos apresentam boa qualidade de ajuste. Os  $R^2$  são superiores a 95 %. Pela tabela 2.5, os erros médios absolutos são menores que 5 %. Entretanto para predição individual isso pode não ser suficiente. Verifica-se que para prever o peso do pernil inteiro chega-se a cometer um erro oscila de -5,8 a 7,1 %. Para a quantidade Carne a oscilação é de -11,0 a 8,9 % e para gordura é ainda maior, oscilando de -13,3 a 14,5 %.

Não há dúvida que a informação produzida sobre o pernil, conforme mostra a tabela 2.6, é útil na linha de abate para dar destino industrial às carcaças, evitando-se pelo menos os erros grosseiros que o olho nu seriam cometidos. Entretanto para garantir especificação, esses modelos podem não ser adequado. Por isso, se o objetivo da agroindústria é lançar produtos ao mercado com determinada especificação, antes de pensar em planejar uma dissecação é importante conhecer o que determina a legislação.

Tabela 2.5 - Erro cometido para predizer o Peso, quantidade de carne e gordura do pernil resfriado.

Variável	Resíduo	Erro relativo	Erro absoluto
	Média (min, max)	Média (min, max)	Média (min, max)
Peso do Pernel (kg)	0 (-709 g; 671 g)	0,1 (-5,8; 7,1) %	2,5 (0,1; 7,1) %
Carne do Pernel (kg)	0 (-569 g; 738 g)	-0,1 (-11,0; 8,9) %	3,2 (0,0; 11,0)
Gordura do Pernel (kg)	0 (-357 g; 561 g)	-0,1 (-13,3; 14,5) %	4,9 (0,2; 14,5)

Tabela 2.6 — Simulação para predizer o peso, quantidade de carne e gordura do pernil resfriado.

Pcarf	% Carne		Pernil Inteiro		Carne do Pernel		Gordura do Pernel	
	Kg	Resf.	Peso, Kg	%	Quant. Kg	%	Quant. Kg	%
50	55,0	28,0	7,9	31,6	4,7	59,3	1,9	24,3
60	55,0	28,0	9,4	31,5	5,6	59,3	2,3	24,8
70	55,0	28,0	11,0	31,4	6,5	59,3	2,8	25,3
80	55,0	28,0	12,5	31,3	7,4	59,2	3,2	25,6
90	55,0	28,0	14,1	31,2	8,3	59,2	3,6	25,8
100	55,0	28,0	15,6	31,1	9,2	59,2	4,1	26,0
110	55,0	28,0	17,1	31,0	10,1	59,2	4,5	26,2

### **E) Aspectos Relacionados com a Representatividade da Amostra de Carcaças Dissecadas**

A lei universal de Fisher diz que "Não se pode extrair dos dados mais do que eles podem oferecer, isto é: estimativas geradas a partir de amostras inadequadas

também serão inadequadas". Esses dizeres são muito importantes para serem seguidos por aquelas empresas que pretendem continuar na atividade pensando em aplicar os princípios básicos da qualidade. Antes de qualquer discussão é desejável entender que uma amostra só é representativa se ela concordar com a população que a contém em pelo menos 95 % das ocorrências. No entanto, (Guidoni 1999) ao realizar estudos sobre tipificação de carcaças referente a quatro empresas, verificou que a amostra dissecada de maior concordância com a população foi de 85 %. Isso significa que independente de qualquer outra questão que possa ser desencadeada o erro de partida já é de 15 %. As vezes é melhor usar 30 carcaças escolhidas convenientemente do que escolher 120 inadvertidamente. Admita-se que os preditores a serem usados numa determinada empresa para fazer predições da carcaça sejam o peso da carcaça quente (Pcarq), espessura de toucinho (Esp) e Profundidade de músculo (Mus). Nesse caso, se existir dados armazenados ao longo do tempo, na empresa, contendo informações dessas três características a primeira providência é fazer um estudo da população determinando-se inicialmente os valores mínimos, médio e máximo de cada característica. Uma amostra de 54 carcaças resultante de uma combinação fatorial Sexo (Macho, Fêmea) X Pcarq(mínimo, médio, máximo) X Esp(mínimo, médio, máximo) X Mus(mínimo, médio, máximo) já pode ser considerada uma amostra adequada para estimar equações de predição, inclusive pode estimar uma equação para cada sexo. Pois, uma das impropriedades dos modelos de regressão clássicos se verifica quando eles são usados para extrapolação.

Nessa amostra de tamanho 54 isso já não ocorre. É claro que precisa ser determinada a distribuição dos animais para Pcarq, Esp e Mus conjuntamente e conhecer a concentração de animais nas classes combinadas e realizar uma amostragem proporcional, para garantir que o modelo preditor seja de máxima precisão, isto é cometa o mínimo de erro possível.

## **CAPÍTULO 3 - REVIZÃO DOS CONCEITOS BÁSICOS DE RN'S**

Segundo (Barreto, 1997) pesquisas cerebrais são um antigo campo de atividade. Elas tiveram um grande avanço, assim como muitos outros campos da ciência, depois da Segunda Guerra Mundial. Isso porque surgiam novas tecnologias que permitiram a realização de experimentos inéditos. Um dos primeiros passos na neuroanatomia foi a descoberta do italiano Camillo Golgi em 1875. Ele encontrou um método, aparentemente ao acaso, pelo qual apenas umas porções de neurônios são coradas durante um tempo, e essas células são completamente coradas. Com esse método é possível isolar e observar neurônios individuais.

Golgi foi contemporâneo de Santiago Ramón y Cajal, um espanhol, que dedicou sua vida usando o método de Golgi para cada parte do sistema nervoso. Sua “Histologie du système nerveux de l’homme et des vertébrés” publicada na Espanha em 1904 e é um dos mais importantes trabalhos já escritos em neurobiologia. Ao tempo de Cajal as junções entre neurônios eram desconhecidas, principalmente porque o método de Golgi revelou um grande número de células isoladas mas sem sugerir junções entre elas de modo a formar uma rede.

Entretanto os estudos de Cajal apresentaram dois resultados principais. Primeiro Cajal adotou noção de sistema nervoso, postulando sobre a comunicação entre as células pela sinapse. A segunda maior contribuição foi de que a interconexão entre neurônios não seria feita ao acaso, pois é altamente específica e estruturada. Ele descreveu diversas estruturas cerebrais. Isto fez com que as pesquisas se voltassem não apenas para a estrutura dos neurônios, mas também para o desconhecido campo das muitas estruturas formadas pelos grupos de neurônios.

### **3.1 Principais componentes dos neurônios**

Os dendritos, que tem por função, receber os estímulos transmitidos pelos outros neurônios;

O corpo de neurônio, também chamado de soma, que é responsável por coletar e combinar informações vindas de outros neurônios;

E finalmente o axônio, que é constituído de uma fibra tubular que pode alcançar até alguns metros, e é responsável por transmitir os estímulos para outras células.

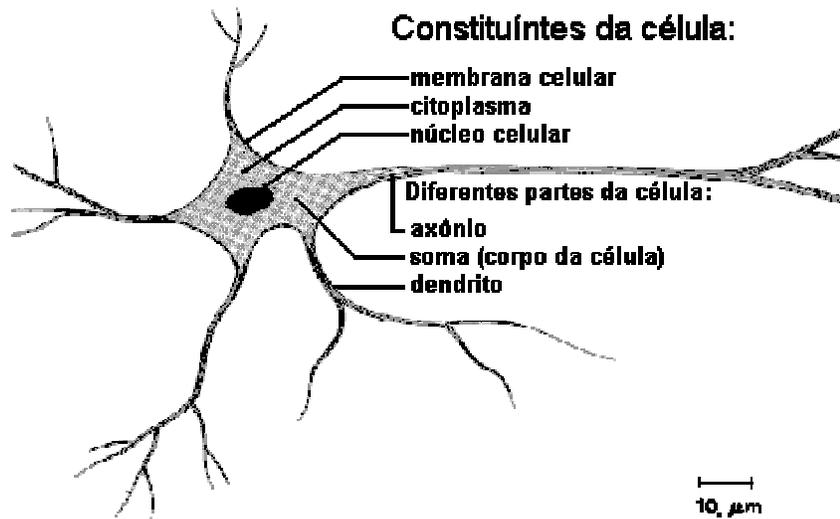


Figura 3.1 - Esquema dos constituintes da célula neural

### 3.2 Histórico das Redes Neurais Artificiais

As primeiras informações mencionadas sobre a neuro computação datam de 1943, em artigos de McCulloch e Pitts, em que sugeriam a construção de uma máquina baseada ou inspirada no cérebro humano. Muitos outros artigos e livros surgiram desde então, porém, por um longo período de tempo, pouco resultado foi obtido. Até que em 1949 Donald Hebb escreveu um livro intitulado "*The Organization of Behavior*" (A Organização do Comportamento) que perseguia a idéia de que o condicionamento psicológico clássico está presente em qualquer parte dos animais pelo fato de que esta é uma propriedade de neurônios individuais. Suas idéias não eram completamente novas, mas Hebb foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios. Este primeiro e corajoso passo serviram de inspiração para que muitos

outros pesquisadores perseguissem a mesma idéia. E embora muito tenha sido estudado e publicado nos anos que seguiram (1940-1950), estes serviram mais como base para desenvolvimento posterior que para o próprio desenvolvimento.

Também proveniente deste período de tempo foi a construção do primeiro neuro computador, denominado *Snark*, por Mavin Minsky, em 1951. O Snark operava com sucesso a partir de um ponto de partida técnico, ajustando seus pesos automaticamente, entretanto, ele nunca executou qualquer função de processamento de informação interessante, mas serviu de inspiração para as idéias de estruturas que o sucederam.

Em 1956 no "*Darhmouth College*" nasceram os dois paradigmas da Inteligência Artificial, a simbólica e o conexionista. A Inteligência Artificial Simbólica tenta simular o comportamento inteligente humano desconsiderando os mecanismos responsáveis por tal. Já a Inteligência Artificial Conexionista acredita que construindo-se um sistema que simule a estrutura do cérebro, este sistema apresentará inteligência, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros.

O primeiro neuro computador a obter sucesso (Mark I Perceptron) surgiu em 1957 e 1958, criado por Frank Rosenblatt, Charles Wightman e outros. Devido a profundidade de seus estudos, suas contribuições técnicas e de sua maneira moderna de pensar, muitos o vêem como o fundador da neuro computação na forma em que a temos hoje. Seu interesse inicial para a criação do Perceptron era o reconhecimento de padrões.

Após Rosenblatt, Bernard Widrow, com a ajuda de alguns estudantes, desenvolveram um novo tipo de elemento de processamento de redes neurais chamado de Adaline, equipado com uma poderosa lei de aprendizado, que diferente do Perceptron ainda permanece em uso. Widrow também fundou a primeira companhia de hardware de neurocomputadores e componente.

Infelizmente, os anos seguintes foram marcados por um entusiasmo exagerado de muitos pesquisadores, que passaram a publicar mais e mais artigos e livros que

faziam uma previsão pouco confiável para a época, sobre máquinas tão poderosas quanto o cérebro humano que surgiriam em um curto espaço de tempo. Isto tirou quase toda a credibilidade dos estudos desta área e causou grandes aborrecimentos aos técnicos de outras áreas.

Um período de pesquisa silenciosa seguiu-se durante 1969 a 1982, quando poucas pesquisas foram publicadas devido aos fatos ocorridos anteriormente. Entretanto, aqueles que pesquisavam nesta época, e todos os que se seguiram no decorrer de treze anos conseguiram novamente estabelecer um campo concreto para o renascimento da área.

Nos anos 80, muitos dos pesquisadores foram bastante corajosos e passaram a publicar diversas propostas para a exploração de desenvolvimento de redes neurais bem como suas aplicações. Porém talvez o fato mais importante deste período tenha ocorrido quando Ira Skurnick, um administrador de programas da DARPA *Defense Advanced Research Projects Agency* decidiu ouvir os argumentos da neuro computação e seus projetistas, e divergindo dos caminhos tradicionais dos conhecimentos convencionais, fundou em 1983 pesquisas em neuro computação. Este ato não só abriu as portas para a neuro computação, como também deu à DARPA o status de uma das líderes mundiais em se tratando de "moda" tecnológica.

Outra "potência" que emergiu neste período foi John Hopfield, renomado físico de reputação mundial, se interessou pela neuro computação, e escreveu artigos que percorreram o mundo todo persuadindo centenas de cientistas, matemáticos, e tecnólogos altamente qualificados a se unirem esta nova área emergente.

Apesar de um terço dos pesquisadores da área terem aderido à mesma pela influência de Hopfield, foi em 1986 que este campo de pesquisa "explodiu" com a publicação do livro "*Parallel Distributed Processing*" (Processamento Distribuído Paralelo) editado por David Rumelhart e James McClelland.

Em 1987 ocorreu em São Francisco a primeira conferência de redes neurais em tempos modernos, a *IEEE International Conference on Neural Networks*, e também foi formada a *International Neural Networks Society* (INNS). A partir destes acontecimentos decorreram a fundação do INNS journal em 1989, seguido do *Neural Computation* e do *IEEE Transactions on Neural Networks* em 1990.

Desde 1987, muitas universidades anunciaram a formação de institutos de pesquisa e programas de educação em neuro computação.

Alguns dos fatos mencionados são listados abaixo:

Neurofisiologista McCulloch e matemático (Walter Pitts 1943), cujo trabalho fazia uma analogia entre células vivas e o processo eletrônico, simulando o comportamento do neurônio natural, onde o neurônio possuía apenas uma saída, que era uma função de entrada (threshold) da soma do valor de suas diversas entradas;

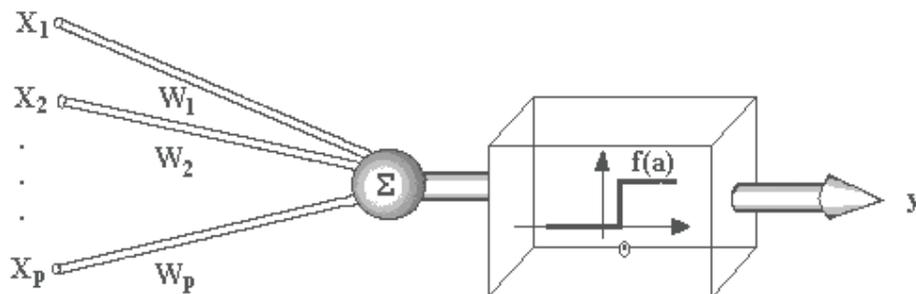


Figura 3.2 - Neurônio artificial projetado por McCulloch

O psicólogo (Donald Hebb 1949), demonstrou que a capacidade da aprendizagem em redes neurais vem da alteração da eficiência sináptica, isto é, a conexão somente é reforçada se tanto as células pré-sinápticas quanto as pós-sinápticas estiverem excitadas;

E (Roseblatt ,1958) mostrou em seu livro (*Principles of Neurodynamics*) o modelo dos "Perceptrons". Nele, os neurônios eram organizados em camada de entrada e saída, onde os pesos das conexões eram adaptados a fim de se atingir a eficiência sináptica;

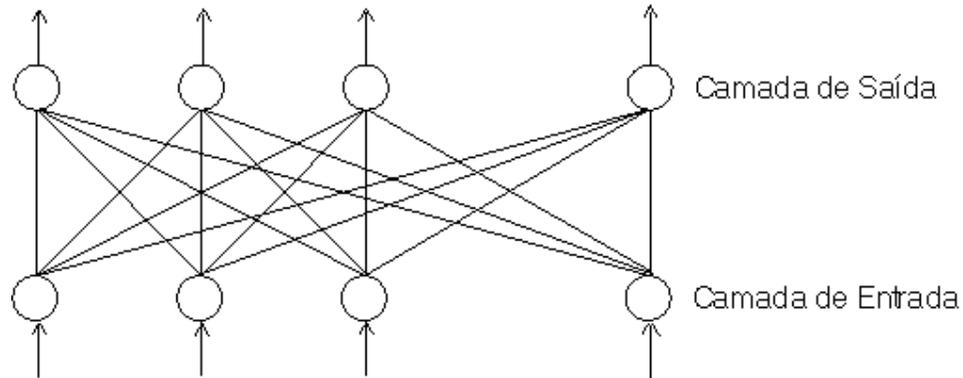


Figura 3.3 - Rede de perceptrons proposta por Roseblatt

Em 1960 surgiu a rede Adaline Adaptive Linear Network e o Madaline Many Adaline perceptron, proposto por Widrow e Hoff. O Adaline/Madaline utilizou saídas analógicas em uma arquitetura de três camadas.

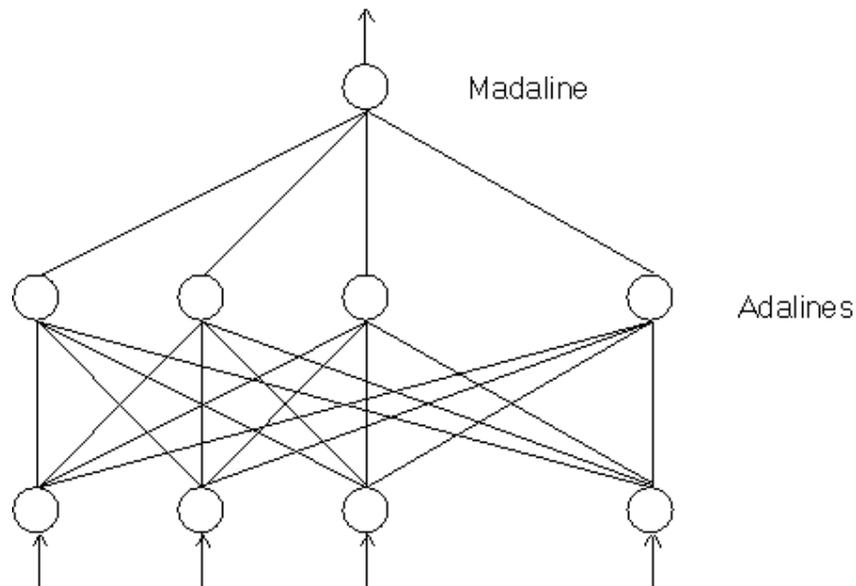


Figura 3.4 - Redes ADALINE e MADALINE

Muitos históricos desconsideraram a existência de pesquisa nessa área nos anos 60 e 70 e apontam uma retomada das pesquisas com a publicação dos trabalhos do físico e biólogo (Hopfield, 1982) relatando a utilização de redes simétricas para otimização, através de um algoritmo de aprendizagem que estabilizava uma rede binária simétrica com realimentação.

Rumelhart, Hinton e Williams introduziram o poderoso método Retropropagação.

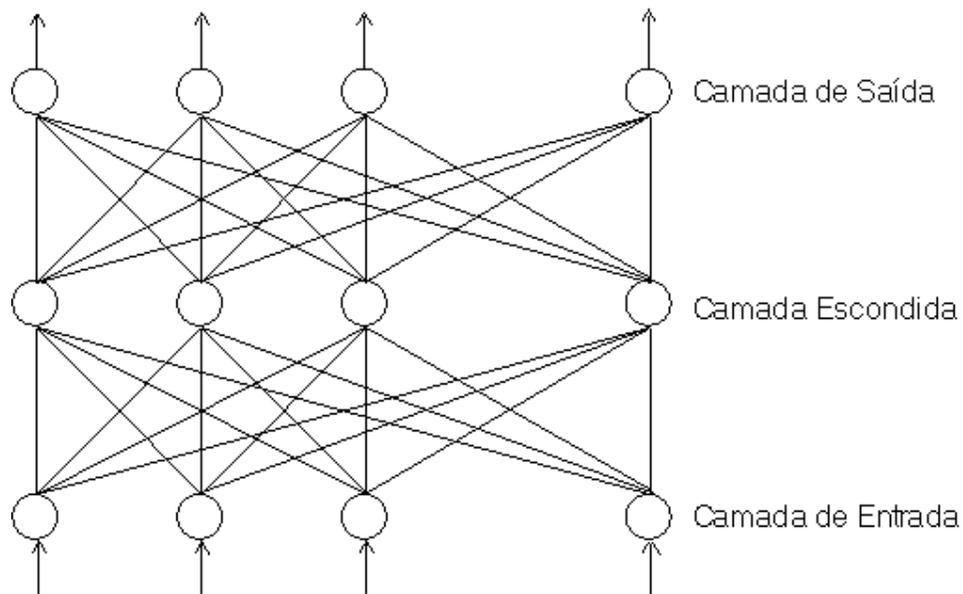


Figura 3.5 - Estrutura do método *Retropropagação*

Cooper, Cowan, Fukushima, Von der Malsburg e muitos outros foram alguns dos muitos pesquisadores dos anos 60 e 70, cujos estudos não devem ser menosprezados.

### 3.3 Neurocomputação

Os modelos neurais procuram aproximar o processamento dos computadores ao cérebro. As redes neurais possuem um grau de interconexão similar à estrutura do cérebro e um computador convencional moderno a informação é transferida em tempos específicos dentro de um relacionamento com um sinal para sincronização.

A tabela abaixo traça um comparativo entre o cérebro humano e o computador:

Tabela 3.1 - Quadro comparativo entre cérebro e o computador

Parâmetro	Cérebro	Computador
Material	Orgânico	Metal e plástico
Velocidade	Milisegundos	Nanosegundos
Tipo de Processamento	Paralelo	Seqüencial
Armazenamento	Adaptativo	Estático
Controle de Processos	Distribuído	Centralizado
Número de elementos processados	10 e 11 à 10 e 14	10 e 5 à 10 e 6
Ligações entre elementos processados	10.000	<10

O mesmo paralelo pode ser traçado comparando o computador com as redes neurais. Para tanto, a comparação não se dará com um computador específico encontrado no mercado, mas sim com o paradigma predominante nos computadores atuais.

Tabela 3.2 - Quadro comparativo entre computadores e neurocomputadores

Computadores	Neurocomputadores
Executa programas	Aprende
Executa operações lógicas	Executa operações não lógicas, transformações, comparações
Depende do modelo ou do programador	Descobre as relações ou regras dos dados e exemplos
Testa uma hipótese por vez	Testa todas as possibilidades em paralelo

### 3.4 Redes Neurais Artificiais

As redes neurais artificiais consistem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São mais que isso são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto que o cérebro de um mamífero pode ter muitos bilhões de neurônios.

Apesar da complexidade das redes neurais não permitir uma única definição, as linhas seguintes seguem como uma tentativa das inúmeras definições ou interpretações do que seja realmente uma rede neural.

Um grafo direcionado é um objeto geométrico que consiste de um conjunto de pontos, chamados nós, ao longo de um conjunto de segmentos de linhas direcionadas entre eles. Uma rede neural é uma estrutura de processamento de informação distribuída paralelamente na forma de um grafo direcionado, com algumas restrições e definições próprias.

Os nós deste grafo são chamados elementos de processamento. Suas arestas são conexões, que funcionam como caminhos de condução instantânea de sinais em uma única direção, de forma que seus elementos de processamento podem receber qualquer número de conexões de entrada. Estas estruturas podem possuir memória local, e também possuir qualquer número de conexões de saída desde que os sinais nestas conexões sejam os mesmos. Portanto, estes elementos têm na verdade uma única conexão de saída, que pode dividir-se em cópias para formar múltiplas conexões, sendo que todos carregam o mesmo sinal.

Então, a única entrada permitida para a função de transferência (que cada elemento de processamento possui) são os valores armazenados na memória local do elemento de processamento e os valores atuais dos sinais de entrada nas conexões recebidas pelo elemento de processamento. Os únicos valores de saída permitidos a partir da função de transferência são valores armazenados na memória local do elemento de processamento, e o sinal de saída do mesmo.

A função de transferência pode operar continuamente ou episodicamente. Sendo que no segundo caso, deve existir uma entrada chamada "*activate*" que causa o ativamento da função de transferência com o sinal de entrada corrente e com valores da memória local, e produzir um sinal de saída atualizado (ocasionalmente alterando valores da memória). E no primeiro caso, os elementos estão sempre ativados, e a entrada "*activate*" chega através de uma conexão de um elemento de processamento agendado que também é parte da rede.

Sinais de entrada para uma rede neural a partir de fora da rede chegam através de conexões que se originam do mundo externo, saídas da rede para o mundo externo são conexões que deixam a rede.

De forma geral, a operação de uma célula da rede se resume em:

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível excede um limite *threshold* a unidade produz uma saída;

### **3.4.1 O Neurônio Artificial e a Rede Neural**

Assim como o sistema nervoso é composto por bilhões de células nervosas, a rede neural artificial também seria formada por unidades que nada mais são que pequenos módulos que simulam o funcionamento de um neurônio. Estes módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações.

### 3.4.2 O Neurônio Artificial

O fisiologista Warren MacCulloch interpretou o funcionamento do neurônio biológico como sendo um circuito de entradas binárias combinadas por uma soma ponderada (com pesos) produzindo uma entrada efetiva:

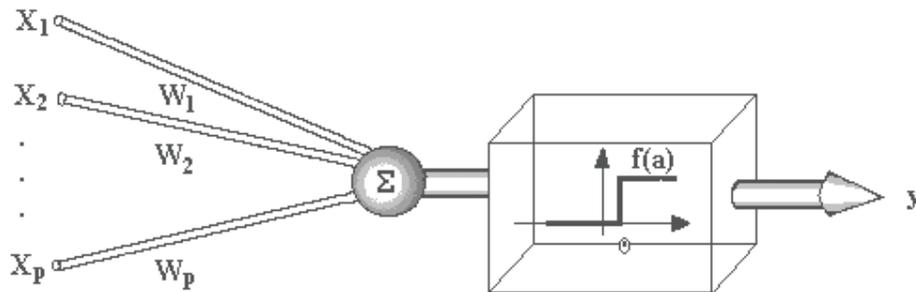


Figura 3.6 - Modelo de McCulloch e Pitts

No modelo geral de neurônio (Figura 3.6) as entradas  $W_i U_i$  são combinadas usando uma função  $F$ , para produzir um estado de ativação do neurônio (correspondente à frequência de descarga do neurônio biológico). As entradas chegam através dos dendritos e tem um peso atribuído pela sinapse.

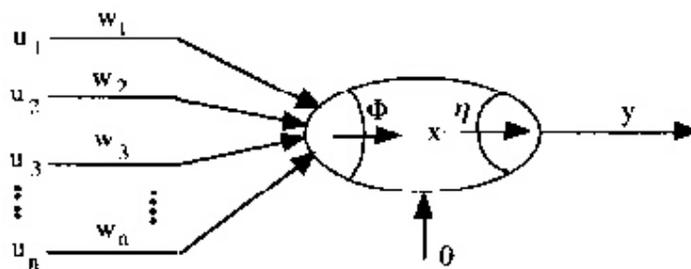


Figura 3.7 - Esquema de um neurônio artificial (Barreto, 1997)

A função básica de um neurônio é somar as entradas e retornar uma saída, caso esse valor seja maior que o valor de soma (threshold).

### 3.4.3 A Rede Neural Artificial (*Perceptron Multi-Camada e Redes Diretas Multicamadas*)

Segundo Barreto 1997, informalmente uma rede neural artificial RNA é um sistema composto por vários neurônios de modo que as propriedades de sistema complexo sejam usadas. Estes neurônios estão ligados por conexões, chamadas conexões sinápticas. Alguns neurônios recebem excitações do exterior e são chamados neurônios de entrada e correspondem aos neurônios dos órgãos dos sentidos. Outros têm suas respostas usadas para alterar, de alguma forma, o mundo exterior e são chamados neurônios de saída e correspondem aos motoneurônios que são os neurônios biológicos que excitam os músculos. Os neurônios que não são nem entrada nem saída são conhecidos como neurônios internos. Estes neurônios internos à rede tem grande importância e são conhecidos na literatura saxônica como “hidden”.

O perceptron tem saída de cada neurônio binário. Entretanto é comum chamar de perceptron multicamada, a uma rede em que se distinguem neurônios de entrada, neurônios de saída, e neurônios internos, arrumados formando camadas, se bem que os neurônios não sejam binários e tenham uma não linearidade do tipo função logística, tangente hiperbólica, ou outra função qualquer. Muitas vezes, esta função é derivável e se emprega o algoritmo da retropropagação (“backpropagation”), o que leva muitos autores, pouco preocupados com não ambigüidade de seus escritos, a chamarem estas redes de redes de retropropagação ou simplesmente usando a expressão em inglês, redes backpropagation.

Estritamente o perceptron multicamada é uma rede direta multicamada com neurônios binários. Note-se que na rede direta multicamada cada neurônio de uma camada se liga somente a neurônios da camada vizinha.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessários um conjunto de regras rígidas pré-fixadas e algoritmos.

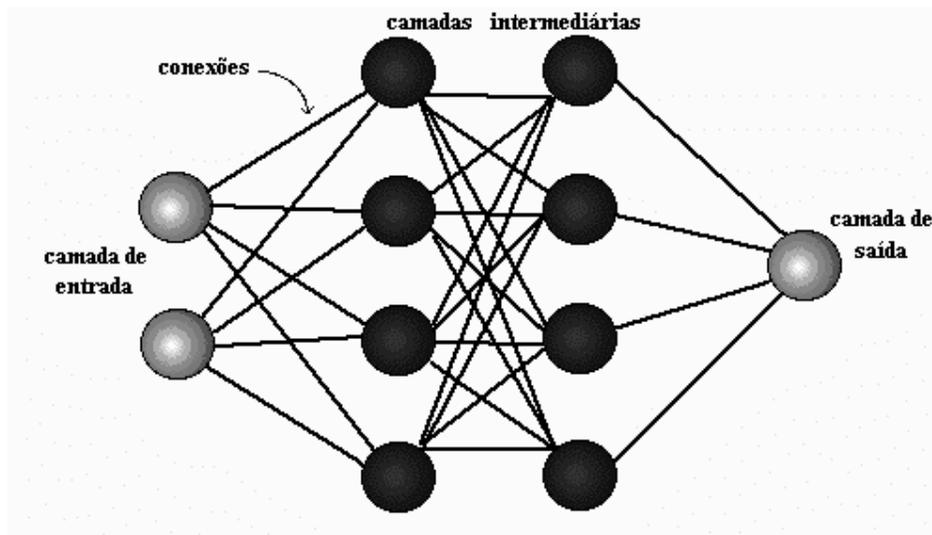


Figura 3.8 - Organização em camadas.

Usualmente as camadas são classificadas em três grupos:

- Camada de Entrada: onde os padrões são apresentados à rede;
- Camadas Intermediárias ou Ocultas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- Camada de Saída: onde o resultado final é concluído e apresentado.

Redes neurais são também classificadas de acordo com a arquitetura em que foram implementadas, topologia, características de seus nós, regras de treinamento, e tipos de modelos.

### 3.5 Classificação de Redes Neurais Artificiais

Um dos objetivos da pesquisa sobre redes neurais na computação é desenvolver morfologias neurais matemáticas, não necessariamente baseadas na biologia, que podem realizar funções diversas. Na maior parte dos casos, modelos neurais são compostos de muitos elementos não lineares que operam em paralelo e que são classificados de acordo com padrões ligados à biologia.

Quando um processo é criado visando utilizar aspectos de redes neurais começam com o desenvolvimento de um neurônio artificial ou computacional baseado no entendimento de estruturas biológicas neurais, seguidas do aprendizado de mecanismos voltados para um determinado conjunto de aplicações. Ou em outras palavras, seguindo as três etapas:

O desenvolvimento de modelos neurais motivado por neurônios biológicos;

Modelos de estruturas e conexões sinápticas;

O aprendizado das regras (um método de ajuste de pesos ou forças de conexões internodais)

Por causa de diferenças entre algumas ou às vezes todas as entidades envolvidas, diferentes estruturas de redes neurais tem sido desenvolvidas por pesquisadores. Do ponto de vista estrutural, a arquitetura de redes neurais pode ser classificada como estática, dinâmica ou *fuzzy*, e de única camada ou múltiplas camadas (seu significado é mais bem especificado na parte de Topologia de Redes Neurais Artificiais). Além disso, diferenças computacionais surgem também quando se trata da maneira com que são feitas as conexões existentes entre os neurônios. Estas conexões podem ser estritamente no sentido de ida, no sentido de ida e volta, lateralmente conectadas, topologicamente ordenadas ou híbridas.

A aplicação de redes neurais pode ser classificada em classes distintas: Reconhecimento de padrões e Classificação; Processamento de imagem e visão; Identificação de sistema e controle e Processamento de sinais. É importante verificar

que uma determinada aplicação de um sistema baseado em rede neural não precisa necessariamente ser classificada em apenas uma das citadas acima.

### 3.6 Topologias de Redes Neurais Artificiais

#### 3.6.1 Disposição dos Neurônios:

De acordo com Rummelhart, a rede neural deve possuir no mínimo duas camadas, a de entrada de dados e a da saída dos resultados. Como a rede apresenta desempenho muito limitado com somente duas camadas, a adição de uma camada intermediária faz-se necessária. Neste tipo de configuração, cada neurônio está ligado com todos os outros das camadas vizinhas, mas neurônios da mesma camada não se comunicam, além da comunicação ser unidirecional, apresentando assim um comportamento estático.

Já a rede neural de Hopfield apresenta comportamento dinâmico e fluxo de dados multidirecional devido à integração total dos neurônios, desaparecendo assim a idéia das camadas bem distintas. Com isso seu funcionamento é mais complexo, havendo certas complicações, seja na fase de aprendizado quanto na fase de testes. Seu uso é direcionado à problemas de minimização e otimização, como por exemplo de percurso de caminhões.

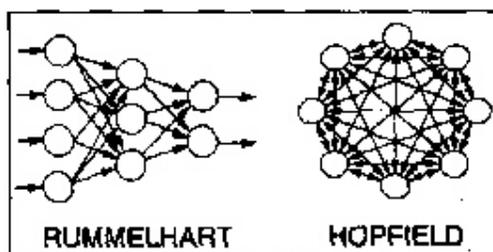


Figura 3.9 - Modelos de Rummelhart e Hopfield

Há pesquisadores como Hecht - Nielsen, que afirmam que com apenas uma camada oculta já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos. De acordo com Hecht - Nielsen, a camada oculta deve ter por volta de  $2i+1$  neurônios, onde  $i$  é o número de variáveis de entrada.

Outros, no caso de Cybenko, defendem o uso de duas camadas ocultas.

No caso de Kucricky, empiricamente observou-se que para cada 3 neurônios da primeira camada oculta era preciso um da segunda camada.

Já Lippmann afirma que a segunda camada oculta deve ter o dobro de neurônios da camada de saída. No caso de apenas uma camada oculta, ela deverá ter  $s(i+1)$  neurônios, onde  $s$  é o número de neurônios de saída e  $i$  o número de neurônios na entrada.

Outros autores definem o número máximo como:

$$- O_{max} = c / 10.(i+s)$$

Onde  $s$ : número de neurônios de saída

$i$ : número de neurônios na entrada

Em redes pequenas o número de neurônios da camada oculta pode ser a média geométrica entre o número de neurônios de entrada pelo número de neurônios de saída.

Independente de cada abordagem, quanto mais camadas de neurônios, melhores é o desempenho da rede neural, pois aumenta a capacidade de aprendizado, melhorando a precisão com que ela delimita regiões de decisão. Estas regiões de decisão são intervalos fixos onde a resposta pode estar. A camada de entrada possui um neurônio especial chamado de "bias" e serve para aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento à ela fornecido.

Ciclos:

### 3.6.1.1 Redes Diretas

São redes neurais cujo grafo não possui ciclos e podem ser representadas em camadas. Por exemplo, os neurônios que recebem sinais de excitação do meio externo estão na camada de entrada; os neurônios que estão na saída são chamados de camada de saída.

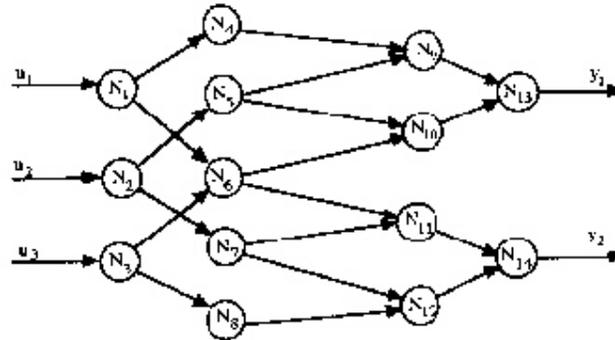


Figura 3.10 - Rede Direta (Barreto 1997)

### 3.6.1.2 Redes com ciclos

São redes em que o grafo de conectividade contém pelo menos um ciclo. São também chamadas redes com realimentação ou com feedback.

### 3.6.1.3 Redes simétricas

São redes cuja matriz (do grafo de conectividade) é simétrica, sendo um caso particular das redes com ciclos.

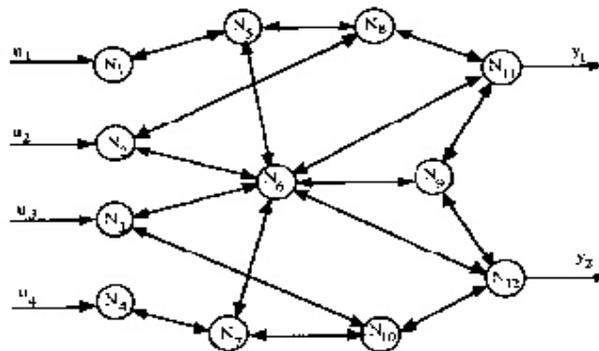


Figura 3.11 - Rede Simétrica (Barreto 1997)

### 3.7 Processos de Aprendizado de uma Rede Neural Artificial

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

A rede neural se baseia nos dados para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitar modelos espúrios. 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.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente.

Nesse contexto existem os seguintes paradigmas de aprendizado (Barreto 1997):

- Por independência de quem aprende

As Redes Neurais Artificiais aprendem por memorização, contato, exemplos, por analogia, por exploração e também por descoberta.

- Por retroação do mundo

Diz respeito a ausência ou presença de realimentação explícita do mundo exterior, ou seja, que em certos intervalos de tempo um agente assinala acertos e erros.

Aprendizado Supervisionado: utiliza um agente externo que indica à rede um comportamento bom ou ruim de acordo com o padrão de entrada

Aprendizado Não Supervisionado (auto-organização): não utiliza um agente externo indicando a resposta desejada para os padrões de entrada, utiliza-se, entretanto, exemplos de coisas semelhantes para que a rede responda de maneira semelhante.

- Por Finalidade do Aprendizado

Auto-associador: é apresentada à rede uma coleção de exemplos para que ela memorize.

Quando se apresenta um dos elementos da coleção de exemplos mas de modo errôneo, a rede deve mostrar o exemplo original, funcionando assim como um filtro.

Hetero-associador: é uma variação do Auto-associador, mas que se memoriza um conjunto de pares. O sistema aprende a reproduzir o segundo elemento do par mesmo que o primeiro esteja pouco modificado, funcionando desta maneira como um reconhecedor de padrões.

É necessário também que exista um Detector de Regularidades, que nada mais é que um reconhecedor de padrões em que o sistema deve se auto-organizar e criar padrões possíveis.

Podemos denominar ainda ciclo como sendo uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executado de dois modos:

Modo Padrão: A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.

Modo Batch: Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro fazem-se as correções dos pesos.

Hebbian Learning

Descreveremos aqui uma sugestão simples de uma teoria que responde à pergunta: Como nós aprendemos? A base desta teoria data do ano de 1949 do livro "*Organization of Behavior*", escrito por Hebb. A idéia central estava na seguinte afirmação:

"Quando um axônio de uma célula A está próxima o suficiente de excitar uma célula B e repetidamente ou persistentemente toma parte em ativá-la, algum processo crescente ou mudança metabólica se apossa de uma ou ambas as células de forma que a eficiência de A, assim como a de uma das células de B excitadas, são aumentadas".

Assim como o modelo de McCulloch-Pitts, esta lei de aprendizagem não explica tudo sobre este tema, porém, de uma forma ou de outra, ela está presente em muitos modelos de redes neurais que conhecemos hoje. Utilizaremos como exemplo, o condicionamento clássico, o experimento de Pavlov, para ilustrar a idéia anteriormente exposta.

Pelo fato das conexões através de neurônios ocorrerem através de sinapses, é realmente razoável imaginar que qualquer mudança que ocorra durante o aprendizado ocorra nestas. Hebb teorizou que a área da junção sináptica aumenta. Teorias mais recentes afirmam que o responsável por isto é um aumento na taxa de liberação neurotransmissora efetuada pela célula pré-sináptica. Em qualquer evento, mudanças certamente ocorrem na sinapse. Se nem a célula pré, nem a pós sináptica são alteradas como um todo, outras respostas, que não são relacionadas ao experimento podem ser reforçadas.

#### Desenvolvimento de Aplicações

Esta página procura ilustrar os passos necessários para o desenvolvimento de aplicações utilizando redes neurais artificiais.

## **CAPÍTULO 4 – ANÁLISE DOS EXPERIMENTOS.**

Esse capítulo descreve o modelo implementado para o problema de predição da percentagem de carne suína na carcaça resfriada. Uma análise minuciosa dos dados é feita e com base nessa análise, a topologia da rede (tamanho, estrutura e conexões) e os parâmetros do algoritmo de treinamento (taxa de aprendizado, termo de momento e outros) são definidos. A rede é treinada e os resultados são analisados e confrontados com os obtidos pelo modelo linear de regressão múltipla, modelo este, utilizado atualmente pela Empresa Frigorífica S.A. Ind. e Com. na determinação do índice de bonificação.

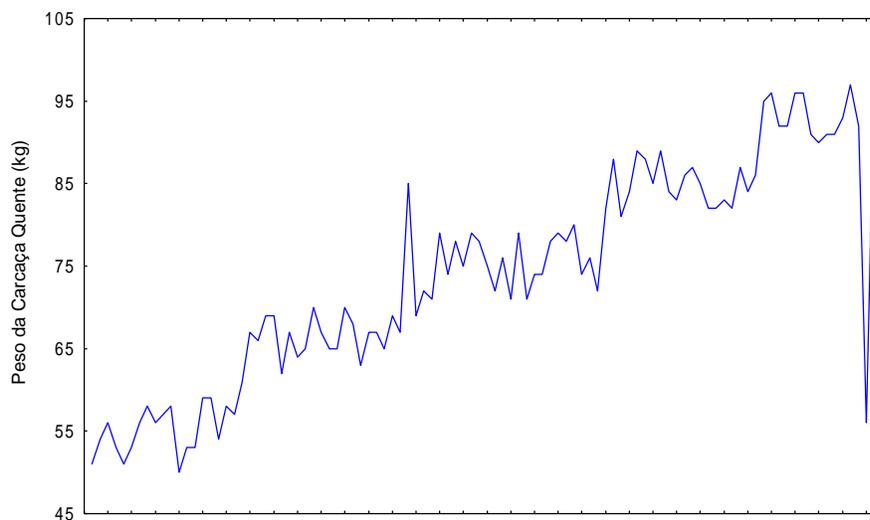
### **4.1 Dados**

Os dados utilizados neste trabalho provêm de levantamentos efetivados por técnicos da Empresa Frigorífica S.A. Ind. e Com. No levantamento, uma amostra de cem suínos foi selecionada e as seguintes variáveis foram mensuradas: Peso da carcaça quente – PCarq (kg), Espessura de toucinho avaliada entre a última e penúltima costela – Esp (mm) e Profundidade de músculo avaliada entre a última e penúltima costela – Mus (mm). Após, esses cem suínos foram dissecados e a Percentagem de carne na carcaça resfriada (PCmf) foi avaliada. Segundo a equipe técnica, a partir das três primeiras variáveis é possível prever a PCmf. Uma vez que a dissecação de todos os animais para a determinação do PCmf é impossível, quanto melhor a predição do PCmf feita, maior será a confiabilidade no índice de bonificação e mais justa será a tipificação de carcaças.

Antes de se aplicar qualquer metodologia a um problema deve-se analisar, além da natureza do problema, os dados existentes. O não conhecimento dos dados pode deteriorar o desempenho do método aplicado.

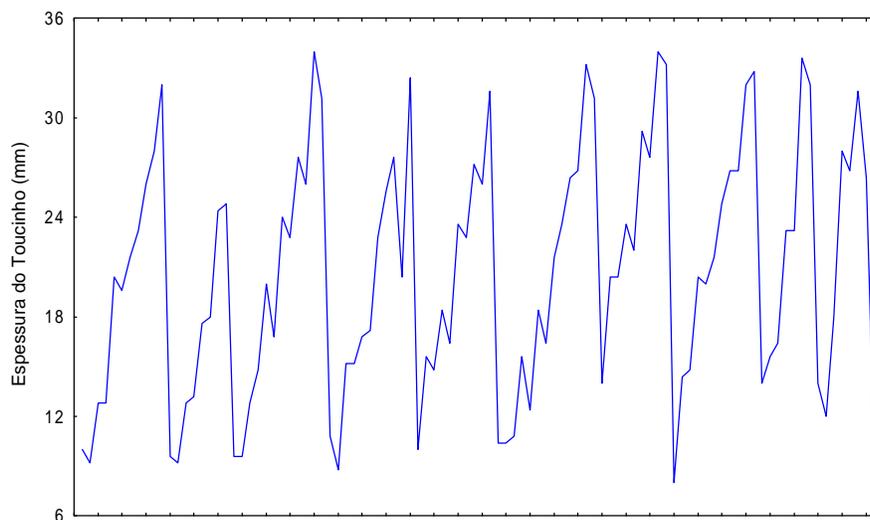
O problema é ainda maior quando o modelo que se deseja aplicar é um modelo conexionista. RNAs são baseadas em dados. Se o conjunto de treinamento da rede for mau montado, a rede certamente não será capaz de abstrair o padrão composto nos dados.

Sendo assim, analisou-se o comportamento de cada uma das variáveis utilizadas, além da inter-relação entre essas variáveis.



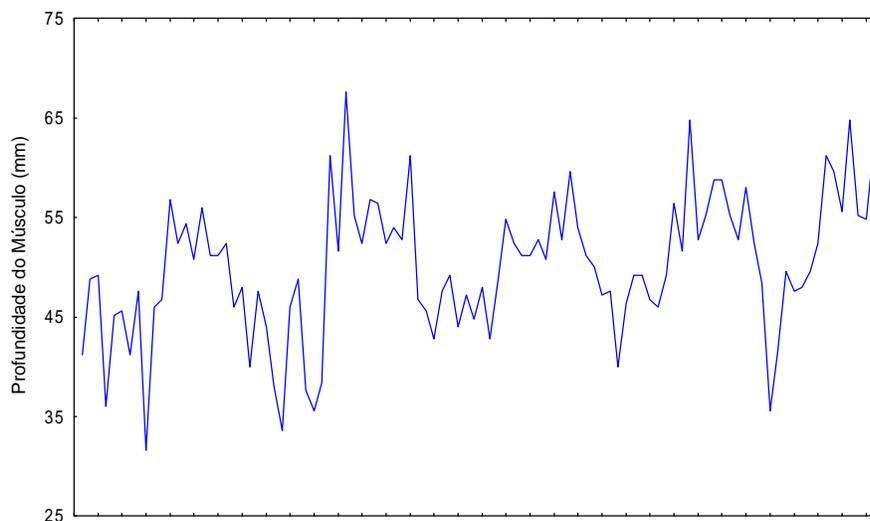
**Figura 4.1 – Peso da carcaça quente (kg).**

A fig. 4.1 apresenta a variável peso da carcaça quente. Para obter-se uma amostra significativa da população existente, procura-se variar o peso do animal amostrado. Devido a esse artifício, pode-se observar uma tendência crescente nos dados.



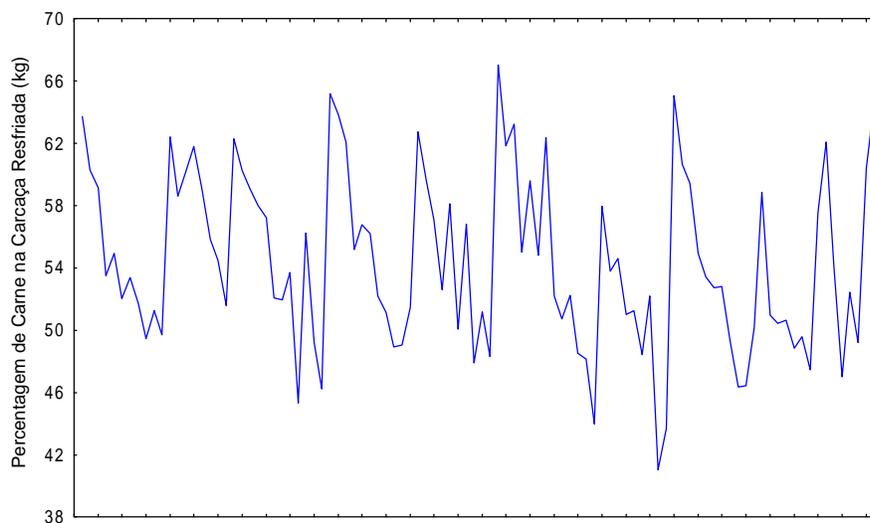
**Figura 4.2 – Espessura do toucinho (mm).**

A variável Espessura do toucinho (fig. 4.2) variou de forma regular entre 8 mm a 34 mm., independente do peso do animal.



**Figura 4.3 – Profundidade do músculo (mm).**

A fig. 4.3 apresenta o comportamento da variável Profundidade do músculo. Diferente da Espessura do toucinho, a profundidade mínima do músculo tende a aumentar, mesmo que muito pouco, conforme o peso do animal aumenta. Observam-se também, picos e reduções de largura oscilatória.



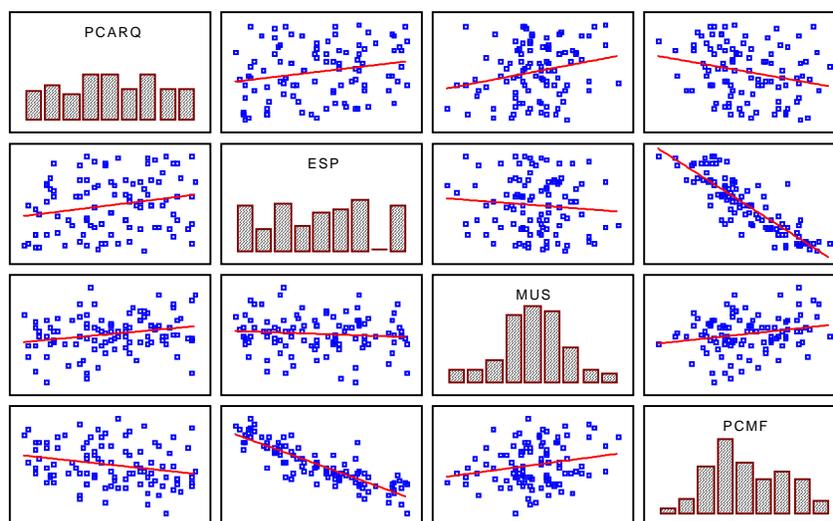
**Figura 4.4 – Porcentagem de carne da carcaça resfriada .**

A variável a ser prevista (fig. 4.4) também variou bastante na amostra obtida. Como se pode observar ela apresenta sinais indicativos dos três padrões encontrados nas outras variáveis, o que indica que esta pode ser estimada com base nas outras três.

Para verificar se todas as variáveis eram significativa na previsão da percentagem de carne resfriada da carcaça quente no momento do abate, uma análise de correlação múltipla foi feita.

**Tabela 4.1 - Matriz de correlação entre as variáveis.**

	<b>PCarq</b>	<b>Esp</b>	<b>Mus</b>	<b>PCmf</b>
<b>PCarq</b>	1	0,216191	0,237874	-0,24562
<b>Esp</b>	0,216191	1	-0,09361	-0,86386
<b>Mus</b>	0,237874	-0,09361	1	0,216036
<b>PCmf</b>	-0,24562	-0,86386	0,216036	1



**Figura 4.5 – Gráfico de correlação entre as variáveis (Matlab).**

Examinando a correlação entre cada par de variáveis incluídas no modelo (tabela 4.1 ou fig. 4.5), observamos que a correlação entre PCarq e Esp é igual a 0,216 e PCarq e Mus é igual a 0,238 indicando uma fraca associação positiva entre as variáveis. Podemos ver também que a correlação entre PCarq e PCmf é de  $-0,246$ , indicando uma correlação negativa fraca entre as variáveis. Além disso, notamos que não existe praticamente correlação entre as variáveis explicativas Esp e Mus ( $-0,094$ ) e a variável Esp apresenta uma correlação negativa forte com a variável de resposta ( $-0,864$ ).

Isso mostra que animais com maior peso da carcaça quente tem espessura de toucinho e profundidade do músculo maior; Já, a percentagem de carne na carcaça resfriada desses animais é menor. Observa-se também, que animais com uma espessura de toucinho grande tem menor percentagem de carne na carcaça resfriada. Assim,

animais com menor peso da carcaça quente, apresentam espessura de toucinho menor e maior percentagem de carne na carcaça resfriada (o que seria desejável).

Uma correlação significativa grande entre duas ou mais variáveis explicativas indica que apenas uma delas deve ser levada em conta na predição. Como no caso em estudo a correlação entre as três variáveis explicativas é pequena, decidiu-se utilizar as três variáveis. Além disso, a análise de correlação entre as três variáveis preditoras e a variável a ser prevista (tabela 4.1 ou fig. 4.5) indica que todas influenciam na determinação da percentagem de carne da carcaça resfriada.

Devido à grande variação de grandeza na magnitude dos dados, a função logaritmo foi aplicada a estes.

## 4.2 Modelo Proposto

O modelo de rede proposto foi uma RNA direta MLP, totalmente conectada. Essa escolha deu-se devido ao sucesso destas em problemas de predição. Exemplos podem ser encontrados em (Fernandes et al. 1995), (Corrêa & Portugal 1995), (Braga et al. 1996), (Tamari et al. 1996), (Valença, 1997) entre outros.

Outro tipo de rede muito utilizada para predição é a rede RBF (*Radial Basis Function*). Porém, esta não foi utilizada neste trabalho porque, apesar de convergir mais rápido que uma rede MLP para uma solução ótima, a rede RBF perde em termos de capacidade de generalização (De Oliveira, 1999) (Braga et al., 2000). Este tipo de rede seria ótimo para problemas em que um treinamento on-line é necessário, não para um problema como o aqui exposto, onde se busca um modelo estático, e prima-se por uma boa capacidade de generalização.

Tendo escolhido o modelo de rede a ser utilizado (Rede direta multicamadas), parte-se para a definição deste.

O número de neurônios da camada de entrada da rede é definido em função dos resultados da análise de correlação. Ou seja, a camada de entrada conterá três neurônios, um para cada variável explicativa (PCarq, Esp e Mus). A camada de saída da rede é

definida pelo número de variáveis resposta do problema, neste caso apenas a variável percentagem de carne na carcaça resfriada (PCmf).

O número de camadas intermediárias da rede variou entre [1 e 2] em função dos estudos de (Bybenko 1988), citado por (Braga et al. 2000, p. 49). Esse estudo diz que uma camada intermediária é suficiente para se implementar qualquer função contínua. Ainda segundo o autor, a utilização de duas camadas intermediárias permite a aproximação de qualquer função.

Essa característica fazem das RNAs aproximadoras universais de funções multivariáveis. Característica esta importante em problemas como o aqui exposto onde, como mostra a análise de correlação efetuada, a pouca ou nenhuma correlação entre as variáveis explicativas e a variável de resposta.

A determinação do número ótimo de neurônios da(s) camada(s) intermediária(s) é um problema ainda em aberto no campo de RNAs. Este geralmente é determinado pelo método heurístico. Inicia-se com uma das regras ad-hoc conhecidas, e a partir destas eliminam-se ou acrescentam-se neurônios.

Das regras ad-hoc mais conhecidas na literatura tem-se que, *o número de neurônios da camada intermediária é igual à média geométrica do número de neurônios das camadas de entrada e saída, ou ainda, é igual a raiz quadrada da quantidade de neurônios na camada de entrada somado ao número de neurônios da camada de saída da rede.*

Para o modelo proposto, experimentos foram feitos considerando-se fatores como convergência, generalização e escalabilidade (ver item 4.4). Testou-se uma e duas camadas intermediárias com o número de neurônios de cada camada variando de [2 a 8]. As simulações foram feitas utilizando-se a *toolbox* de RNA do programa MATLAB, versão 6.3.

Com duas camadas internas, de dois e três neurônios cada, o desempenho da rede foi igual ao desempenho de uma rede com uma camada interna de dois ou três neurônios cada. Aumentando-se o número de neurônios da segunda camada interna, o desempenho da rede caiu. Sendo assim, na procura de uma arquitetura ótima (com uma boa escalabilidade), limitou-se a apenas uma camada interna. A tabela 4.2. apresenta a média de erro alcançada pelo método do gradiente descendente durante os ensaios.

Tabela 4.2 – Quanto ao número de neurônios da camada interna.

	N° neurônios camada interna					
<b>MSE</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>6</b>	<b>7</b>	<b>8</b>
<b>Média</b>	<b>0.0376089</b>	0.0334870	0.0293300	0.0248900	0.0240990	0.0233860

Como observado na tabela 4.2, a configuração da rede em que o erro minimizado pelo método do gradiente descendente chegou mais próximo de zero, foi a RNA(3, 8, 1). Porém, em termos de generalização a RNA(3, 2, 1) foi a que apresentou melhores resultados.

Como é sabido, a diminuição dos parâmetros livres (número de conexões) da rede aumenta a probabilidade de uma boa generalização.

Desse modo, a arquitetura selecionada foi a RNA(2,2,1) (fig. 4.5). Ou seja, uma RNA com três neurônios na camada de entrada, dois na camada intermediária e um na camada de saída.

A rede contém ainda três “bias”, um para cada neurônio da camada interna e de saída. Todos têm valor de entrada igual a um. O peso do “bias” é tratado como qualquer outro peso, tendo seu valor atualizado durante o treinamento. Essa entrada adicional serve para transladar a função de ativação no eixo  $x$ . Assim, no total, a rede possui onze conexões  $((3*2) + (2*1) + 3 \text{ bias})$ .

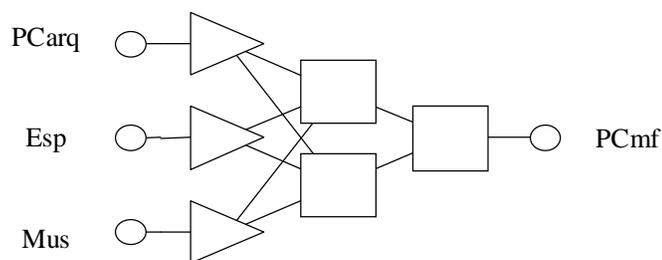


Figura 4.6 – Arquitetura de RNA proposta para a predição da porcentagem de carne na carcaça resfriada.

```

%Programa Principal
%Recebe como parâmetro o número de neurônios da camada interna.
function net = treina(nPe)
load BDados.mat;      %Arquivo com os dados
load PrevistoMQ.txt   %Arquivo com os dados previstos pelo método MQ

[minIn,maxIn,DInN] = normaliza(DIn); %Normaliza os dados de entrada
[minOut,maxOut,DOutN] = normaliza(DOut); %Normaliza os dados de saída
[DtstN, tstDN, DtrtN, trtDN, tstPrev] =
divdados(DInN,DOutN,PrevistoMQ); %Divide os dados-Treinamento/Teste
%Criação e definição dos parâmetros da rede
net= newff([-1 1;-1 1;-1 1],[nPe,1],{'tansig','tansig'},'traingdm');
net.trainParam.lr = 0.1;
net.trainParam.mc = 0.3;
net.trainParam.show = 10000;
net.trainParam.epochs = 20000;
net.trainParam.goal = 1e-2;

%Treinamento da rede
[net,tr] = train(net,DtrtN,trtDN,[],[],[],[]);

```

**Figura 4.7 – Script da função para criação e treinamento da rede (Matlab).**

A função de ativação utilizada (tangente hiperbólica) foi a mesma para todos os neurônios. A escolha deve-se ao fato de esta ser uma função simétrica que apresenta um bom comportamento matemático.

Essa função exige que os padrões de treinamento apresentado à rede sejam bipolares. Assim, os dados de treinamento e teste foram padronizados entre [-1 e 1], conforme a eq. 4.1.

$$V_{norm} = \frac{(2 * V - (V_{max} + V_{min}))}{(V_{max} - V_{min})} \quad (4.1)$$

onde:

$V_{norm}$  → valor normalizado

$V$  → valor original

$V_{min}$  → valor mínimo

$V_{max}$  → valor máximo

```

%Aplica o logaritmo e normaliza os dados entre [1,-1].
%Retorna uma matrix com dimensão igual a matrix de entrada com os
valores normalizados e
%o valor mínimo e máximo necessários para a desnormalização
posterior.

function [vmin,vmax,vn] = normaliza(v)
v = log(v);
[l,c] = size(v);
vmin = min(v,[],1);
vmax = max(v,[],1);
for i=1:c
    for j=1:l
        vn(j,i) = (2*v(j,i)-(vmax(i)+vmin(i)))/(vmax(i)-vmin(i));
    end
end
end

```

**Figura 4.8 – Script da função para normalização do conjunto de dados. (Matlab)**

Para testar a capacidade de generalização da rede, o conjunto de dados foi dividido em dois conjuntos distintos: treinamento (83,34% dos dados) e teste (16,66% dos dados).

Os dois conjuntos foram obtidos a partir da aleatorização do conjunto de dados. Essa técnica eliminou a tendência que pode ser vista nas variáveis PCarq (fig 4.1) e Mus (fig. 4.3). Essa tendência não é uma característica dos dados, e sim, do processo de amostragem, assim, deve ser eliminada.

A função criada para a divisão dos dados em treinamento e teste é listada na fig. 4.9.

```

%Divide os dados em dois conjuntos - treinamento e teste
%1/6 para teste e 5/6 para o treinamento
%Dtst (Dados teste), tstD (Desejado teste), Dtrt (Dados treinamento)
%trtD (Desejado treinamento), tstPrev(Conjunto teste MQ)

function [Dtst, tstD, Dtrt, trtD, tstPrev] = divdados(Bd, Desejado,
PrevistoMQ)

Bd = Bd'; Desejado = Desejado'; PrevistoMQ = PrevistoMQ';

[l,c] = size(Bd);

tst = 6:6:c;
trt = [1:6:c 2:6:c 3:6:c 4:6:c 5:6:c];
Dtst = Bd(:,tst); tstD = Desejado(:,tst);
Dtrt = Bd(:,trt); trtD = Desejado(:,trt);
tstPrev = PrevistoMQ(:,tst);

```

**Figura 4.9 – Script da função para divisão do conjunto de dados em treinamento e teste.**

O treinamento da rede foi feito pelo método de retropropagação do erro com momento, cuja configuração foi:

- Inicialização aleatória dos pesos entre  $[-1 \ 1]$ ;
- Número de épocas: 20000
- Constante de aprendizado ( $\alpha$ ): 0.1(constante);
- Termo de momento ( $\beta$ ): 0.3;
- Função de erro: MSE (Erro Quadrático Médio);
- Erro Máximo admissível:  $1e^{-2}$ .
- Frequência (periodicidade) de ajuste de pesos: por ciclo (*batch*).

A taxa de aprendizagem ( $\alpha$ ) define o tamanho do passo dado pelo erro, na superfície de erro em direção a solução desejada. Um valor grande, faz com que o algoritmo oscile sobre a solução desejada, já, um valor muito pequeno, garante a convergência, mas pode aumentar o tempo de treinamento. Normalmente varia-se o  $\alpha$  entre 0.05 a 0.25.

O termo de momento ( $\beta$ ) é a fração da mudança anterior dos pesos a ser adicionada na atualização atual dos pesos. Esse termo adicional tende a manter a direção de mudança no peso. Seu valor é, geralmente, positivo e menor que um.

O número de épocas é o número de vezes que o conjunto de treinamento é apresentado a rede. É definido em função da convergência e da capacidade de generalização da rede.

O número de épocas e o erro máximo admissível definem a parada do algoritmo, evitando que este não convirja para uma solução.

Neste trabalho, na determinação da rede ótima, testes foram feitos variando-se a taxa de aprendizagem (0.01, 0.05, 0.1 e 0.2), o termo de momento (0.2, 0.3, 0.4 e 0.9) e o número de épocas apresentadas à rede durante o treinamento (18000, 20000, 25000 e 30000).

### 4.3 Modelo Linear de Regressão Múltipla

Um modelo linear de regressão múltipla, como o utilizado atualmente para predição da percentagem de carne na carcaça resfriada, foi estimado utilizando-se o Sistema Computacional para Análise Estatística de Dados – *STATISTICA™*, versão 5.0.

Para dados com três variáveis explicativas, o modelo de regressão múltipla linear pode ser escrito como:

$$\hat{Y}_i = b_0 + b_1 X_{1i} + b_2 X_{2i} + b_3 X_{3i}$$

Utilizando-se o método dos Mínimos Quadrados<sup>1</sup>, os valores calculados dos três coeficientes de regressão de amostras encontrados são:

$$b_0 = 64,03709 \quad b_1 = -0,04555 \quad b_2 = -0,62368 \quad b_3 = 0,132051$$

onde o coeficiente de determinação ( $R^2$ ) é igual a 0,769129, ou seja, 77% da variação da percentagem de carne na carcaça resfriada podem ser explicados a partir do modelo atual.

Portanto, a equação de regressão múltipla para predição da *PCmf* pode ser expressa como:

$$\hat{Y}_i = 64,03709 - 0,04555X_{1i} - 0,62368X_{2i} + 0,132051X_{3i}$$

sendo que:

- $\hat{Y}_i$  – Percentagem de carne da carcaça resfriada do animal;
- $X_{1i}$  – Peso da carcaça quente do animal;
- $X_{2i}$  – Espessura do toucinho do animal;
- $X_{3i}$  – Profundidade de músculo do animal;

---

<sup>1</sup> Técnica matemática que minimiza as diferenças entre os valores reais e os valores que seriam previstos pela linha de regressão ajustada.

A interseção de  $\hat{Y}$  com  $b_0$ , calculada como 64,037, estima a percentagem de carne da carcaça resfriada, quando as outras três variáveis ( $PCarq$ ,  $Esp$  e  $Mus$ ) forem nulas. A inclinação do  $PCarq$ , em relação ao  $PCmf$  ( $b_1 = -0,045$ ), significa que, para um animal com uma dada  $Esp$  e  $Mus$ , estima-se que a  $PCmf$  decresça em 0,045, para cada  $kg$  a mais de carne na carcaça ( $PCarq$ ). A inclinação de  $Esp$ , em relação ao  $PCmf$  ( $b_2 = -0,623$ ), significa que, para um animal com uma dada  $PCarq$  e  $Mus$  estima-se que a  $PCmf$  decresça em 0,624, para cada  $mm$  a mais de espessura no toucinho ( $Esp$ ). A inclinação do  $Mus$ , em relação ao  $PCmf$  ( $b_3 = 0,132$ ) significa que, para um animal com uma dada  $PCarq$  e  $Esp$  a  $PCmf$  cresça em 0,132, para cada  $mm$  a mais de profundidade do músculo ( $Mus$ ).

#### 4.4 Avaliação do Modelo Proposto

O desempenho da RNA foi avaliado de acordo com três fatores: Convergência, Generalização e Escalabilidade.

- Convergência: indica se o procedimento de treinamento foi capaz de aprender a classificar corretamente os padrões apresentados, sob que condições e sob quais exigências computacionais. Em um tempo limite ( $\cong 10$  min), rodando em um PC com processador AMD-K6, 60MB de RAM e sistema Microsoft Windows® Me, o erro minimizado pelo método do gradiente descendente tendeu a zero ( $MSE = 0.0376089$ ).
- Generalização: diz respeito à capacidade da rede aprender através de um conjunto reduzido de exemplos e posteriormente dar respostas coerentes para dados não conhecidos.

Para verificar a capacidade de generalização dos dados, estes foram divididos (como citado no item 4.2) em dois conjuntos distintos: treinamento e teste. O desempenho foi avaliado em cima do conjunto de teste.

- Escalabilidade: diz respeito a ambos, convergência e generalização. É relativa ao procedimento de ajustar os parâmetros da RNA para que ela consiga convergir e generalizar bem.

A escalabilidade foi garantida pelos vários ensaios efetuados com diversas topologias e variando-se os parâmetros de controle do algoritmo de treinamento.

## 4.5 Resultados Obtidos

As previsões obtidas pela RNA foram comparadas com as provenientes do modelo de mínimos quadrados através dos seguintes indicadores: Erro Médio (ME), Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Erro Quadrático Médio Normal Absoluto (NRMSE) e Erro Percentual Absoluto Médio (MAPE).

**Tabela 4.3 – Medidas de desempenho utilizadas.**

Erro Médio (ME)	$ME = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)$ <p>onde <math>Y_t \rightarrow</math> Observações reais  <math>F_t \rightarrow</math> Previsões realizadas</p>
Erro Absoluto Médio (MAE)	$MAE = \frac{1}{n} \sum_{t=1}^n ( Y_t - F_t )$
Erro Quadrático Médio (MSE)	$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2$
Erro Quadrático Médio Normal Absoluto (NRMSE)	$NRMSE = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \bar{Y})^2}}$ <p>onde, <math>\bar{Y} = \frac{1}{n} \sum_{t=1}^n (Y_t)</math></p>

---

Erro Percentual Médio Absoluto (MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n |PE_t|$$

$$\text{onde, } PE_t = \left( \frac{Y_t - F_t}{Y_t} \right) \cdot 100$$


---

Estatística  $U_2$  de Theil

$$U_2 = \sqrt{\frac{\sum_{t=1}^{n-1} \left( \frac{F_{t+1} - Y_{t+1}}{Y_t} \right)^2}{\sum_{t=1}^{n-1} \left( \frac{F_{t+1} - Y_t}{Y_t} \right)^2}}$$

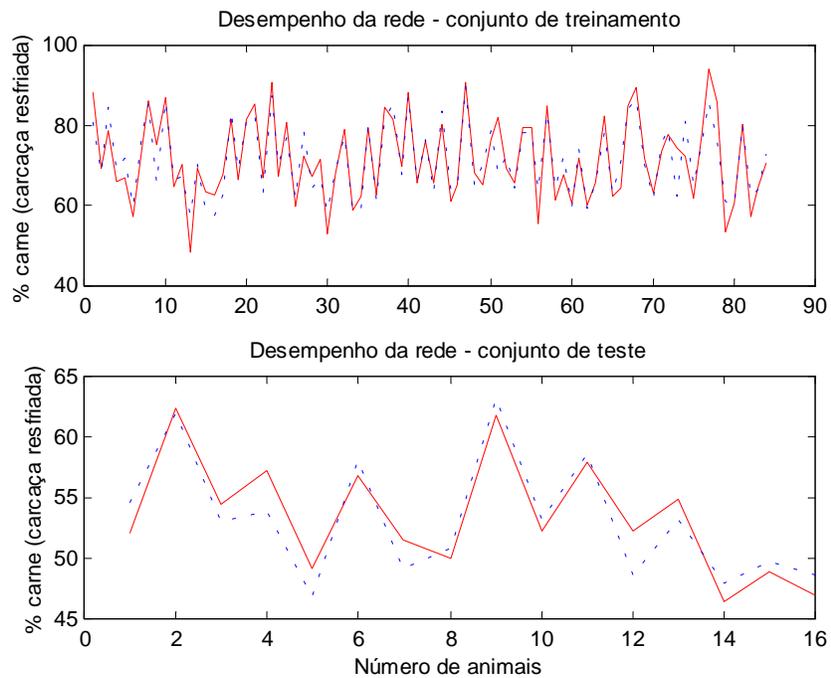
onde, para uma boa previsão, o valor de  $U_2$  deve variar entre [0 a 1]. Quanto menor o valor de  $U_2$ , melhor o modelo de previsão.

---

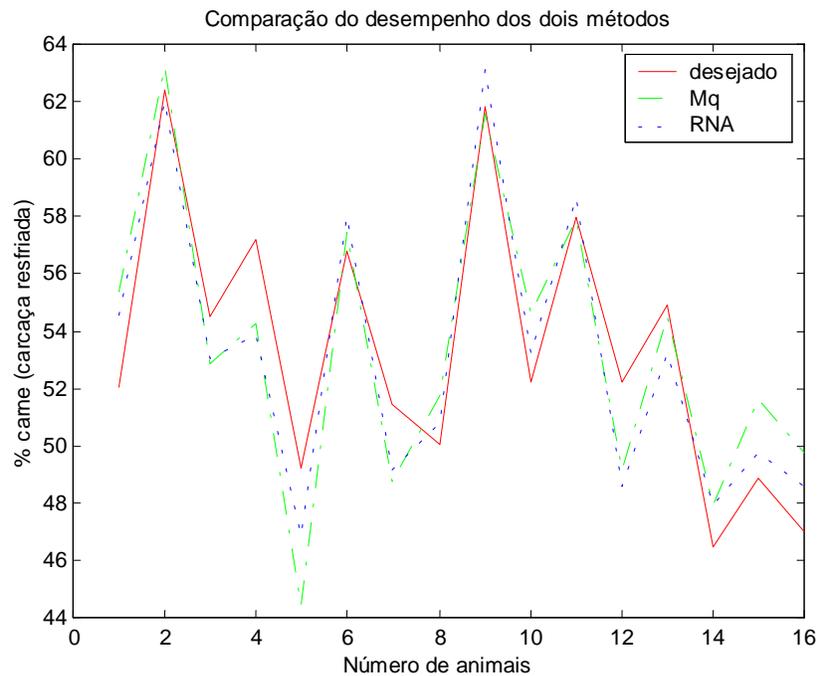
**Tabela 4.4 – Comparação dos resultados obtidos.**

<b>Medida de exatidão</b>	<b>RNA</b>	<b>MQ</b>
<b>ME</b>	-0,097	-0,173
<b>MAE</b>	0,097	0,173
<b>MSE</b>	1,500e-001	4,806e-001
<b>NRMSE</b>	0,035	0,063
<b>MAPE (%)</b>	0,206	0,369
<b><math>U_2</math></b>	<b>0,161</b>	<b>0,198</b>

A tabela 4.4 mostra os resultados obtidos. Como se podem observar, os erros cometidos pela RNA foram menores que os cometidos pelo método dos mínimos quadrados em todas as medidas de erro. A medida MAPE da RNA ficou em torno de 0,2%, enquanto a dos mínimos quadrados ficou em torno de 0,4%. A estatística  $U_2$  de *Theil* da rede, considerada a melhor medida para seleção do método de previsão mais preciso (Makridakis et al., 1998), foi de 0,18 comprovando a superioridade da RNA.



**Figura 4.10 – Desempenho da rede treinamento/teste.**



**Figura 4.11 – Comparação do desempenho da RNA com o método dos mínimos quadrados.**

As figuras 4.10 e 4.11, mostram o desempenho da rede no conjunto de treinamento, teste, e quando comparado com o método dos mínimos quadrados.

Tabela 4.5 – Medidas descritivas dos erros cometidos pelos dois modelos no teste de previsão.

	RNA	MQ
<b>Média</b>	0,235300	0,462562
<b>Mínimo - Máximo</b>	-2,5630 – 3,610300	-14,6020 – 6,334000
<b>Variância</b>	3,80886	31,26159
<b>Desvio Padrão</b>	1,951630	5,591206
<b>Erro Padrão</b>	0,487908	1,397802

A tabela 4.5 resume as estatísticas descritivas dos erros dos dois modelos. A média de erros da RNA é 0,23, enquanto a do método dos mínimos quadrados é de 0,46. Na figura 4.12 é apresentado o gráfico de dispersão desses erros.

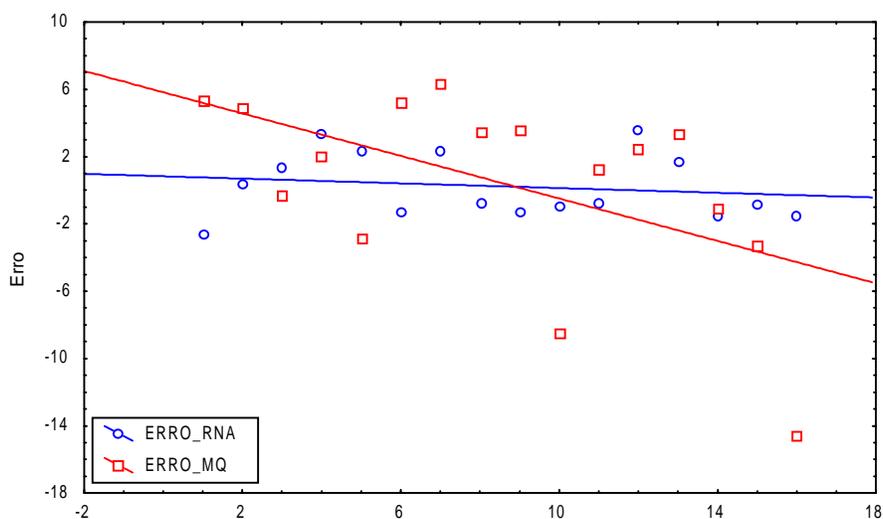


Figura 4.12 – Gráfico de dispersão dos erros cometidos pelos dois modelos.

A fig. 4.12 mostra o gráfico de dispersão dos erros obtidos pelos dois modelos. Observa-se que os erros cometidos pelo método dos mínimos quadrados estão bem mais dispersos do que os erros cometidos pela RNA.

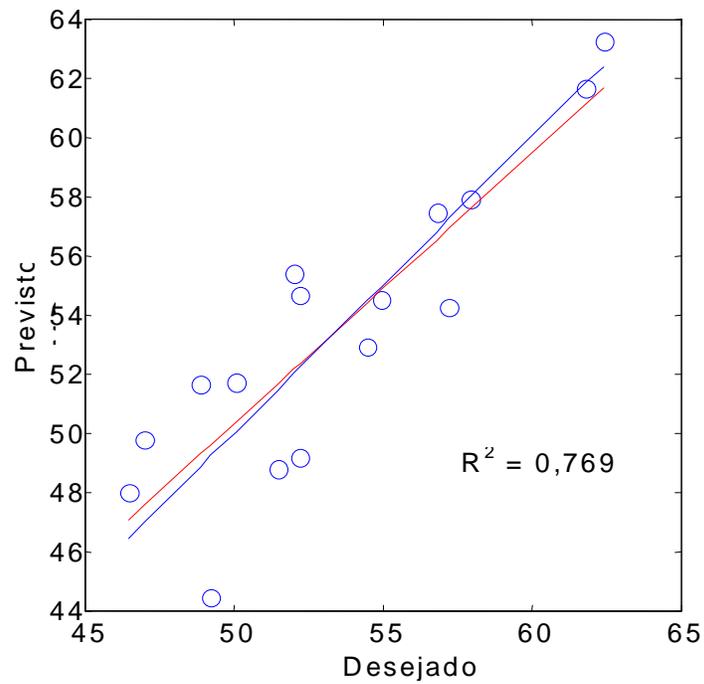


Figura 4.13 – Análise de regressão dos valores previstos pelo método dos mínimos quadrados para os dezesseis animais do conjunto de teste e os valores desejados correspondentes.

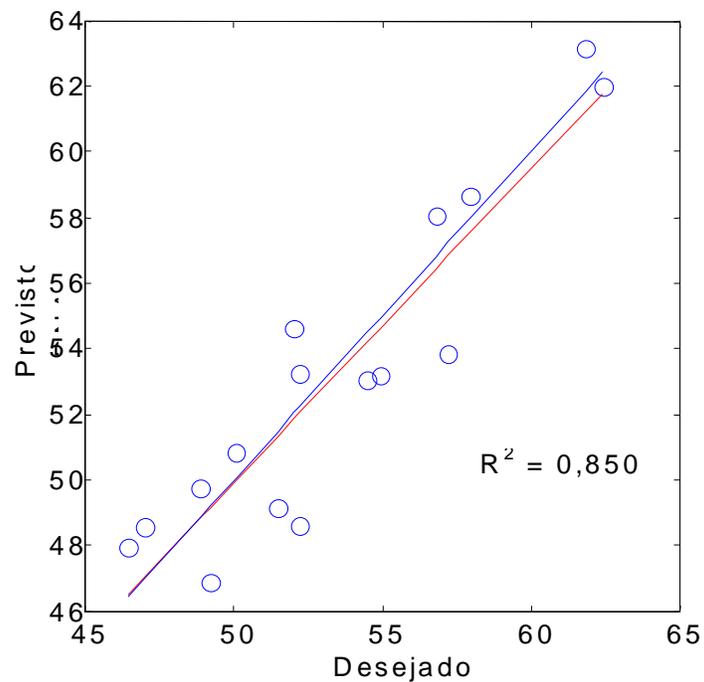


Figura 4.14 – Análise de regressão dos valores previstos pela RNA para os dezesseis animais do conjunto de teste e os valores desejados correspondentes.

As figuras 4.13 e 4.14 comprovam a superioridade da RNA para predição da percentagem de carne na carcaça resfriada. O coeficiente de determinação ( $R^2$ ) do método dos mínimos quadrados é de 0,769129, enquanto o da RNA é de 0,850084. Ou seja, enquanto o método em uso explica 76,91% da variação na percentagem de carne na carcaça resfriada, a RNA pode explicar 85% desta variação.

No próximo capítulo, os resultados obtidos são discutidos e analisados. Fatores importantes a serem considerados em problemas de predição como a escolha das medidas de avaliação, o tratamento estatístico dos dados e a escolha da topologia ótima da rede são ressaltados. Além disso, as limitações e possíveis investigações futuras são enumeradas.

## CAPÍTULO 5 – CONCLUSÕES FINAIS

Neste trabalho, investigou-se a habilidade das RNAs na predição da porcentagem de carne suína na carcaça resfriada.

O modelo de RNA especificado, uma rede direta multicamadas, melhorou em 8,02% o grau de confiança na determinação do índice de bonificação, proporcionando uma tipificação de carcaças mais justa e acertada. Essa melhoria na confiabilidade da predição, incentiva os produtores a produzirem suínos com mais carne e de maior qualidade; melhora o aproveitamento industrial das carcaças e por fim, torna o produto melhor e mais competitivo frente ao mercado.

A aplicação e o sucesso das RNAs em problemas de predição não é novidade no meio científico. Pesquisadores das mais diversas áreas vem aplicando RNAs e obtendo bons resultados em problemas cujo objetivo é abstrair padrões de dados passados e extrapolar para o futuro. A maioria das aplicações encontradas na literatura, compara o desempenho das RNAs com os métodos estatísticos de predição. Essas, reportam principalmente a vantagem das RNAs serem não-paramétricas, dispensando o conhecimento a prior dos dados. Porém, como pode-se verificar neste trabalho, RNAs não dispensam uma boa análise estatística dos dados.

Os modelos conexionistas são extremamente baseados em dados. Porém, são flexíveis, ou seja, permitem o uso tanto do conhecimento intuitivo do especialista como também de informações geradas por modelos estatísticos formais na montagem do conjunto de treinamento. Esse conhecimento melhora significativamente o desempenho das RNAs.

Neste trabalho, pelos resultados da análise de correlação entre as variáveis, acredita-se poder chegar a resultados ainda melhores. A fraca correlação entre as variáveis explicativas e a variável resposta é um indicativo que a relação contida nos dados é não linear, tornando as RNAs uma metodologia em potencial na solução do problema.

O fator limitante para se chegar a resultados melhores foi a quantidade de dados disponíveis para o treinamento da rede. A PCmf é uma variável difícil, custosa e trabalhosa para se coletar.

Outro fator positivo da aplicação de RNAs é que diferente da maioria dos métodos estatísticos tradicionais, estas não especificam condições sobre os parâmetros da população da qual se extraiu a amostra. É comum antes de se aplicar um método estatístico a necessidade de se fazer testes para verificar se os dados atendem ou não as condições impostas.

Um fator importante a ser analisado é que nem sempre a arquitetura que alcançou o menor erro no processo de treinamento, é a melhor. Neste trabalho todas as outras arquiteturas testadas, arquiteturas com 3, 4, 5, 6, 7 e 8 neurônios na camada interna, apresentaram um erro menor durante o treinamento. Porém, em termos de capacidade de generalização a rede com dois neurônios na camada interna é que apresentou os melhores resultados. O que pode ter acontecido com a rede com oito neurônios na camada interna, a que alcançou um menor erro no treinamento, foi um supertreinamento. A rede acabou decorando os dados apresentados, perdendo a capacidade de generalizar.

Outro fator importante a ser analisado quando o problema a ser tratado é de predição, são as medidas de erro que serão utilizadas para avaliar o desempenho dos métodos em avaliação. Dependendo da medida de erro utilizada os resultados podem divergir significativamente. Uma solução para este problema, segundo Makridakis et al. 1998, seria o uso da maioria das medidas padrão de erros, como utilizado neste trabalho.

Por fim, o modelo conexionista resultante deste trabalho, mostrou-se superior ao modelo utilizado atualmente na predição da percentagem de carne na carcaça resfriada, atendendo assim, o objetivo maior do trabalho.

Vale ressaltar que os resultados aqui publicados são válidos na comparação do modelo conexionista com o modelo de regressão linear múltipla, modelo este utilizado atualmente nas empresas para o cálculo do índice de bonificação. Porém, como a relação entre os dados é não linear, esses resultados podem ser extrapolados para a comparação com qualquer outro método estatístico linear de predição.

Como trabalho futuro, poder-se-ia analisar o desempenho da RNA com os poucos métodos estatísticos não lineares existentes (reconhecimento do espaço de estado e Alisamento exponencial com resposta adaptativa).

Com relação à rede poder-se-ia tentar melhorar seu desempenho obtendo uma amostra maior de dados de treinamento e re-treinando a rede.

Ainda com relação ao desempenho da RNA, poder-se-ia testar outras variações do algoritmo de treinamento de retropropagação como os algoritmos *Quickprop*, *Levnberg-Marquardt*, Momentum de Segunda Ordem, *Newton* ou *Rprop*.

## REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE CRIADORES DE SUÍNOS, Estrela, RS. **Método Brasileiro de Classificação de Carcaças**, 1973.

AZEVEDO F., F. MENDES & BRASIL, L. MATTOS & OLIVEIRA, R. C. LIMÃO de. "**Redes Neurais com aplicações em controle e em sistemas especialistas**". 1. ed., Florianópolis: Visual Books, 2000. 401p, ISBN: 85-901540-1-7.

BARRETO, JORGE M., Introdução às Redes Neurais Artificiais. **Anais V Escola Regional de Informática da SBC Regional Sul**, 5 a 10 de maio de 1997. Páginas 41 - 71.

BRAGA, A. P.; CARVALHO, A. P. L.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000.

BRAGA, M. J.; RESENDE, M. A. **Comparação entre o uso de redes neuronais e metodologia de Box & Jenkins na previsão de preços agrícolas: Um exercício empírico**. In: Congresso da sociedade Brasileira de Economia e Sociologia Rural, 34, 1996, Aracaju. Anais... Aracaju: SOBER, 1996. V. II, p. 1130-1148.

CANADIAN PORK COUNCIL, Ottawa, Ontario, Canada. **The Canadian Carcass Grading/Settlement System, 1979**.

CORRÊA, W. R.; PORTUGAL, M. S. **Previsão de Séries de tempo na presença de mudança estrutural: Redes neurais artificiais e modelos estruturais**. Trabalho apresentado ao XVIII International Symposium on Forecasting, Edinburgh, Escócia, 1995.

CORREIO DO POVO, Porte Alegre, RS. **Instituída a tipificação de carcaças suínas**. Porto Alegre, 21 de agosto de 1981. Supl. Rural no 1.200, p. 15, 1981.

COTTERILL R.M.J., NIELSEN C.: Gamma-band and Beta-band Cortical Oscillations, in Aleksander I. and Taylor J.(eds.), *Artificial Neural Networks*, 2, **North-Holland, Amsterdam/New York, pp.847-850, 1992**.

CYBENKO - Cybenko G.: Mathematical Problems in Neural Computing, Center for Supercomputing Research and Development, **University of Illinois at Urbana-Champaign, CSRD Report No. 905, 1989**.

DANSKE SLAGTERIER, Axelborg, Copenhagen, Dinamarca, **Statistics 1992**, 1993.

DAUMAS, G. Comparaison des taux de muscle des carcasses de porc dans l'union européenne. **Journées Rech. Porcine en France**, v. 27, p.285-290, 1995.

DAUMAS, G.; DHORNE, T. Historique et futur du classement objectif des carcasses de porc en France. **Journées Rech. Porcine en France**, v.28, 1996 (no prelo).

DAUMAS, G.; DHORNE, T. Problèmes statistiques posés par l'harmonisation des méthodes de classement des carcasses de porc dans la C.E.E. **Journées Rech. Porcine en France**, v.24, p.47-54, 1992.

DE OLIVEIRA, C. M. **Um modelo de rede neural artificial para previsão automática da carga ativa nodal de curto prazo em sistemas de transmissão e distribuição de energia elétrica com supervisão e controle automatizados**. Florianópolis, 1999. Dissertação (Mestrado em Engenharia) – Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina.

DEMING, W.E. Quality, productivity and competitive Position. Massachusetts: Institute of Technology, 1982. 373p.

DIESTRE, A ; GISPERT, M.; OLIVER, M.A The evolution of automatic probes in Spain for the new scheme for pig carcass grading according to the E C regulations. **Anim. Prod.**, v.48, p.443-448, 1989.

FERNANDES, L. G. L. **Utilização de Redes Neurais na Análise e Previsão de Séries Temporais**. Porto Alegre, 1995. Dissertação (Mestrado em Ciências da Computação) – Curso de Pós Graduação em Ciência da Computação, Universidade Federal do Rio Grande do Sul.

FILHO, EDSON COSTA DE BARROS CARVALHO., Modelagem, Aplicações e Implementações de redes Neurais. **Anais da IV Escola Regional de Informática da SBC Regional Sul**, 21 a 27 de abril de 1996. Páginas 36 - 53.

FONTES, E.M.G. Desenvolvimento, Estágio no Brasil e Requisitos para uma Política Nacional de Biossegurança. In: **Seminário Internacional Sobre Biodiversidade e Transgênicos**, 1999, Brasília, DF. Anais. Brasília: SENADO FEDERAL, 1999. P 21-30.

FREEMAN, JAMES A./SKAPURA, DAVID M., Neural Networks - Algorithms, Applications and Programming Techniques. Loral Space Information Systems and Adjunct Faculty, **School of Natural and Applied Sciences University of Houston at Clear Lake**.

GARRAFA, V. Ciência, Poder e Ética. In: **Seminário Internacional Sobre Biodiversidade e Transgênicos**, 1999, Brasília, DF. Anais. Brasília: SENADO FEDERAL, 1999. P 09-20.

GORNI, ANTÔNIO AUGUSTO, Redes Neurais Artificiais - Uma Abordagem revolucionária em Inteligência Artificial. **Revista MicroSistemas** edição 133 páginas 14 a 25 e edição 134 páginas 14 a 17, Ano XII

GUIDONI, A.L. Aspectos Metodológicos da Valorização de Carcaças de Suínos No Brasil. In: **Workshop Manejo e Pré-abate na Qualidade da Carne e da Carcaça Suína**. 2000, Campinas, SP. Anais. Centro de Tecnologia de Carnes -Instituto de Tecnologia de Alimentos. Campinas, SP, 2000.

GUIDONI, A.L. Embrapa Suínos e Aves : Relatórios de prestação de serviço às agroindústrias (Sadia, Perdigão, Aurora e Batávia) sobre estudo de sistemas de tipificação e valorização de carcaças de suínos. Concórdia:Embrapa Suínos e Aves, 1999. (**Relatórios Confidenciais**) não publicado.

GUIDONI, A.L. Otimização do processo de tipificação e valorização de carcaças de suínos atrelado a um sistema agroindustrial de qualidade. Concórdia: Embrapa Suínos e Aves, 2000. (**Seminário interno**) não publicado.

GUPTA, MADAN M.E RAO, DANDINA H. - Neuro-Control Systems. **Um volume selecionado reeditado**.

HEBB D.O.: *The organization of behavior*, Wiley, **Chichester/London/New York, 1949**.

HECHT-NIELSEN R., KUDRICKY A.: Theory of Backpropagation Neural Network, in *IEEE International Joint Conference On Neural Networks, Washington D.C., June 18-22, IEEE, Volume I, pp.593-606, 1989*.

HECHT-NIELSEN, ROBERT - Neurocomputing. HNC, Inc. and **University of California, San Diego**.

HULSEGGE, B.; STERRENBURG, P.; MERKUS, G.S. Prediction of lean meat proportion in pig carcasses and in the major cuts from multiple measurements made with the Hennessey Grading Probe. **Anim. Prod.**; v.59, p. 119-123, 1994.

IEEE Neural Networks Council, **Sponsor**.

INSTITUTO CEPA/SC, Florianópolis, SC. Preços dos principais produtos Agropecuários. **Informe Conjuntural**, ano XIII, n.578, 1995.

IRGANG, R. Avaliação e tipificação de carcaças de suínos no Brasil. In: Conferência Internacional sobre Ciência e Tecnologia de Produção e Industrialização de Suínos.

- Suinotec II**, 1996, Campinas, SP. Anais, Campinas- SP: ITAL, 1996, p 67-85. MEAT AND LIVESTOCK COMMISSION (MLC). Pig Yearbook, Inglaterra, 1995. 149 p.
- IRGANG, R.; GUIDONI, A L. Medidas de espessura de toucinho e de profundidade de músculo recomendadas para estimar rendimento de carne em suínos, 1996 (não publicado):
- IRGANG, R.; PROTAS, J.F.S. Peso ótimo de abate de suínos II. Resultados de carcaça. **Pesq. Agrop. Bras.**, Brasília, v.21, n.12, p.1337-1345, 1986.
- KEELER J., RUMELHART D.E.: A Self-Organizing Integrated Segmentation and Recognition Neural Net, in Moody J.E., et al.(eds.), *Neural Information Processing Systems 4 (NIPS'92)*, Morgan Kaufmann, **Los Altos/Palo Alto/San Francisco, pp.496-503, 1992.**
- KOVÁCS, ZSOLT L. - redes Neurais **Artificiais**. Segunda edição, editora **Collegium Cognito**, 1996
- LEE Y., LIPPMANN R.P.: Practical Characteristics of Neural Network and Conventional Pattern Classifiers on Artificial and Speech Problems, in Touretzky D.S.(ed.), *Advances in Neural Information Processing 2*, **Morgan Kaufmann, Los Altos/Palo Alto/San Francisco, pp.168-177, 1990.**
- MAKRIDAKIS, S.; WHEELWRIGHT, S.C; HYNDMAN, R. J. **Forecasting – Methods and applications. Ed. 3.** New York: John Wiley & Sons, Inc., 1998.
- MCCULLOCH N.: Recurrent Networks for Learning Stochastic Sequences, in *International Joint Conference on Neural Networks, San Diego, IEEE, pp.561-566, 1990.*
- McPHEE, C.P. Economic returns from reducing backfat thickness in pigs by genetic and other means. **Austr. J. Exp. Agric. Anim. Husb.**, v.17, p.399-402, 1977.
- MEAT AND LIVESTOCK COMMISSION, Milton Keynes, Inglaterra. Pig Yearbook, p. 1-149, 1995.
- PELOSO, J.V. Transporte de Suínos para o Abate: Uma Visão Técnica e Empresarial. In: WORKSHOP MANEJO E PRÉ-ABATE NA QUALIDADE DA CARNE E DA CARCAÇA SUÍNA. 2000,Campinas, SP. **Anais**. Centro de Tecnologia de Carnes - Instituto de Tecnologia de Alimentos. Campinas, SP, 2000.

- PORTUGAL, M. S. **Neural networks versus time series methods: a forecasting exercise.** *Revista Brasileira de Economia*, Rio de Janeiro: FGV, v. 49, n. 4, p. 611-629, 1995.
- ROACH, B. Computer controls movement of meat. **International Pig Topics.** P.5-11, 1993.
- RUMELHART, D. E., HINTON, G. & WILLIAMS, R., HEBIAN L. *Learning Representation by Back-Propagation Errors*, **Nature**, 1986, 323, 9, p. 533-536.
- SATHER, A P.; NEWMAN, J.A ; JONES, S.D.M.; TONG, <sup>a</sup>K.W.; ZAWADSKI, S.M.; COLPITTS, G. The prediction of pork carcass composition using the Hennesy Grading Probe and the Alka SSD –210D XII Echo Camera. **Can J. Anim. Sci.**, v.71, n.4, p.993-1000, 1991 a
- SATHER, AP.; NEWMAN, J.A; JONES, S.D.M.; TONG, A K.W.; ZAWADSKI, S.M.; COLPITTS, G. The prediction of pork carcass composition using live animal echographic measurements from the Krautkramer USK7, Ithaca Scanoprobe 731C and Alaka SSD-210 DXII Echo Camera **Can. J. Anim. Sci.**, v.71, n.4, p.1001-1009, 1991b.
- TAMARI, S.; RUIZ-SUDREZ, J. C.; WÔSTEN, J. H. M. **Testing an artificial neural network for predicting soil hydraulic conductivity.** In: Sixth International Conference on Computers in Agriculture (1996: Cancun). Anais: Cancun: American Society of Agricultural Engineers, 1996. P. 913-919.
- TANK D.W., HOPFIELD J.J.: Concentrating Information in Time: Analog Neural Networks with Applications to Speech Recognition Problems, in Caudill M. and Butler C.(eds.), **IEEE First International Conference on Neural Networks, San Diego, IEEE, pp.455-468, 1987.**
- UTTARO, B.E.; BALL, R.A Porcine portions... or the piecemeal pig. **Ontario Swine Research Review**, p.29-30, 1995.
- VALENÇA, M. J. S. Um estudo comparativo dos modelos Box & Jenkins, **Redes Neurais e Regressão Múltipla na previsão de vazões médias mensais.** In: Simpósio Brasileiro de Redes Neurais (IV.: Dez/97: Goiânia). Anais... Goiânia,1997, p. 55-57.
- WARRISS, P.D. Optimizing the Preslauhter Handling of Pigs Lairage. In: WORKSHOP MANEJO E PRÉ-ABATE NA QUALIDADE DA CARNE E DA CARÇAÇA SUÍNA. 2000,Campinas, SP. **Anais. Centro de Tecnologia de Carnes - Instituto de Tecnologia de Alimentos.** Campinas, SP, 2000.
- YOSHIDA, KEILA M. - Redes Neurais e suas aplicações em Inteligência Artificial. **Trabalho de graduação de 1996.**

## ANEXO I

Tabela 1 – Conjunto de dados utilizado.

PCARQ	ESP	MUS	PCMF	PCARQ	ESP	MUS	PCMF
51	10,0	41,2	63,7067	76	10,4	48,8	67,0180
54	9,2	48,8	60,2965	71	10,4	54,8	61,8271
56	12,8	49,2	59,1269	79	10,8	52,4	63,2475
53	12,8	36,0	53,5247	71	15,6	51,2	55,0388
51	20,4	45,2	54,9465	74	12,4	51,2	59,5983
53	19,6	45,6	52,0234	74	18,4	52,8	54,8154
56	21,6	41,2	53,3910	78	16,4	50,8	62,3904
58	23,2	47,6	51,7020	79	21,6	57,6	52,2075
56	26,0	31,6	49,4769	78	23,6	52,8	50,7463
57	28,0	46,0	51,2577	80	26,4	59,6	52,2356
58	32,0	46,8	49,7094	74	26,8	54,0	48,5395
50	9,6	56,8	62,3979	76	33,2	51,2	48,1399
53	9,2	52,4	58,6314	72	31,2	50,0	43,9956
53	12,8	54,4	60,2652	82	14,0	47,2	57,9557
59	13,2	50,8	61,7945	88	20,4	47,6	53,7951
59	17,6	56,0	59,0253	81	20,4	40,0	54,6033
54	18,0	51,2	55,8509	84	23,6	46,4	51,0262
58	24,4	51,2	54,4742	89	22,0	49,2	51,2708
57	24,8	52,4	51,5717	88	29,2	49,2	48,4495
61	9,6	46,0	62,2960	85	27,6	46,8	52,2144
67	9,6	48,0	60,2644	89	34,0	46,0	41,0468
66	12,8	40,0	59,1111	84	33,2	49,2	43,6883
69	14,8	47,6	58,0120	83	8,0	56,4	65,0726
69	20,0	44,0	57,2223	86	14,4	51,6	60,6478
62	16,8	38,0	52,0672	87	14,8	64,8	59,4462
67	24,0	33,6	51,9358	85	20,4	52,8	54,9264
64	22,8	46,0	53,7185	82	20,0	55,2	53,4427
65	27,6	48,8	45,3483	82	21,6	58,8	52,7529
70	26,0	37,6	56,2469	83	24,8	58,8	52,7975
67	34,0	35,6	49,2083	82	26,8	55,2	49,3580
65	31,2	38,4	46,2398	87	26,8	52,8	46,3623
65	10,8	61,2	65,2064	84	32,0	58,0	46,4436
70	8,8	51,6	63,8481	86	32,8	52,4	50,1618
68	15,2	67,6	62,1019	95	14,0	48,4	58,8581
63	15,2	55,2	55,1960	96	15,6	35,6	50,9905
67	16,8	52,4	56,7859	92	16,4	41,6	50,4618
67	17,2	56,8	56,2053	92	23,2	49,6	50,6557
65	22,8	56,4	52,2101	96	23,2	47,6	48,8641
69	25,6	52,4	51,1494	96	33,6	48,0	49,6003
67	27,6	54,0	48,9381	91	32,0	49,6	47,4560
66	26,0	50,0	49,0405	90	14,0	52,4	57,4920
69	32,4	61,2	51,4619	91	12,0	61,2	62,0914
72	10,0	46,8	62,7335	91	18,0	59,6	54,1533
71	15,6	45,6	59,6582	93	28,0	55,6	46,9954
79	14,8	42,8	57,0945	97	26,8	64,8	52,4608
74	18,4	47,6	52,5948	92	31,6	55,2	49,2223
78	16,4	49,2	58,1065	56	26,4	54,8	60,4190
75	23,6	44,0	50,0647	96	10,4	62,4	64,4659
79	22,8	47,2	56,8225				
78	27,2	44,8	47,9233				
75	26,0	48,0	51,1837				
72	31,6	42,8	48,3012				

