



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Classificação Automática do Acabamento de Gordura em Imagens Digitais de Carcaças Bovinas

Carmen Dalla Rosa Bittencourt

Dissertação apresentada como requisito parcial
para conclusão do Mestrado em Informática

Orientador

Prof. Dr. Marcelo Ladeira

Coorientador

Prof. Dr. Díbio Leandro Borges

Brasília

2009

CIP — Catalogação Internacional na Publicação

Bittencourt, Carmen Dalla Rosa.

Classificação Automática do Acabamento de Gordura em Imagens Digitais de Carcaças Bovinas / Carmen Dalla Rosa Bittencourt.

Brasília : UnB, 2009.

78 p. : il. ; 29,5 cm.

Dissertação (Mestrado) — Universidade de Brasília, Brasília, 2009.

1. processamento de imagens digitais, 2. redes neurais,
3. carcaças bovinas

CDU 004.4

Agradecimentos

Quero agradecer a Deus pela vida, pela força e benção nos momentos difíceis.

Ao meu orientador, Prof. Dr. Marcelo Ladeira, pela confiança e dedicação a mim oferecida e pelo apoio na condução desta dissertação. Ao meu co-orientador Díbio Leandro Borges pela ajuda com seus conhecimentos para o desenvolvimento desta pesquisa.

Agradeço e dedico este trabalho ao meu esposo Anderson Luis Schvindt Bittencourt, pelo apoio, pelas dicas, críticas, sugestões e pela presença sempre constante durante a realização deste trabalho. Dedico aos meus familiares que sempre me encorajaram a seguir em frente, em especial ao meu irmão Rogério, que mesmo distante participou ativamente.

Ao Prof. Saul Fontoura da Silva, professor do Departamento de Medicina Veterinária da Universidade Federal de Santa Maria (UFSM/RS) que colaborou de forma direta para o desenvolvimento desta pesquisa. Ao bolsista Cássio Barbosa Ferrari pelas atividades desenvolvidas junto aos frigoríficos e também fora deles, para que conseguíssemos coletar as imagens.

Ao Prof. Dr. David Leonel Pennington e Prof. Dr. Armando Bulcão pela colaboração no desenvolvimento do protótipo de aquisição de imagens.

Ao órgão financiador, CAPES, agradeço pela oportunidade da bolsa de estudos e a FAPDF pelo financiamento do projeto.

A todos aqueles que contribuíram de forma direta ou indireta para a conclusão desta pesquisa, os meus mais sinceros agradecimentos.

Sumário

Lista de Figuras	vi
Lista de Tabelas	vii
1 Introdução	1
1.1 Objetivos	3
1.1.1 Geral	3
1.1.2 Específico	4
1.2 Áreas de pesquisas relacionadas	4
1.3 Contribuição	4
1.4 Organização deste documento	5
2 Revisão de literatura	6
2.1 Avaliação por observação visual	7
2.2 Avaliação de características não observáveis visualmente	11
2.3 Imagens digitais	13
2.3.1 Sistema de cor RGB	14
2.3.2 Sistema de cor HSV	15
2.3.3 Etapas do processamento digital de imagens	16
2.4 Redes neurais artificiais	18
2.4.1 Breve histórico das redes neurais artificiais	20
2.4.2 Neurônio biológico	22
2.4.3 Neurônio artificial	24
2.4.4 Função de ativação	24
2.4.5 Perceptron de múltiplas camadas	26
2.4.6 Algoritmos de treinamento	26
2.5 Conclusão do capítulo	31
3 Solução proposta	32
3.1 Metodologia da pesquisa	32
3.2 Aquisição de imagens	34
3.3 Segmentação	36
3.3.1 Base de dados	39
3.3.2 Preparação dos dados	40
3.3.3 Treinamento da rede neural	40
3.3.4 Configuração da rede neural	41
3.4 Classificação do acabamento	43

3.4.1	Base de dados	46
3.4.2	Preparação dos dados	47
3.4.3	Treinamento da rede neural	48
3.4.4	Configuração da rede neural	49
3.4.5	Métricas para avaliação dos resultados	50
3.5	Conclusão do capítulo	52
4	Resultados obtidos	53
4.1	Protótipo de aquisição de imagens	53
4.2	Segmentação	54
4.3	Classificação do acabamento	56
4.4	Conclusão do capítulo	62
5	Conclusões e Trabalhos Futuros	63
5.1	Trabalhos futuros	64
	Referências Bibliográficas	66
A	Algoritmo de Levenberg-Marquardt	69

Lista de Figuras

1.1	Exemplo de meia carcaça bovina	2
1.2	Classificações dos acabamentos de gordura conforme as 5 categorias	3
2.1	Padrões de referência de marmorização da carne nos Estados Unidos	7
2.2	Classificações do acabamento de gordura na União Européia	8
2.3	Padrões de referência de marmorização da carne na Austrália	9
2.4	Padrões de referência de marmorização da carne no Canadá	10
2.5	Padrões de referência de marmorização da carne no Japão	10
2.6	Avaliação do acabamento de gordura - Uruguai	11
2.7	Avaliação digital da carcaça feita pelo sistema VBS 2000	12
2.8	Sistema de cores RGB	15
2.9	Sistema de cores HSV	16
2.10	Modelo de um neurônio biológico	23
2.11	Modelo de um neurônio artificial	25
2.12	Gráfico da função sigmoide	25
2.13	Arquitetura MLP com duas camadas intermediárias	26
2.14	Propagação das Entradas	27
2.15	Retropropagação do Erro	27
2.16	Sequência de passos para o método de <i>Levenberg-Marquardt</i>	30
3.1	Imagem digital de uma carcaça bovina obtida durante o abate	37
3.2	Gráfico de sobreposição dos pixels	39
3.3	(a) Imagem digital (b) Rede neural (c) Segmentação	40
3.4	Modelo de topologia de rede usado na etapa da segmentação	42
3.5	Imagem original e imagem resultante da aplicação do filtro de sobel	44
3.6	Gráfico de Frequência de Pixels de Gordura e não Gordura	46
3.7	(a)Imagem segmentada (b)Pré-processamento (c)Rede neural (d)Saída	46
3.8	Carcaça segmentada (esq.) e carcaça submetida a máscara (dir.)	48
4.1	Mecanismo de aquisição <i>in loco</i> das imagens digitais	54
4.2	Gráfico do treinamento utilizando o conjunto T1Cj1	56
4.3	Imagem original e imagem resultante da segmentação	56
4.4	Exemplo de segmentação conforme acabamentos de gordura	57
4.5	Exemplos de Tipo 1 e 2 após pré-processamento	57
4.6	Exemplos de Tipo 3 e 4 após pré-processamento	58

Lista de Tabelas

2.1	Categorias de classificação das carcaças na União Européia	8
3.1	Problemas enfrentados durante instalação do protótipo	36
3.2	Componentes de cor dos pixels correspondentes à gordura	38
3.3	Componentes de cor dos pixels correspondentes à não gordura	38
3.4	Conjunto treinamento usado para segmentação	41
3.5	Parâmetros de treinamento da rede neural usados na segmentação	43
3.6	Distribuição das imagens por categoria	47
3.7	Conjunto treinamento usado para classificação	49
3.8	Resultados esperados para a classificação	49
3.9	Parâmetros de treinamento da rede neural usados na classificação	49
3.10	Matriz de Confusão com duas classes	51
3.11	Índices para discriminação entre classificadores dicotômicos	51
4.1	Topologias de redes submetidas para a segmentação	55
4.2	Topologias de redes submetidas para classificação	58
4.3	Classificações corretas obtidas com as redes	59
4.4	Resultado classificação - Rede 01	59
4.5	Resultado classificação - Rede 02	59
4.6	Resultado classificação - Rede 03	60
4.7	Matriz de confusão por tipo do acabamento - Rede 01	60
4.8	Matriz de confusão por tipo do acabamento - Rede 02	60
4.9	Matriz de confusão por tipo do acabamento - Rede 03	60
4.10	Performance obtida com a Rede 01	60
4.11	Performance obtida com a Rede 02	61
4.12	Performance obtida com a Rede 03	61
4.13	Performance obtida com a rede contendo 3 saídas	61

Resumo

No Brasil, a classificação do acabamento de gordura em carcaças bovinas é realizada por meio de inspeção visual de regiões predefinidas da carcaça, feita por um profissional habilitado, seguindo os critérios estabelecidos na Portaria N.º 612/89 do Ministério da Agricultura, Pecuária e Abastecimento. O acabamento é classificado em cinco categorias, de 1 a 5. Esse método, por ser subjetivo, é mais propenso a ocorrência de erros de classificação. Essa pesquisa propõe uma metodologia para aquisição de imagens digitais de carcaças bovinas durante o abate e a classificação automática do acabamento de gordura das carcaças. A metodologia proposta é baseada no uso de redes neurais artificiais e compreende duas fases distintas. A primeira delas, consiste no uso de uma rede MLP com treinamento *Levenberg - Marquardt* para segmentação das regiões de gordura. A segunda consiste em usar uma rede MLP com treinamento de retropropagação do erro para classificar a carcaça em relação ao acabamento da gordura. Os resultados obtidos foram o desenvolvimento do protótipo de aquisição de imagens de carcaças bovinas, o uso de redes neurais para segmentar a gordura em imagens digitais das carcaças obtidas sem a utilização de artifícios de intervenção no processo de abate e a proposição de um classificador neural com acurácia de 86% na classificação do acabamento de gordura. Para a realização dessa pesquisa, até o momento foram coletadas 4.710 imagens de carcaças bovinas, utilizando o protótipo desenvolvido.

Palavras-chave: processamento de imagens digitais, redes neurais, carcaças bovinas

Abstract

In Brazil, the classification of fat layer of bovine carcasses has to follow the Regulation Act number 612/89 from the Ministry of Agriculture (MAPA). There are five class of fat layer, growing from 1 to 5. This process is performed by mean of visual and subjective observation of specific regions of the carcass, done by a technician during the bovine slaughter process inside the meat industries. The technician is certified by the MAPA. This paper proposes a methodology for automatic classification of the fat layer in bovine carcasses based on two steps. The first one uses an artificial neural network to segment the fat regions of digital image of bovine carcasses. This artificial neural network is a MLP training with the Levenberg - Marquardt algorithm. The imagens have been gathered with no intervention in the process of slaughter. The second step comprises the proposal of a classifier of the fat layers in bovine carcasses based on both a MLP backpropagation artificial neural network and the Regulation Act 612/89 of the Ministry of Agriculture. Until now, the results obtained were the proposal of a functional prototype for image acquisition of carcasses during the slaughter process and the performance level of 86% of accuracy in a experimental evaluation for the fat layers classifier based on artificial neural network. For the purposes of this research so far were collected 4,710 images of bovine carcasses, using the prototype developed.

Keywords: digital image processing, neural network, bovine carcass

Capítulo 1

Introdução

A tipificação de carcaças é um instrumento auxiliar na comercialização de gado e carne que deve ter surgido no fim do século 19 ou início do século 20, e que ainda hoje é comumente utilizada em países como Brasil, Estados Unidos, Canadá, Argentina e Uruguai. A tipificação é formada de duas partes, sendo a primeira de classificação dos lotes por sexo, pela maturidade e pela faixa de peso do gado, de modo que as carcaças são agrupadas por categoria. A segunda parte é a tipificação propriamente dita, que consiste em alocar as carcaças das principais categorias, como novilho ou novilha, em tipos ordenados de melhor a pior, segundo outros indicadores tradicionalmente utilizados nos julgamentos de gado de corte em exposições, como a conformação e a quantidade de gordura (acabamento). Em tese as carcaças dos melhores tipos dariam carne de melhor qualidade [FELICIO, 2005].

Os esforços em definir uma metodologia para classificação e tipificação de carcaças bovinas no Brasil, resultaram na publicação, pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA), da Portaria Ministerial N.º 612/89 que estabelece o Sistema Nacional de Tipificação de Carcaças Bovinas e determina a tipificação de carcaças obedecendo os parâmetros de sexo-maturidade, conformação, acabamento e peso. Tal documento define carcaça bovina como sendo o animal abatido, sangrado, esfolado, eviscerado, desprovido de cabeça, patas, rabada, glândulas

mamárias na fêmea, ou verga, exceto suas raízes e testículos, no macho. Após a divisão em meia carcaça (Figura 1.1), retiram-se ainda os rins, gordura perirrenal e inguinal, “ferida de sangria”, medula espinhal, diafragma e seus pilares.



Figura 1.1: Exemplo de meia carcaça bovina

De acordo com a Portaria N.º 612/89, o sexo é obtido por meio da observação dos caracteres sexuais dos animais; a maturidade é obtida pelo exame dos dentes incisivos; a conformação expressa o desenvolvimento das massas musculares e é obtida pela verificação visual dos perfis musculares; o peso refere-se ao peso quente da carcaça obtido na sala de matança, logo após o abate. O acabamento expressa a distribuição e a quantidade de gordura de cobertura da carcaça, sendo descrita por meio das seguintes categorias (Figura 1.2):

- Magra (1) – Gordura ausente;
- Gordura escassa (2) – Gordura de 1mm a 3mm de espessura;
- Gordura mediana (3) – Gordura acima de 3mm e até 6mm de espessura;
- Gordura uniforme (4) – Gordura acima de 6mm e até 10mm de espessura;
- Gordura excessiva (5) – Gordura acima de 10mm de espessura.




Figura 1.2: Classificações dos acabamentos de gordura conforme as 5 categorias

Fonte: Portaria N.º 612/89 do Ministério da Agricultura

A avaliação da gordura de cobertura e posteriormente classificação do acabamento é realizada por meio da observação visual da distribuição da gordura sobre a superfície da carcaça e realizada por um técnico treinado [FELICIO, 2005].

O estudo proposto nessa pesquisa visa automatizar a classificação do acabamento de gordura de acordo com as determinações da Portaria N.º 612/89 do MAPA que instituiu o Sistema Nacional de Tipificação de Carcaças Bovinas, visando padronizar o processo de classificação do acabamento de gordura com base em técnicas computacionais e no método existente atualmente.

1.1 Objetivos

Os objetivos desta pesquisa podem ser divididos em geral e específico.

1.1.1 Geral

Propor uma metodologia para classificação automática do acabamento de gordura a partir de imagens digitais de carcaças bovinas. Tal metodologia envolve a aquisição das imagens na indústria frigorífica, a segmentação das regiões de gordura nas

imagens obtidas e a classificação do acabamento de gordura conforme as categorias estabelecidas pelo MAPA.

1.1.2 Específico

A partir de imagens digitais das carcaças bovinas coletadas *in loco* na indústria frigorífica, desenvolver uma metodologia capaz de realizar a classificação automática do acabamento de gordura por meio do processamento digital dessas imagens.

1.2 Áreas de pesquisas relacionadas

Essa pesquisa se situa no domínio de aplicação de técnicas de processamento de imagens digitais e reconhecimento de padrões. Como áreas correlatas podemos citar a Medicina Veterinária, a Tecnologia de Alimentos e a Automação de Processos Industriais. A área de Medicina Veterinária visa o aumento da produtividade e rentabilidade do setor agropecuário bem como o acompanhamento nos serviços de controle de qualidade e inspeção da carne animal. Tecnologia de Alimentos busca o desenvolvimento e a aplicação de novas tecnologias no processo alimentício, visando a melhoria da qualidade e o aumento da competitividade da indústria de alimentos. Automação de processos industriais busca o controle automático das ações que não dependam, ou que dependam de pouca intervenção humana, melhorando a produtividade e qualidade nos processos considerados repetitivos presentes no dia-a-dia, além de reduzir a possibilidade de erros.

1.3 Contribuição

Metodologia para classificação automática do acabamento de gordura de carcaças bovinas, baseada na aplicação de técnicas de processamento de imagens digitais e de reconhecimento de padrões. São propostas metodologias para segmentação

das áreas de gordura e para a classificação da carcaça com relação ao acabamento de gordura, por meio da automatização do processo de classificação. Processo este capaz de realizar tarefa equivalente àquela atualmente realizada por um observador humano. A contribuição tecnológica dar-se-á por meio de uma metodologia de aquisição, segmentação e classificação das imagens digitais das carcaças bovinas durante o processo de abate.

1.4 Organização deste documento

Este documento está organizado da seguinte forma:

Capítulo 1 aborda sobre o sistema de tipificação de carcaças bovinas instituída pelo MAPA por meio da Portaria N.º 612/89, os objetivos desta dissertação e qual a contribuição esperada.

Capítulo 2 apresenta a revisão de literatura dos sistemas de classificação do acabamento de gordura existentes, bem como uma revisão teórica sobre processamento de imagens digitais e redes neurais artificiais.

Capítulo 3 aborda a solução proposta para a classificação automática do acabamento de gordura em carcaças bovinas, fazendo uso de redes neurais artificiais tanto na etapa de segmentação das áreas de gordura como na etapa de classificação do acabamento.

Capítulo 4 apresenta uma análise dos resultados obtidos nas simulações com a solução proposta descrita no capítulo 3, bem como são apresentadas algumas considerações a respeito do processo de treinamento das redes neurais propostas.

Capítulo 5 abrange a conclusão da dissertação, incluindo as observações finais, considerações relevantes sobre os assuntos tratados e também as limitações do trabalho e recomendações para futuras pesquisas.

Capítulo 2

Revisão de literatura

Este capítulo apresenta uma revisão dos sistemas de classificação do acabamento de gordura adotados atualmente por diferentes países, dentre eles: sistema americano, canadense, australiano, europeu, irlandês, neozelandês, japonês e uruguaio. Esses sistemas são aqui divididos entre baseados na observação visual realizada por profissional habilitado, e aqueles baseados na utilização de técnicas computacionais e ou na mensuração e avaliação de características não observáveis visualmente (dependente de análise humana e não dependente de análise humana).

As técnicas que utilizam a observação visual podem ser definidas como sendo aquelas em que a classificação é realizada, de acordo com critérios pré estabelecidos, por um profissional habilitado, por meio da análise baseada na observação visual da carcaça como um todo ou uma determinada parte dela. Essa análise pode ser feita por meio da marmorização (marmoreio, ou *marbling*), que é a quantidade de gordura depositada entre as fibras musculares (intra-muscular) de uma determinada região da carcaça, sendo essa avaliação realizada na carcaça resfriada. As técnicas que medem características não observáveis visualmente podem ser definidas como sendo aquelas que utilizam algum recurso para auxiliar, computacionalmente ou não, na classificação do acabamento de gordura.

Esse capítulo contemplará também a revisão teórica de alguns conceitos relacionados ao processamento de imagens digitais, cujo conhecimento visa tornar mais fácil a compreensão dessa pesquisa. E a fundamentação teórica necessária para se compreender o funcionamento das redes neurais artificiais, principal técnica utilizada nessa pesquisa.

2.1 Avaliação por observação visual

Estados Unidos. Os padrões de classificação do acabamento de gordura, baseiam-se na avaliação visual da quantidade e da distribuição da marmorização no contrafilé (músculo *longissimus dorsi*), entre a 12^a e 13^a costela. Para a classificação da marmorização, usam-se cartões padrões (Figura 2.1) disponibilizadas pelo *United States Department of Agriculture (USDA)* para assegurar maior acurácia nas avaliações [SAINZ, 2001].




Figura 2.1: Padrões de referência de marmorização da carne nos Estados Unidos

Fonte: [AMSA, 2001]

União Européia. O regulamento europeu permite a tipificação de carcaças por avaliação visual, feita por técnicos treinados e licenciados. No sistema europeu de tipificação, o chamado “EUROP - *classification system*”, há cinco categorias do acabamento (Tabela 2.1 e Figura 2.2) e a análise da gordura de cobertura, é realizada através da observação da quantidade de gordura da carcaça como um todo [SAINZ, 2001].

Tabela 2.1: Categorias de classificação das carcaças na União Européia

Categoria	Gordura de Cobertura
<i>Ausente</i> (1)	Nenhuma ou pouca
<i>Escassa</i> (2)	Leve, carne visível em toda parte
<i>Uniforme</i> (3)	Carne com gordura, com exceção do coxão e paleta
<i>Excelente</i> (4)	Carne com gordura, coxão e paleta parcialmente visível
<i>Excessiva</i> (5)	Carcaça coberta, coxão quase completamente coberto

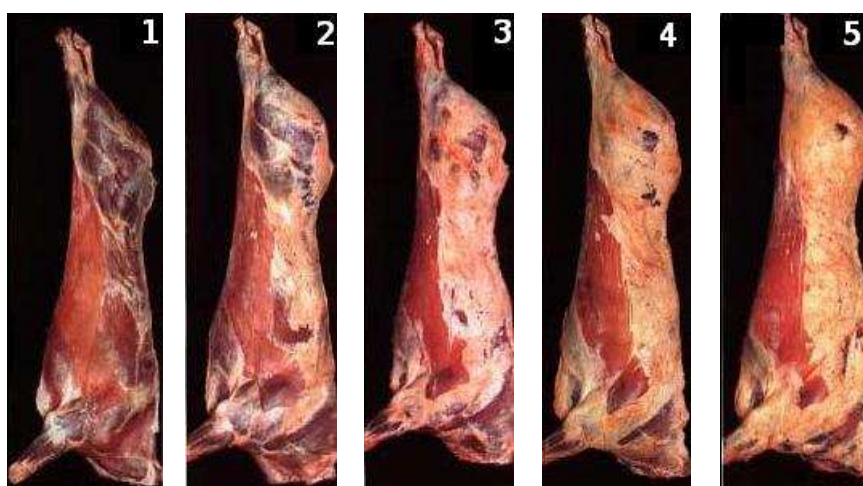


Figura 2.2: Classificações do acabamento de gordura na União Européia

Fonte: [JORGE, 2007]

Austrália. No sistema de tipificação AUS–MEAT, a avaliação do acabamento de gordura é feita pela observação do padrão de marmorização, e o score (varia de 100 a 1100 com aumentos de 10), é dado pelo AUS–MEAT, empresa responsável pela padronização de cortes de carne e carcaça. O grau de marmorização fornece uma indicação da distribuição de gordura, assim como, a quantidade de marmo-

rização. A avaliação da marmorização é feita na carcaça resfriada e o escore de marmorização é avaliado na superfície de corte do contrafilé, conforme comparação entre a amostra retirada da carcaça e os padrões (Figura 2.3) do *Meat Standards Australia* (MSA). [SAINZ, 2001].




Figura 2.3: Padrões de referência de marmorização da carne na Austrália

Fonte: [MSA, 2005]

Canadá. A avaliação do acabamento de gordura é feita pela marmorização baseando-se na quantidade, tamanho e distribuição dos depósitos de gordura e na espessura de gordura na superfície do contrafilé na 12^a costela. A classificação de carcaça canadense utiliza 4 padrões de marmorização (Figura 2.4) [JORGE, 2007].

Japão. A carcaça é cortada entre a 6^a e a 7^a costelas e a classificação do acabamento é feita de forma visual de acordo com as categorias do *Beef Marbling Standard* (BMS) (Figura 2.5), que variam de 1 a 12, sendo a categoria 1 com nenhum acabamento e a categoria 12 com abundante acabamento. A classificação do acabamento é feito juntamente com a análise da marmorização, cor e textura de carne, cor e qualidade da gordura [BUSBOOM, 1991].

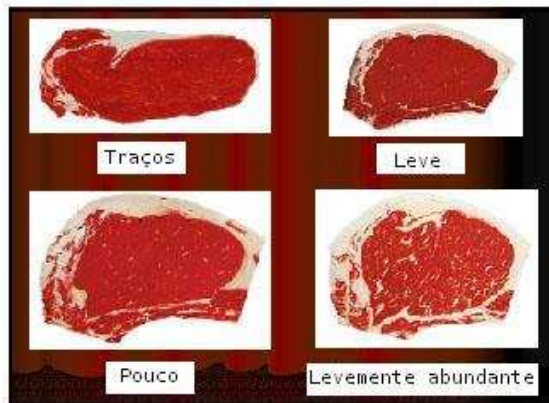


Figura 2.4: Padrões de referência de marmorização da carne no Canadá

Fonte: [Beef, 2008]




Figura 2.5: Padrões de referência de marmorização da carne no Japão

Fonte: [BUSBOOM, 1991]

Uruguai. No *Sistema Oficial de Clasificación y Tipificación de Carnes Vacunas*, o acabamento de gordura é feito pela estimativa visual e por medidas objetivas de gordura, por meio da medição da espessura de gordura subcutânea (Figura 2.6) existente entre a 12^a e 13^a costela do animal abatido [BRITO et al., 2006]. A classificação é feita em 5 categorias (0, 1, 2, 3, 4) variando de carência de gordura a excesso do acabamento.



Figura 2.6: Avaliação do acabamento de gordura - Uruguai

Fonte: [BRITO et al., 2006]

Nova Zelândia. A avaliação do acabamento de gordura é medida na 12^a costela. Na prática os classificadores e auditores consideram a quantidade de gordura total da carcaça. O acabamento de gordura é classificado de acordo com as letras ALPTF (isento, leve irregular, leve médio, denso, excessivo), sendo A, animais sem presença de gordura, e F com maior acabamento de gordura [JORGE, 2007].

2.2 Avaliação de características não observáveis visualmente

Imagem 3D. Desenvolvido na Alemanha, o sistema de tipificação de carcaças bovinas denominado VBS 2000, funciona por meio de uma análise em imagem 3D de

cada metade da carcaça. Uma das tarefas do sistema é a determinação de volumes das carcaças. A série de faixas de luzes (Figura 2.7) projetadas na carcaça faz com que a estrutura do músculo torne-se visível, possibilitando a avaliação digital. Por ser um sistema proprietário, não é divulgado qual a tecnologia usada para realizar a análise digital da carcaça.



Figura 2.7: Avaliação digital da carcaça feita pelo sistema VBS 2000

Fonte: www.eplusv.de/vbs.htm

Ultra-sonografia. A técnica de ultra-sonografia em tempo real é uma alternativa para a avaliação e classificação do acabamento de gordura em animais ainda vivos. As características que podem ser medidas por ultra-sonografia são: espessura de gordura subcutânea ou de cobertura em partes específicas do animal vivo. As medidas de ultra-som possibilitam descrever com precisão os níveis de musculidade e do acabamento de gordura da carcaça.

Nesta técnica, um aparelho converte pulsos elétricos em ondas de alta frequência (ultra-som), acima da capacidade auditiva humana, que promovem uma reflexão parcial (eco) em tecidos menos densos do animal, ou total em tecidos de alta densidade como os ossos. As ondas continuam a se propagar pelo corpo do animal e

o conjunto de informações é projetado em segundos numa tela como imagem, onde as mensurações são realizadas [MORAIS, 2007].

Impedância bioelétrica. Eletrodos são inseridos em pontos estratégicos da carcaça bovina, e uma corrente elétrica é aplicada, fazendo a medição da resistência da carcaça e estimando o conteúdo de carne magra. Esta tecnologia tem sido estudada para bovinos e suínos [BOHUSLAVEK, 2000].

Análise de imagens de vídeo. Instrumentos como o VIAScan da Austrália; o *Computer Vision Systems* do Canadá; e o BCC-2 da Dinamarca fazem análise de imagens por vídeo. Geralmente, estes capturam várias imagens da carcaça por vídeo digital, e um computador analisa as imagens, faz uma série de mensurações, e estima a classificação. Além de analisar a conformação da carcaça, alguns sistemas podem medir a coloração da gordura, a área do contrafilé e a gordura de cobertura, desde que a carcaça seja cortada transversalmente como nos EUA [SAINZ, 2001].

2.3 Imagens digitais

As imagens digitais são representadas por bitmaps, ou seja, por uma matriz bidimensional de elementos de imagem chamados pixels. Um pixel é o menor elemento de resolução da imagem, ele tem um valor numérico chamado de amplitude. O número de bits disponíveis para codificar um pixel é chamado de profundidade de amplitude ou profundidade de pixel. Exemplos típicos de profundidade de pixel são 1 (utilizado para imagens preto e branco), 2, 4, 8, 12, 16 ou 24 bits. Este valor numérico pode representar um ponto preto/branco, um nível de cinza, ou os três valores do atributo de cor do pixel de imagens coloridas.

O número de linhas da matriz de pixels é chamado de resolução vertical da imagem, já o número de colunas é chamado de resolução horizontal da imagem e o

produto da resolução vertical pela resolução horizontal denomina-se resolução espacial ou resolução geométrica. A resolução geométrica ou espacial estabelece a frequência de amostragem final da imagem, desta forma, quanto maior esta resolução, mais detalhes da imagem podem ser captados na representação matricial de pixels da imagem.

Devemos considerar que a resolução geométrica dada em termos absolutos não fornece muita informação sobre a resolução real da imagem quando esta é realizada em dispositivo físico, isso porque, neste caso, fica-se na dependência do tamanho físico do pixel do dispositivo. Uma medida mais confiável de resolução é dada pela densidade de resolução da imagem que fornece o número de pixels por unidade linear de medida. Em geral utiliza-se pixel por polegada ppi *pixels per inch* que também é chamada de dpi *dots per inch*.

2.3.1 Sistema de cor RGB

No modelo RGB, cada cor aparece nos seus componentes espectrais primários de vermelho, verde e azul. Esse modelo baseia-se num sistema de coordenadas cartesianas. O subespaço de cores de interesse é o cubo mostrado na Figura 2.8, no qual os valores de RGB estão nos três cantos; ciano, magenta e amarelo estão nos outros três cantos; preto está na origem; e branco está no canto mais distante da origem. Nesse modelo, a escala de cinza estende-se do preto até o branco ao longo da linha juntando estes dois pontos, e as cores são pontos sobre ou dentro do cubo, definidas por vetores estendendo-se a partir da origem. Por conveniência, assume-se que todos os valores de cor foram normalizados, de modo que o cubo mostrado na Figura 2.8 é o cubo unitário. Isto é, todos os valores de R, G e B são assumidos estar no intervalo $[0,1]$ [GONZALES, 2000].

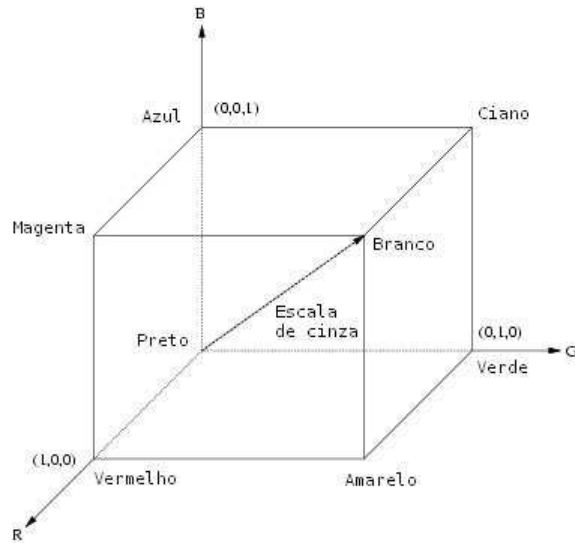


Figura 2.8: Sistema de cores RGB

Fonte: [GONZALES, 2000]

2.3.2 Sistema de cor HSV

O modelo de cor HSV é mais intuitivo que o modelo RGB. A sua sigla é formada pela primeira letra das palavras de língua inglesa correspondentes às três variáveis do modelo: *Hue* (cor/matiz), *Saturation* (saturação) e *Value* (luminância). Com estas variáveis, o modelo HSV aproxima-se muito do modelo intuitivo utilizado em artes visuais que emprega os conceitos qualitativos de matiz, luz e tonalidade.

A representação do espaço de cor do modelo HSV pode ser facilmente compreendida a partir do cubo do modelo RGB. Colocando o ponto de vista sobre a linha contendo a diagonal principal do cubo RGB e orientando a visão na direção da origem do espaço RGB, o cubo RGB apresentará uma secção diagonal onde, intercaladas e em planos diferentes, se encontram as cores primárias aditivas e as cores primárias subtrativas. A cor branca ocupará o centro. Projetando tanto as cores primárias aditivas e subtrativas e a cor branca sobre um mesmo plano à distância de uma unidade da origem e escalando o hexágono de forma a que a distância entre o ponto representativo de qualquer cor primária e o ponto central correspondente

à cor branca seja também unitária, obteremos uma pirâmide hexagonal contendo todas as cores do espaço HSV, tal como na Figura 2.9.

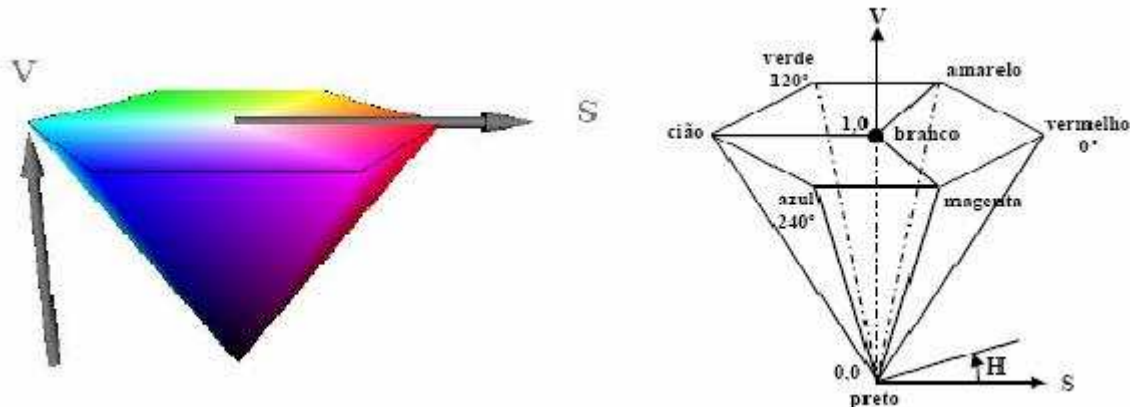


Figura 2.9: Sistema de cores HSV

Conforme Figura 2.9, os vários matizes estão representados na parte superior do cone, a saturação (S) é medida ao longo do eixo horizontal e a luminância (V) é medida ao longo do eixo vertical, que passa pelo centro do cone. O matiz (H), que corresponde às arestas ao redor do eixo vertical, varia de 0° (vermelho) a 360° , e o ângulo entre os vértices é de 60° . A saturação varia de 0 a 1 e é representada como sendo a razão entre a pureza de um determinado matiz e a sua pureza máxima ($S = 1$).

2.3.3 Etapas do processamento digital de imagens

Para executar uma tarefa de processamento de imagens são fundamentais os seguintes passos [GONZALES, 2000]:

Aquisição: nessa etapa, as informações visuais do ambiente são convertidas em sinais elétricos através de dispositivos ou sensores ópticos. A qualidade da imagem obtida é de fundamental importância para as demais etapas do processo.

Pré-processamento: As imagens obtidas na etapa de aquisição podem apresentar ruídos e pouca definição de detalhes, sendo que a utilização de técnicas de

processamento digital de imagens prepara a imagem para as próximas etapas, eliminando ruídos, visão periférica, suavizando efeitos indesejados decorrentes da resolução espacial e quantização de intensidades luminosas, além de realçar detalhes importantes para a detecção de objetos.

Segmentação: Na etapa de segmentação, a imagem é dividida em uma ou mais regiões que satisfaçam um critério de uniformidade (homogeneidade), que constituem os diversos objetos nela representados. A identificação de um objeto baseia-se na detecção de discontinuidades ou similaridades na imagem, gerando uma representação abstrata de seu contorno ou da região que ocupa. Inicialmente quando uma imagem é capturada, existem informações pertencentes à cena que muitas vezes não interessam ao sistema, por exemplo, o plano de fundo contra o qual a imagem se encontra, sendo necessário a retirada destas informações através de algoritmos de segmentação de imagens.

Descrição: Cada objeto identificado no processo de segmentação da imagem é analisado para a extração de algumas de suas características. Esse conjunto de características é denominado padrão, e representa o objeto nas etapas seguintes.

Reconhecimento: Na etapa de reconhecimento, o padrão de cada objeto identificado é comparado com classes de padrão já conhecidas com o objetivo de se decidir a qual grupo ele pertence. Metodologias de reconhecimento devem estabelecer um compromisso entre eficiência e confiabilidade, além de possibilitarem revisão do conhecimento por meio da experiência adquirida.

Interpretação: Conforme a natureza do problema tratado, pode ser necessária uma análise de cena, onde os objetos são relacionados entre si, buscando-se uma consciência descritiva do ambiente em que eles se encontram.

2.4 Redes neurais artificiais

As redes neurais artificiais (RNA), usualmente denominadas redes neurais ou redes neuronais, são pesquisadas pela linha da Inteligência Artificial denominada conexionismo. O cérebro humano é um sistema de processamento altamente complexo, não linear e paralelo, constituído por aproximadamente 10 bilhões de elementos ou unidades estruturais chamadas de neurônios [SHEPHERD, 1994]. A linha conexionista visa modelar a inteligência humana através da simulação da estrutura e funcionamento do cérebro, em especial dos neurônios e das suas ligações (conexões sinápticas). O processamento de informação no cérebro é realizado pelo neurônio, com sinais elétricos propagando entre os neurônios através das sinapses. Os conexionistas consideram que a capacidade de aprendizagem do cérebro está relacionada com a plasticidade, isto é, alterações das ligações sinápticas entre neurônios. A plasticidade pode ser atribuída a dois mecanismos, a criação de novas conexões sinápticas entre neurônios e a modificação das sinapses já existentes. A capacidade do cérebro para realizar certos tipos de processamentos, tais como reconhecimento de padrões, percepção, classificação e controle motor, muito mais rápido que qualquer computador hoje existente, tem motivado o estudo cada vez mais aprofundado das redes neurais e suas aplicações.

Segundo [HECHT-NIELSEN, 1988], as redes neurais artificiais consistem em uma estrutura de processamento de informação distribuída e paralela, formada por unidades de processamento, chamadas nós, neurônios ou células, interconectadas por arcos unidirecionais, chamadas ligações, conexões ou sinapses. Associado às sinapses entre neurônios existem pesos denominados pesos sinápticos. Esses pesos são utilizados para ponderar os sinais que chegam a um neurônio, através de suas sinapses. Os nós possuem memória local e podem realizar operações de processamento de informação local. Cada célula possui uma única saída (axônio), a qual pode se ramificar em muitas ligações colaterais (cada ramificação possuindo

o mesmo sinal de saída do neurônio). Todo o processamento que se realiza em cada unidade deve ser completamente local, isto é, deve depender apenas dos valores correntes dos sinais de entrada que chegam dos neurônios através das conexões. Estes valores atuam sobre os valores armazenados na memória local da célula.

Do ponto de vista topológico, uma rede neural pode ser vista como um grafo orientado onde os nós representam neurônios artificiais (Seção 2.4.3) e os arcos representam as sinapses entre eles. A orientação dos arcos indica o sentido do fluxo de informação entre os neurônios. O grafo é estruturado em camadas, com arcos conectando os neurônios de uma camada com neurônios da camada seguinte ou da camada anterior. A primeira camada é a camada de entrada, sendo sua função apenas distribuir as entradas para os neurônios da camada seguinte. A última camada é a camada de saída, podendo existir camadas intermediárias (em geral uma ou duas), denominadas camadas escondidas. Caso existam camadas escondidas, a rede neural é denominada rede multicamadas. Se existem arcos de todo neurônio de uma camada para todos os neurônios da camada seguinte, a rede neural é denominada totalmente conectada. Caso contrário é denominada parcialmente conectada. Se os arcos conectam neurônios de uma camada com apenas neurônios da camada seguinte, a rede é denominada alimentada à frente (do inglês, *feed-forward*). Caso contrário, a rede é denominada recorrente. No primeiro caso os arcos são unidirecionais e o grafo é acíclico. O fluxo de informação é propagado da camada de entrada para a camada de saída. Se a rede é recorrente, arcos podem ser bidirecionais para permitir retropropagação de informação. Redes recorrentes podem torna-se instáveis, oscilar ou exibir comportamento caótico, requerendo um longo tempo para a propagação do fluxo, visando a obtenção de uma configuração de saída estável.

A aprendizagem em redes neurais artificiais consiste na estimação dos pesos sinápticos e do bias através da aplicação de técnicas de aprendizagem automática supervisionada (por um “professor”) ou não supervisionada (devido à ausência de

“professor”). Na aprendizagem supervisionada, um conjunto de casos históricos classificados é submetido à rede e a resposta obtida (na camada de saída) para cada caso é comparada com a resposta correta. A regra de aprendizagem é usada para ajustar os valores dos pesos sinápticos e bias (Seção 2.4.5) da rede para que as respostas dadas se aproximem das respostas corretas. Na aprendizagem não supervisionada inexistem casos pré-classificados da função a ser aprendida pela rede. O objetivo é encontrar regularidades nos dados de entrada. Com este tipo de aprendizagem são dadas condições para realizar uma medida da qualidade da representação que a rede deve aprender, e os pesos e bias são modificados para atender a esta medida. Para o caso de se usar a rede para descobrir agrupamentos “naturais” dos dados de entrada, a aprendizagem não supervisionada requer: a) definição de uma medida de similaridade (distância) entre entradas, b) definição de uma função de custo para agrupar as entradas e c) definição de um algoritmo para minimizar a função de custo.

O algoritmo básico da aprendizagem supervisionada é: a) defina uma topologia fixa para a rede; b) atribua valores iniciais para os pesos sinápticos, usualmente no intervalo $[-0.5,+0.5]$; c) para cada caso do conjunto de casos pré-classificados, propague um caso e observe a saída; d) ajuste os pesos sinápticos de forma a reduzir a diferença entre o valor de saída observado e o valor de saída previsto, associado ao caso em questão; e) repita os passos “c” e “d” até que todos os casos sejam preditos corretamente ou que um critério de parada seja atingido. A forma como os pesos sinápticos são atualizados em função de cada caso exemplo e das saídas prevista e observada difere para cada algoritmo de aprendizagem específico.

2.4.1 Breve histórico das redes neurais artificiais

Os primeiros conceitos de máquinas baseadas no comportamento das células nervosas biológicas surgiram no início da década de 40. Em 1943, Warren McCulloch e Walter Pitts [McCULLOCH, 1988b] publicaram um estudo sobre *neuro-logical*

network. Em 1947 eles publicaram o segundo estudo, intitulado *How we know universals* [McCULLOCH, 1988a]. A partir destas ideias, surgiu a *Cybernetics* que utiliza conceitos de biologia, psicologia, engenharia e matemática. A década terminou com a publicação do livro de Donald Hebb *The Organization of Behavior* [HEBB, 1949].

Após a era *Cybernetics* ter aberto a perspectiva de se construir máquinas baseadas no conhecimento, surgiram, no início da década de 50, os primeiros protótipos neste campo, com arquiteturas específicas para desempenhar tarefas determinadas. Contudo, tendo em vista o fato de que os animais podiam aprender a fazer muitas coisas para as quais eles não tinham sido “construídos” para fazer, passou-se a ter como meta a construção de máquinas que fossem capazes de aprender. Com isso, a década de 50 presenciou o surgimento de muitos sistemas que aprendiam baseados em reforço, isto é, baseados na idéia de reforçar ações que tenham sido feitas no passado com sucesso, e em formas simples de aprendizado, sendo que o primeiro deles, provavelmente foi feito por Minsky em 1951. O conexionismo passou por um ostracismo após a publicação, em 1969, do livro *Perceptrons: An Introduction to Computational Geometry* por Marvin Minsky e S.A. Papert, no qual as propriedades de uma rede de neurônios artificiais (*perceptrons*) foram analisadas e suas limitações apontadas. Minsky e Papert provaram que uma rede de *perceptrons* somente pode resolver problemas linearmente separáveis. Um problema é linearmente separável quando pode ser resolvido através da divisão do seu espaço de estados em conjuntos disjuntos por meio de hiperplanos. Por exemplo, as funções lógicas AND e OR são linearmente separáveis mas XOR não o é. Em face dessas críticas, a pesquisa em redes neurais sofreu uma forte retração. A década de 70 e o início da de 80 foram marcadas por um silêncio quase geral na área. Alguns poucos pesquisadores como Grossberg, Kohonen, Anderson, Hopfield, Marr, Von der Malsburg e Copper continuaram pesquisando e desenvolveram trabalhos interessantes, principalmente nas áreas de memória associativa endereçável pelo

conteúdo, sistema visual e reformulações do problema de aprendizado das redes. Em 1982, Hopfield deu uma importante contribuição com a introdução da função energia e pela ênfase na noção de memórias como atratores dinamicamente estáveis. Entretanto, talvez a maior influência desta época ainda tenha vindo dos *perceptrons* [ROSENBLATT, 1962] de Rosenblatt pois, baseados em suas teorias, vários pesquisadores foram desenvolvendo algoritmos para o ajuste dos pesos das redes neurais de múltiplas camadas, culminando com o surgimento do algoritmo de *backpropagation* (retropropagação). O *backpropagation* parece ter sido primeiramente proposto por Werbos em 1974 [WERBOS, 1998] e independentemente redescoberto por volta de 1985 por Rumelhart, Hinton e Williams [RUMELHART, 1986], tendo Parker e Le Cun também propostos algoritmos semelhantes.

Após a proposição do algoritmo *backpropagation* o interesse na área voltou a crescer, desta vez de forma mais madura e promissora, sendo a teoria de redes neurais utilizada em aplicações práticas tais como: compressão de imagens e voz, reconhecimento de padrões, diagnósticos médicos, previsão de séries temporais, entre outros, e novas corporações dedicadas à comercialização desta tecnologia têm surgido.

2.4.2 Neurônio biológico

O neurônio biológico (Figura 2.10) é uma célula composta basicamente por água, eletrólitos, proteínas, lipídios e carboidratos, sendo dividida em três seções: o corpo da célula ou soma, os dendritos e o axônio, cada uma com funções específicas e complementares. O corpo de um neurônio é o centro dos processos metabólicos da célula, mede apenas alguns milésimos de milímetros e é a partir dele que se projetam os dendritos e o axônio. Os dendritos apresentam pouco comprimento. O axônio, contudo, pode ser mais longo e em geral, tem calibre uniforme. Os dendritos tem por função receber as informações, ou impulsos nervosos, oriundos de outros neurônios e conduzi-los até o soma. No soma, o impulso é processado, novos

impulsos são gerados e então transmitidos aos dendritos de outros neurônios pelo axônio. O ponto de transferência de impulso entre um axônio e os dendritos de outro neurônio é chamado de sinapse e é por meio delas que os neurônios se unem, formando redes neurais. As sinapses funcionam como válvulas, sendo capazes de controlar a transmissão de impulsos entre os neurônios. O efeito das sinapses é variável e esta variação dá ao neurônio a capacidade de adaptação.

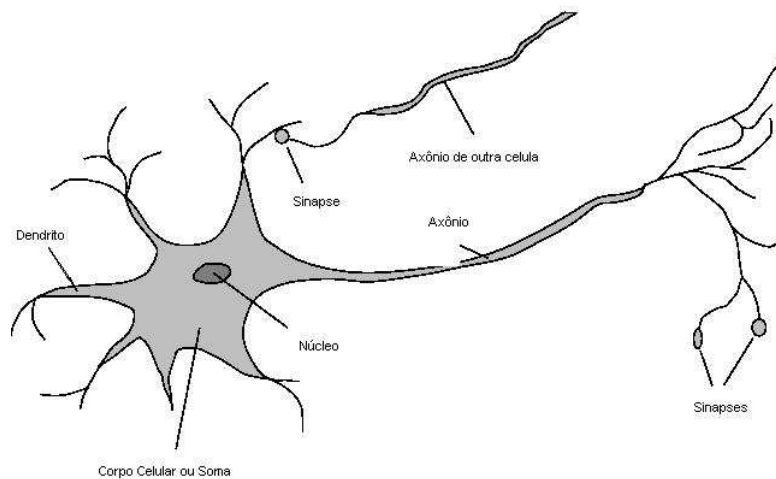


Figura 2.10: Modelo de um neurônio biológico

Fonte: McCulloch e Pitts

Segundo [Almeida, 1999] a descrição e função de cada elemento componente do neurônio biológico é:

Soma (corpo da célula): O centro dos processos metabólicos da célula nervosa, a partir do qual, projetam-se extensões filamentosas, os dendritos e o axônio.

Dendritos: cobrem um volume muitas vezes maior que o próprio corpo celular e formam uma árvore dendrital, que são “dispositivos de entrada”, que conduzem sinais das extremidades para o corpo celular.

Axônio: é um dispositivo de saída que transmite um sinal do corpo celular para as extremidades. As extremidades do axônio são conectadas com dendritos de outros neurônios pelas sinapses.

Sinapse: é a ligação entre a terminação axônica e os dendritos e que permite a propagação dos impulsos nervosos de uma célula para outra.

2.4.3 Neurônio artificial

McCulloch e Pitts desenvolveram o primeiro modelo matemático de um neurônio como um elemento binário e discreto no espaço do tempo [McCULLOCH, 1988b]. Nesse modelo, cada sinapse tem um peso sináptico positivo se a sinapse for excitatória e negativo se for inibitória. O neurônio artificial é composto por um vetor de valores de entrada (0 ou 1), um vetor de pesos sinápticos, um somador, um limiar (do inglês, *threshold*) e um valor de saída (0 ou 1). O neurônio opera em uma escala de tempo discreta. A cada passo é calculada a soma dos valores das entradas, multiplicados pelos respectivos pesos sinápticos. Se o valor resultante for maior do que o limiar, o neurônio dispara (saída assume valor 1). Caso contrário o neurônio não dispara (saída assume o valor 0). Posteriormente esse modelo foi estendido para permitir que os neurônios assumissem valores contínuos em suas entradas ou na sua saída, generalização do limiar através da inclusão de um bias e uma função de ativação para restringir a amplitude de saída do neurônio. O bias pode ser considerado como um peso adicional, com entrada fixa 1. Estes elementos podem ser vistos na Figura 2.11 onde (x_1, \dots, x_m) representam os sinais de entrada do neurônio k , (w_{k1}, \dots, w_{km}) são os pesos sinápticos aplicados às entradas (x_1, \dots, x_m) do neurônio k , b_k representa o bias aplicado externamente, v_k é a saída do somador Σ , $\varphi(\cdot)$ é a função de ativação e y_k o valor de saída do neurônio k .

2.4.4 Função de ativação

Uma função de ativação consiste de uma função para transformar o nível de ativação de um neurônio em sinal de saída. A função de ativação define a saída de um neurônio de acordo com o nível de atividade da sua entrada. Em geral, a função

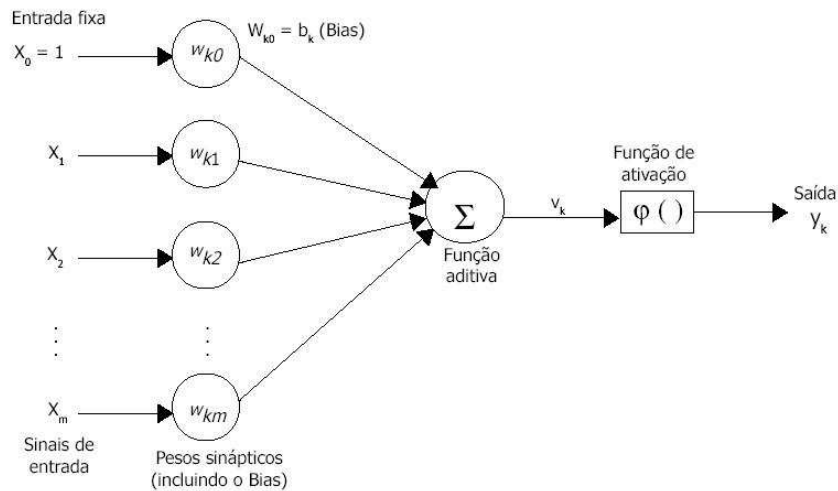


Figura 2.11: Modelo de um neurônio artificial

Fonte: McCulloch e Pitts

de ativação limita os valores da saída do neurônio aos conjuntos $0,1$ ou $-1,1$ no caso discreto ou aos intervalos $[0,1]$ ou $[-1,1]$ no caso contínuo. As funções de ativação comumente utilizadas são: binária (assume valores 0 ou 1), bipolar (assume valores -1 ou 1), sigmoide (assume valores em $[0,1]$) e tangente hiperbólica (assume valores em $[-1,1]$). A função sigmoide, cujo gráfico tem a forma de “s” (Figura 2.12), é mais utilizada na construção de redes neurais [HAYKIN, 2001].




Figura 2.12: Gráfico da função sigmoide

A representação mais utilizada para a sigmoide é a função logística, definida por: $f(v_k) = \frac{1}{1+e^{(-av_k)}}$, onde a é o parâmetro de inclinação da função sigmoide e v^k é o valor de ativação do neurônio.

2.4.5 Perceptron de múltiplas camadas

As arquiteturas do tipo *perceptron* de múltiplas camadas (*Multilayer Perceptron* - MLP) constituem os modelos neurais artificiais mais utilizados e conhecidos atualmente. Tipicamente, essa arquitetura consiste de um conjunto de unidades que formam uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Os sinais de entrada são propagados, camada a camada, da entrada para a saída (Figura 2.13).

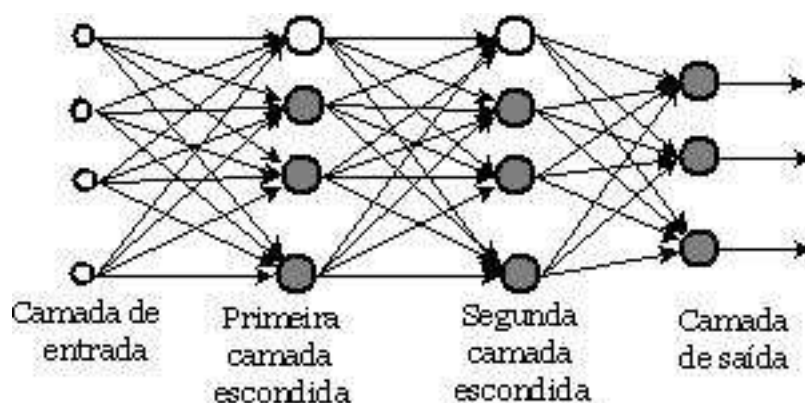


Figura 2.13: Arquitetura MLP com duas camadas intermediárias

As redes do tipo MLP tem sido utilizadas com sucesso para a solução de vários problemas envolvendo alto grau de não-linearidade. Seu treinamento é do tipo supervisionado.

2.4.6 Algoritmos de treinamento

No treinamento, a RNA “aprende” a relacionar dois conjuntos distintos de informação (entrada e saída). O aprendizado utilizado nesta fase pode ser definido como um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre [HAYKIN, 2001]. Nessa seção são apresentados os algoritmos de treinamentos de redes neurais utilizados nessa pesquisa.

Algoritmo de retropropagação

O treinamento baseado na retropropagação do erro é constituído de duas fases: uma fase de propagação das entradas da rede (Figura 2.14) e uma de retropropagação do erro (Figura 2.15). Na fase de propagação, os vetores de dados são aplicados às unidades de entrada, e seu efeito se propaga pela rede, camada a camada. Finalmente, um conjunto de saídas é produzido como resposta da rede. Durante essa fase, os pesos das conexões são mantidos fixos. Na retropropagação do erro, por outro lado, os pesos são ajustados de acordo com uma regra de correção do erro. Especificamente, a resposta da rede é subtraída da saída desejada para produzir um sinal de erro. Esse sinal de erro é retropropagado da saída para a entrada, camada a camada, originando o nome “retropropagação do erro”. Os pesos são ajustados de forma que a “distância” entre a resposta da rede e a resposta desejada seja reduzida. A regra de aprendizado utilizada é denominada regra delta generalizada ou, mais comumente, de retropropagação.

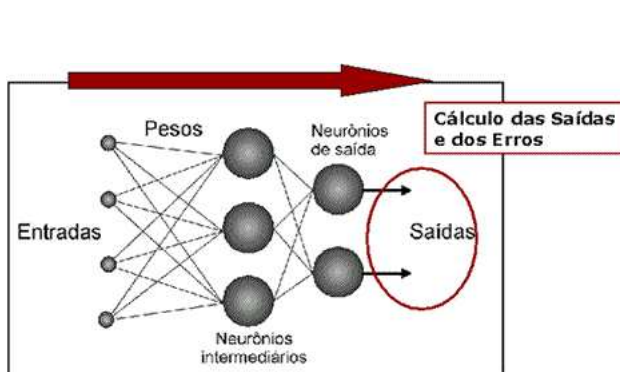


Figura 2.14: Propagação das Entradas




Figura 2.15: Retropropagação do Erro

Fonte: [MENDES, 2009]

Este algoritmo é um método de gradiente descendente que não garante chegar ao mínimo erro global, e que pode ser dividido em 5 passos:

Passo 1: Apresente um padrão de entrada e a saída desejada.

Utilizando uma determinada estratégia de apresentação coloque um dos padrões

de entrada na camada de entrada e a saída desejada na sua respectiva camada de saída, então ative o passo 2.

Passo 2: Calcule saída

A partir da primeira camada, permita que cada camada produza os valores de saída até atingir a camada de saída da rede e, então ative o passo 3.

Passo 3: Ajuste dos pesos da camada de saída

Para cada neurônio j da camada de saída, atualize todos os pesos w_{ij} conforme Equação 2.1 e, então execute o passo 4.

$$\Delta w_{ij} = \eta o_i \delta_j \quad (2.1)$$

Onde:

η : taxa de aprendizado

o_i : saída do neurônio

δ_j : o gradiente da função de erro para o neurônio j , que pode ser calculado segundo a Equação 2.2.

$$\delta_j = o_j(d_j - o_j)(1 - o_j) \quad (2.2)$$

Onde: d_j : saída desejada do neurônio j

Passo 4: Ajuste de pesos das camadas intermediárias

Para ajustar os pesos de todas as camadas intermediárias, atualize o peso de um neurônio em uma camada intermediária que está ligado a outro neurônio na camada anterior conforme Equação 2.3.

$$\Delta w_{ki} = \eta \delta_i o_k \quad (2.3)$$

Onde:

η : taxa de aprendizagem

δ_i : erro relativo do neurônio i , dado pela Equação 2.4.

$$\delta_i = o_i(1 - o_i) \sum w_{ij} \delta_j \quad (2.4)$$

Onde:

o_k : saída do neurônio k , que estimula via w_{ki}

Depois que todas as conexões tenham sido ajustadas ative o passo 5.

Passo 5: Teste a magnitude do erro

Para se testar a magnitude do erro, pode-se adotar várias estratégias diferenciadas quanto à forma de aceitar o erro como desprezível. Uma regra muito comum é verificar se o erro global de saída da rede em relação à saída desejada é menor que um dado erro predefinido. Se a condição adotada é satisfeita, então a rede aprendeu o conjunto de treinamento, caso contrário volte a ativar o passo 1 (apresente um padrão de entrada e a saída desejada).

Este algoritmo pode ser utilizado em uma arquitetura com qualquer número de camadas. O passo 4 (ajuste de pesos das camadas intermediárias) deve ser ativado recursivamente até atingir a camada de entrada. Para reduzir a oscilação durante a convergência [RUMELHART, 1986] é possível introduzir na Equação 2.2 um multiplicador chamado de *momentum* que representa um percentual do ajuste utilizado na iteração anterior o qual é somado ao ajuste atual. A introdução desse termo na equação de adaptação dos pesos tende a aumentar a estabilidade do processo de aprendizado, favorecendo mudanças na mesma direção.

Levenberg-Marquardt

Utilizando-se o algoritmo de retropropagação do erro com algumas modificações é possível utilizar um algoritmo de minimização de mínimos quadrados para o treinamento de redes neurais, denominado de *Levenberg-Marquardt* [HAGAN, 1994]. Esse algoritmo é mais eficiente do que o algoritmo de retropropagação padrão e suas variantes [LIU, 1996].

O algoritmo *Levenberg-Marquardt* possui duas variantes [AMPAZIS, 2002]: LMAM (*Levenberg-Marquardt with Adaptive Momentum*) e OLMAM (*Optimized LMAM*).

Enquanto o algoritmo de retropropagação do erro padrão utiliza a descida de gradiente como método de aproximação do mínimo da função erro, o algoritmo de *Levenberg-Marquardt* utiliza uma aproximação pelo método de Newton [HAGAN, 1994]. Este método combina características dos métodos de descida mais íngreme e do Gauss-Newton. Quando está longe da convergência, o método *Levenberg-Marquardt* comporta-se como um método de descida mais íngreme: retarda, mas é garantida a convergência. Caso contrário, comporta-se como o método do Gauss-Newton.

O método de *Levenberg-Marquardt* na prática tem características de convergência global (converge para o mínimo local a partir de qualquer valor aproximado). O método pode ser resumido conforme Figura 2.16.

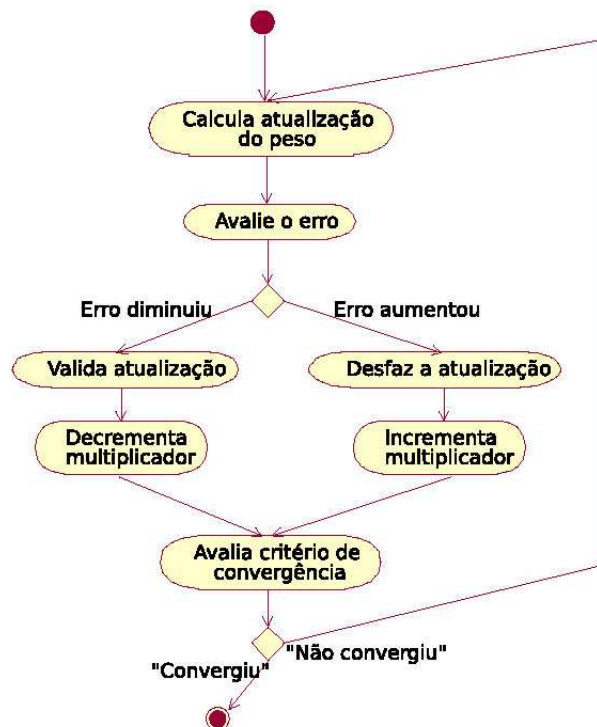


Figura 2.16: Sequência de passos para o método de *Levenberg-Marquardt*

O treinamento da rede por esse método ocorre por iterações. Essas iterações consistem em se aplicar todos os dados de entrada de treinamento na rede, verificar o erro entre a saída obtida e a saída desejada para cada um destes conjuntos e ajustar os pesos das conexões para diminuir o erro médio (MSE) encontrado. Isso evita que, ao ajustar a rede para uma entrada, aumente-se o erro das outras. Os detalhes desse algoritmo estão apresentados no Apêndice A.

2.5 Conclusão do capítulo

Como visto neste capítulo, existem algumas técnicas que são usadas com o objetivo de realizar a classificação do acabamento de gordura. As soluções usadas como marmorização, observação visual, medidas objetivas e até mesmo análise de imagens por vídeo são sistemas que funcionam, mas não são sistemas automatizados e que visam diretamente a classificação do acabamento de gordura. Baseado nisso, no próximo capítulo é proposta uma metodologia para a automatização da classificação do acabamento de gordura conforme as regras estabelecidas pelo Ministério da Agricultura, Pecuária e Abastecimento, por meio da Portaria N.º 612/89 na qual está instituído o sistema de classificação do acabamento usado aqui no Brasil.

Capítulo 3

Solução proposta

Esse capítulo descreve a solução proposta, baseada na proposição e implementação de um protótipo funcional para aquisição, *in loco*, de imagens digitais de carcaças bovinas, segmentação da gordura e classificação das imagens por meio de redes neurais.

3.1 Metodologia da pesquisa

Essa pesquisa foi realizada por meio de pesquisa de campo e revisão de literatura. Ela apresenta um estudo da classificação do acabamento de gordura, conforme Portaria N.º 612/89 do MAPA. Tal Portaria prevê que o acabamento seja feito pela distribuição e quantidade de gordura de cobertura da carcaça bovina de acordo com as 5 categorias, por meio de análise visual de um especialista treinado.

A pesquisa de campo foi realizada em uma indústria frigorífica do sul do país. A coleta de dados ocorreu durante o abate em um período compreendido entre os meses de fevereiro/2009 a junho/2009, sendo coletadas um total de 4.710 imagens digitais de carcaças bovinas.

A revisão de literatura foi realizada por meio de pesquisas dos autores

[SAINZ, 2001] [JORGE, 2007] [BRITO et al., 2006]. A pesquisa é de enfoque quantitativo e experimental.

A partir das imagens digitais coletadas, foram selecionadas amostras de pixels de gordura e amostras de pixels de não gordura. Tais amostras foram submetidas a uma rede neural do tipo MLP, usando algoritmo *Levenberg-Marquardt* para realizar a segmentação. Realizada a segmentação destas áreas correspondentes a gordura, as imagens segmentadas foram reduzidas e submetidas a uma rede neural do tipo MLP usando algoritmo de retropropagação do erro para a classificação do acabamento de gordura.

A classificação do acabamento de gordura é um dos parâmetros do Sistema Nacional de Tipificação de carcaças bovinas e consiste (Seção 1) na classificação das carcaças em categorias de 1 a 5 de acordo com a distribuição da gordura de cobertura. A metodologia proposta automatiza procedimentos para a classificação do acabamento de gordura das carcaças bovinas, em conformidade com a Portaria N.º 612/89.

A solução proposta está estruturada em três etapas.

A primeira etapa compreende a aquisição das imagens de carcaças bovinas, coletadas *in loco* durante o processo de abate em indústrias frigoríficas da Região Sul do país. Para tanto foi desenvolvido um protótipo funcional instalado em Santa Maria, Rio grande do Sul, em parceria com pesquisador do Departamento de Medicina Veterinária da Universidade Federal de Santa Maria.

A segunda etapa engloba o uso de técnicas de processamento de imagens digitais e técnicas de reconhecimento de padrões capazes de separar a área correspondente a gordura nas imagens digitais coletadas de carcaças bovinas. Foram analisadas diversas abordagens sendo que a utilização de rede neural MLP com treinamento supervisionado (*Levenberg-Marquardt*) apresentou melhor desempenho para esta tarefa de segmentação dos pixels de gordura.

A terceira corresponde ao emprego de técnicas de reconhecimento de padrões

capazes de realizar a classificação da imagem resultante da segunda etapa, de acordo com os padrões do acabamento de gordura descritos na Portaria citada. Também para essa tarefa foram estudadas diversas abordagens sendo que novamente a utilização de uma rede neural MLP com treinamento supervisionado com retropropagação do erro apresentou melhor desempenho para a classificação nas quatro categorias iniciais. Devido a não obtenção de imagens do tipo 5, durante os meses de coleta de imagens *in loco* no frigorífico, não foi possível desenvolver um classificador neural para essa categoria de acabamento de gordura.

3.2 Aquisição de imagens

Os experimentos para o desenvolvimento do protótipo foram realizados em indústrias frigoríficas da Região Sul do país. Foram realizados estudos para levantamento de alguns parâmetros, entre eles:

- mínima resolução necessária para as imagens a serem coletadas
- formato de gravação das imagens coletadas
- mídia de gravação das imagens
- características da iluminação necessária
- definição do melhor equipamento (câmera de vídeo ou câmera fotográfica) para operar no ambiente hostil da indústria frigorífica
- projeto e construção de suporte para a câmara industrial selecionada
- seleção e implantação de mecanismo para acionamento remoto da câmara
- definição do local de instalação do dispositivo de aquisição de imagens
- instalação do protótipo de aquisição de imagens

Após a definição de tais parâmetros, partiu-se para a instalação *in loco* na indústria frigorífica. Durante a instalação e operação do protótipo foram detectados

e corrigidos diversos problemas, dentre eles: comprimento excessivo dos cabos coaxiais para conexão da câmera de vídeo ao computador que ocasionava perda de qualidade da imagem durante a captura; sensor de disparo inicialmente utilizado, semelhante a um mouse de computador, não resistiu ao contato com os ganchos de ferro que transportam a carcaça na linha de abate e acabou quebrando, sendo então substituído por sensor infravermelho que parava de funcionar após algum tempo de operação. Detectou-se que isso ocorria em virtude da umidade e do vapor de água excessivos no ambiente. Este sensor foi substituído por um sensor mecânico com haste fixa que também teve que ser substituído pois algumas carretilhas/roldanas vinham inclinadas devido ao grande peso dos animais e não permitiam acioná-lo, conseqüentemente não captando a imagem. Atualmente o sensor utilizado pelo protótipo é um sensor mecânico com haste regulável. Outros problemas menores e as soluções adotadas, durante essa fase, estão descritos na Tabela 3.1.

A instalação do dispositivo para aquisição das imagens segue os seguintes passos. Primeiramente é avaliado o local de instalação, a fim de encontrar a posição mais adequada para instalar a câmera e o sensor mecânico. Então é feita a medição da distância da localização da câmera e sensor até o computador, para verificar se tal distância não comprometerá a qualidade do sinal. A seguir são instalados o sensor e o suporte da câmera. A câmera nessa fase já se encontra com os dois cabos internos soldados (solda de estanho), passados por toda a extensão do suporte e com regulagem de altura já realizada. Os cabos são instalados a uma distância mínima dos cabos elétricos para evitar possíveis interferências, e chegam até o computador. Os cabos que saem do sensor sobem pelo suporte de sustentação do trilho até o forro e assim encaminham-se até a placa de mouse, que é ligada ao computador.

Tabela 3.1: Problemas enfrentados durante instalação do protótipo

Problemas encontrados	Solução adotada
Programa não recebe sinal	Cabo que sai do sensor até a placa oxidou na extremidade e quebrou, refeita a conexão e melhorada a vedação do sensor.
Disparos múltiplos do sensor	350 animais abatidos, em média, mas eram coletadas cerca de 2000 fotos. Mau contato. Trocou-se o par de fios do sensor.
Fadiga da haste do sensor	Sensor em uso tinha como haste uma espécie de mola e capturava fotos tanto na ativação vertical como horizontal, a mola se desgastou e capturava muitas fotos da mesma carcaça. Foi trocado o sensor por um com ativação só na horizontal e com regulagem de haste.
Luzes de fundo atrapalham na visualização da imagem	Foi acrescentado um anteparo na parte frontal da câmera para reduzir o ofuscamento.
Clareza e ruídos na imagem atrapalham sua visualização	Tampado o sensor de luminosidade da câmera que tem regulagem automática de clareza. Uma vez tampado o sensor a luminosidade ficou uniforme. Quanto aos ruídos foram refeitos os conectores do cabo que envia imagens para a câmera e feito a limpeza da lente.
Imagem da câmera embaçada	Lentes limpas com pano úmido.
Problema no cabo coaxial	Substituído o cabo coaxial por um cabo de vídeo e conectores RCA que tem melhor soldabilidade. Os cabos foram passados pelo forro.
Nória e equipamentos da linha de abate ligados provocavam interferência no cabo	Cabo de vídeo não tem um bom isolamento contra interferências. Tal cabo foi passado por um conduíte, por toda a extensão do forro até o computador.
Permanece interferências nas imagens	Trocado cabo novamente, por um cabo blindado com impedância de 75 Ω .
Imagens com pouca nitidez	A lente da câmera estava embaçada, precisando de limpeza diária.

3.3 Segmentação

A segmentação, consiste em subdividir uma imagem em suas partes ou objetos constituintes. O nível até o qual essa subdivisão deve ser realizada depende do problema que está sendo resolvido. Ou seja, a segmentação deve parar quando os objetos de interesse na aplicação tiverem sido isolados. Em geral, a segmentação é uma das tarefas mais difíceis em processamento de imagens. A quali-

dade dessa tarefa determina o eventual sucesso ou fracasso na análise de imagens [GONZALES, 2000].

Como resultado de uma segmentação, cada um dos pixels existentes em uma mesma região é similar com referência a alguma característica ou propriedade computacional, tais como cor, intensidade, textura ou continuidade. No caso da segmentação da área de gordura nas imagens digitais das carcaças bovinas, o resultado deverá ser o conjunto de pixels de gordura que possuem intensidades de cor semelhantes e que correspondem às áreas de gordura da carcaça.

A área referente a carcaça bovina em uma imagem digital (Figura 3.1) é constituída dos seguintes elementos: gordura, músculos, ossos e tendões. A imagem digital obtida possui também regiões que correspondem aos elementos existentes ao plano de fundo, tais como: parede, objetos e instrumentos de metal, pessoal de serviço, luzes, etc. Para melhor compreensão, os elementos da imagem serão divididos em pixels de gordura (regiões de gordura da carcaça) e pixels de não gordura.



Figura 3.1: Imagem digital de uma carcaça bovina obtida durante o abate

Inicialmente foi pesquisada a possibilidade de segmentar a imagem com base na tonalidade dos pixels de gordura e dos pixels de não gordura. Para isso foram

realizados experimentos usando o sistema de cores RGB e HSV. Com o auxílio de médicos veterinários da UFSM foram retiradas das imagens amostras de 5x4 pixels de gordura e de não gordura. A título de exemplo, os valores RGB de uma amostra de gordura são apresentados na Tabela 3.2 e de não gordura na Tabela 3.3.

Tabela 3.2: Componentes de cor dos pixels correspondentes à gordura

R				G				B			
177	158	148	137	161	142	132	121	135	117	107	096
165	155	148	131	149	139	132	115	124	114	107	092
144	148	149	134	128	132	133	118	103	107	108	095
122	137	149	144	106	121	133	128	081	098	110	105
125	144	162	162	109	128	146	145	086	105	123	125

Tabela 3.3: Componentes de cor dos pixels correspondentes à não gordura

R				G				B			
254	245	100	133	254	246	102	134	246	230	080	118
255	188	101	127	255	189	103	128	247	173	081	112
204	111	110	108	204	112	112	109	196	096	090	093
164	074	126	089	164	075	128	190	156	059	107	076
145	083	110	092	144	084	112	093	139	070	091	079

Para facilitar a análise dos variabilidade das tonalidade dos pixels das amostras foi traçado gráfico, a partir dos pixels de áreas de gordura e de não gordura, para visualizar se a distribuição espacial deles não apresentava sobreposição. No gráfico apresentado na Figura 3.2 estão apresentados os intervalos correspondentes aos valores RGB dos pixels para as áreas de gordura e de não gordura. Pode-se observar que há uma superposição dos intervalos para as áreas de gordura e de não gordura para todas as componentes RGB, não permitindo separação via limiar.

Como não foi possível segmentar gordura e não gordura com base na análise de pixels no sistema RGB, foram realizados experimentos com o sistema de cores HSV - *Hue, Saturation and Value* para verificar se, com base na distribuição da componente V, os pixels de gordura e não gordura podem ser separados. Como resultados dos experimentos, foram obtidas faixas de valores para a componente V

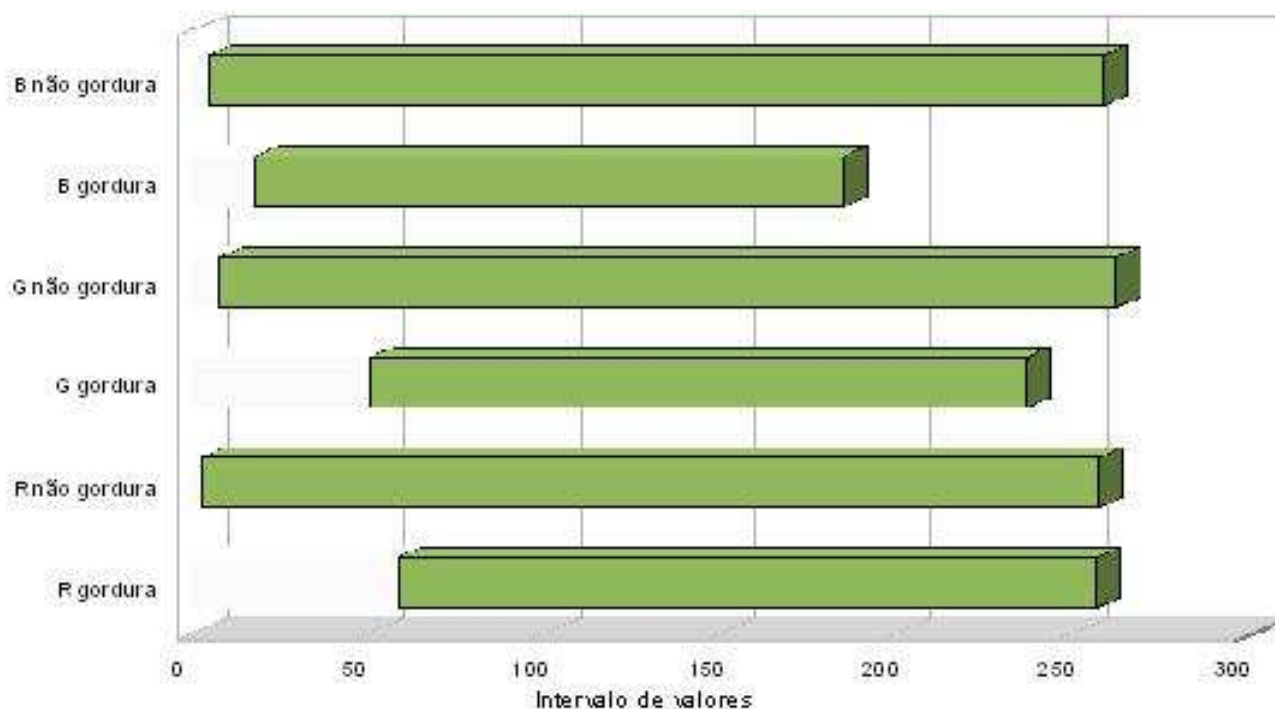


Figura 3.2: Gráfico de sobreposição dos pixels

muito semelhantes, tanto para os pixels de gordura como para os não gordura, não permitindo separação via limiar.

Devido ao fato de não ser possível a separação linear dos pixels, com base em sistemas de cores, partiu-se para o uso de classificadores não lineares, em especial, as redes neurais artificiais (Seção 2.4). Nessa fase foi analisada a possibilidade de se segmentar os pixels de gordura nas imagens das carcaças bovinas através da utilização de uma RNA que fosse capaz de, dado um pixel no formato RGB, classificá-lo como gordura ou não gordura. Esse método está ilustrado na Figura 3.3.

3.3.1 Base de dados

Foram utilizadas nessa pesquisa um total de 4.710 imagens coloridas digitais coletadas durante o abate em uma indústria frigorífica da Região Sul. Tais imagens

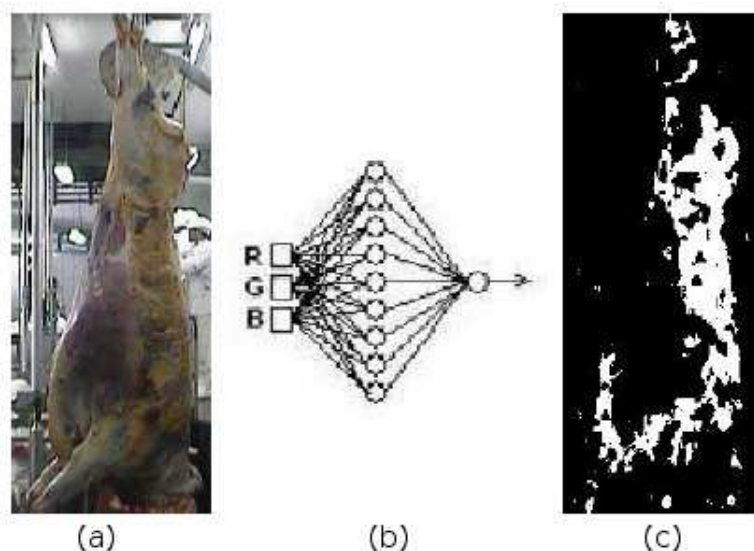


Figura 3.3: (a) Imagem digital (b) Rede neural (c) Segmentação

foram gravadas com o padrão de compressão de imagens JPEG com resolução espacial de 352x132 pixels.

3.3.2 Preparação dos dados

Para o treinamento das redes neurais, foram extraídas, por médicos veterinários da UFSM, amostras de áreas de gordura e de não gordura das imagens das carcaças bovinas. Tais amostras foram obtidas de forma a garantir que todas as variações de cor de áreas de gordura e de áreas de não gordura fossem coletadas. Essas amostras foram submetidas como entrada de uma rede neural do tipo *perceptron* de múltiplas camadas, durante o treinamento da rede, compondo uma base de treinamento balanceada, sendo 50% dessas amostras composta por áreas de gordura.

3.3.3 Treinamento da rede neural

Foi preparado inicialmente um conjunto de treinamento (Tabela 3.4), denominado TreinaCj, composto por 3.528 amostras sendo 1.764 amostras de gordura e 1.764 amostras de não gordura. Esses dados estão dispostos como uma matriz 3×3.528 ,

sendo que cada conjunto de 3 linhas corresponde a um padrão de cor RGB para uma dada amostra. O conjunto de saída denominado Alvo, na forma de uma matriz 1x3.528, está associado a esse conjunto de treinamento, de forma tal que cada linha assuma o valor 1 para pixels de gordura e 0 para pixels de não gordura.

Tabela 3.4: Conjunto treinamento usado para segmentação

Conjunto	Amostras Gordura	Amostras Não Gordura	Total Amostras
TreinaCj1	1.764	1.764	3.528
Alvo	1	0	

Os elementos do conjunto de treinamento foram normalizados pela Equação 3.1.

$$PN = \frac{(P - P_{min})}{(P_{max} - P_{min})} \quad (3.1)$$

Onde:

PN = valor da intensidade de cor do pixel, normalizado

P = valor da intensidade de cor do pixel em questão

P_{min} = menor valor do intervalo do conjunto original

P_{max} = maior valor do intervalo do conjunto original

Os valores referentes às intensidades de cor dos pixels utilizados nesta pesquisa, originalmente dispostos no intervalo [0,255], foram normalizados para o intervalo [0,1].

3.3.4 Configuração da rede neural

Conforme [HAYKIN, 2001] [FAGGIN, 1991], a definição da topologia da rede neural mais apropriada a determinado problema é essencialmente empírica. A primeira camada foi configurada com três neurônios para receber diretamente cada pixel RGB da imagem, e a última camada foi dimensionada com um neurônio para retornar gordura ou não gordura. Na camada intermediária, foi utilizada apenas uma camada. A quantidade de neurônios nessa camada foi definida em função

da quantidade de dados utilizada no treinamento. Após a definição do número de camadas e a quantidade de neurônios em cada uma delas, escolheu-se a função de transferência sigmoide (Seção 2.4.4) para todas as camadas. O motivo dessa escolha foi pelo fato de que a saída dos neurônios fosse limitada a uma pequena faixa, eliminando a possibilidade de ocorrerem valores negativos e diminuindo a possibilidade de resultados muito espúrios.

Durante o treinamento, os dados foram submetidos a diferentes redes neurais com topologia *feedforward*. A escolha inicial do número de neurônios na camada intermediária deu-se por meio do cálculo da média aritmética entre o número de neurônios da camada de entrada e a de saída da rede. No andamento dos experimentos foi aumentado o número de neurônios da camada intermediária. Como algoritmo de treinamento foi usado o *Levenberg-Marquardt* (Seção 2.4.6).

A Figura 3.4 representa graficamente a topologia da rede neural utilizada para segmentar as áreas de gordura da imagem digital da carcaça bovina, nela estão representadas: a camada de entrada contendo 3 (três) neurônios; matriz de pesos de entrada (IW1) e a matriz de bias (b1); a camada intermediária contendo 7 (sete) neurônios; função de ativação sigmoide, matriz de pesos da camada intermediária (LW2) e a matriz de bias (b2); e a camada de saída contendo 1 (um) neurônio, função de ativação sigmoide.




Figura 3.4: Modelo de topologia de rede usado na etapa da segmentação

A rede apresentada na Figura 3.4 foi treinada usando os parâmetros de treinamento apresentados na Tabela 3.5. Os demais parâmetros tiveram seus valores mantidos inalterados em relação aos valores padrões da ferramenta computacional

utilizada (MATLAB®), destacando-se 0.001 como valor inicial para o parâmetro μ do treinamento Levenberg-Marquardt. Sobre esse parâmetro adaptativo são aplicados o fator de incremento de 10 ou o fator de decremento de 0.1.

Tabela 3.5: Parâmetros de treinamento da rede neural usados na segmentação

Parâmetro	Valor
Iterações	10.000
Erro médio	0.001
μ	0.001

3.4 Classificação do acabamento

Para investigar a hipótese de ser possível classificar o acabamento da carcaça com base no cálculo da densidade de gordura (número de pixels de gordura dividido pelo número total de pixels da carcaça) foram realizados experimentos com o objetivo de delimitar na imagem digital a área da carcaça bovina. Tal delimitação foi testada por meio da aplicação de algoritmos de detecção de contornos, mais precisamente, do filtro de Sobel e foi motivada pela constatação de que as carcaças possuem dimensões variadas e o simples cálculo da divisão do número de pixels de gordura pelo total de pixels da imagem não espelha a relação entre pixels de gordura e de não gordura na carcaça.

O filtro de Sobel destina-se a detectar (salientar) os contornos das formas presentes numa imagem. O filtro é composto por duas máscaras [GONZALES, 2000], uma que salienta os contornos verticais e outra que salienta os contornos horizontais. O filtro de Sobel calcula o gradiente da intensidade dos pixels da imagem em cada ponto, dando a direção da maior variação de claro para escuro e a quantidade de variação nessa direção. Assim, obtém-se uma noção de como varia a luminosidade em cada ponto, de forma mais suave ou abrupta.

Nos experimentos realizados foi usado este filtro combinado com operações morfológicas (erosão, dilatação, abertura e fechamento) para se delimitar o contorno da

carça. Juntamente com a aplicação da máscara do filtro, foi realizado o teste com um limiar pré-estabelecido: o pixel só era considerado uma descontinuidade se o valor resultante da operação de filtragem fosse maior que o limiar. Quanto maior fosse o valor deste limiar, menor a quantidade de descontinuidades encontradas na imagem. Esse método não produziu bons resultados (Figura 3.5), pois como a imagem possuía muitos ruídos, houve a detecção de toda e qualquer transição claro-escuro, não sendo possível detectar apenas o contorno da carça. As imagens possuem diversas transições de claro-escuro em função da proibição da Administração do frigorífico de se utilizar qualquer material para compor um plano de fundo escuro na posição da linha de abate onde as imagens foram coletadas. Esse fato dificulta aplicar algoritmos de processamento de imagens digitais para determinação do contorno baseado na transição da tonalidade de pixels.



Figura 3.5: Imagem original e imagem resultante da aplicação do filtro de sobel

Em virtude da dificuldade de se obter contorno da carça e da impossibilidade de se utilizar plano de fundo para minimizar essa dificuldade, foram realizados experimentos considerando a distribuição espacial dos pixels de gordura existentes na carça como um todo. O cálculo da quantidade de pixels referentes a gordura, levando em conta toda a área presente na imagem digital já segmentada, deu-se

conforme a Equação 3.2.

$$IndiceGordura = \frac{QPG * 100}{TImg} \quad (3.2)$$

Onde: QPG é a quantidade de pixels correspondentes a gordura (pixels com valores diferentes de 0) e $TImg$ é o tamanho da imagem (Altura x Largura), em pixels.

O objetivo é verificar se a partir dos valores obtidos na Equação 3.2 é possível encontrar uma faixa de valores que seja única para cada categoria de acabamento de gordura existente. Com base nos valores encontrados por categoria, foram traçados gráficos para melhor visualização das frequências dos pixels gordura e não gordura em um conjunto de 4710 imagens.

No gráfico de barras apresentado na Figura 3.6, a coordenada x representa o percentual de gordura e a coordenada y representa os 4 tipos do acabamento de gordura. Min corresponde ao menor percentual de gordura existente naquela categoria, e Max é o maior percentual existente na respectiva categoria.

Analisando as distribuições verifica-se que há uma grande intersecção dos percentuais de gordura contidos em cada tipo indicando que não é possível efetuar a classificação do acabamento de gordura das carcaças bovinas em imagens digitais apenas pela definição de um intervalo do percentual de gordura entre os tipos possíveis.

Face a dificuldade em realizar a classificação do acabamento com os experimentos realizados e por outros envolvendo tentativa de segmentação com base nos algoritmos *split and merge* e *watershed*, optou-se também por usar redes neurais na etapa de classificação. O esquema da classificação pode ser visto na Figura 3.7.

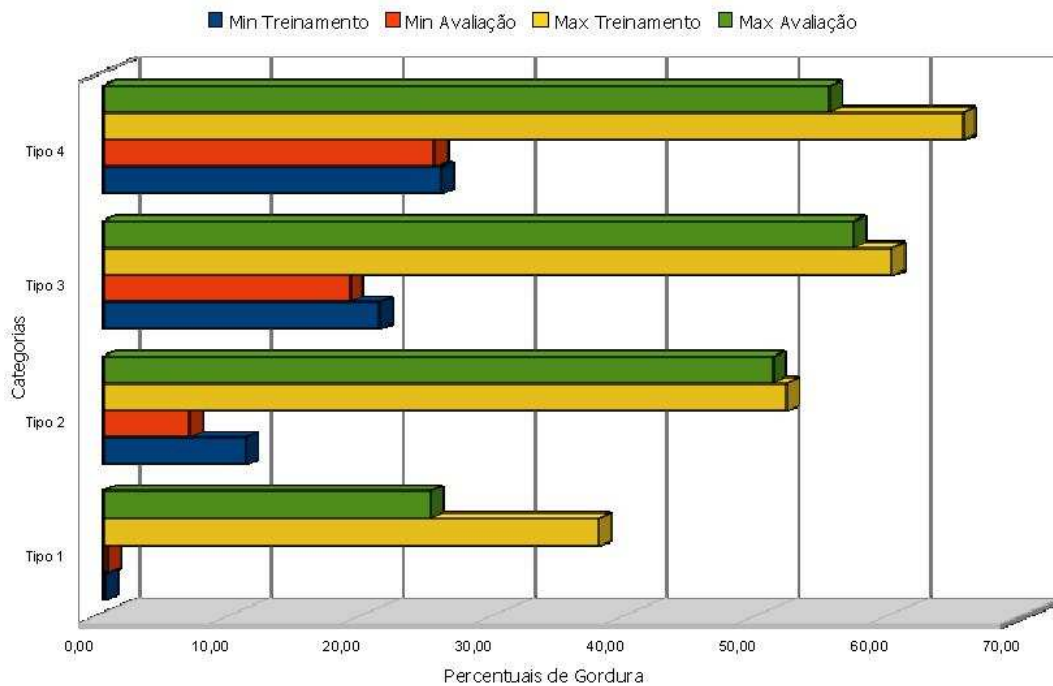


Figura 3.6: Gráfico de Frequência de Pixels de Gordura e não Gordura

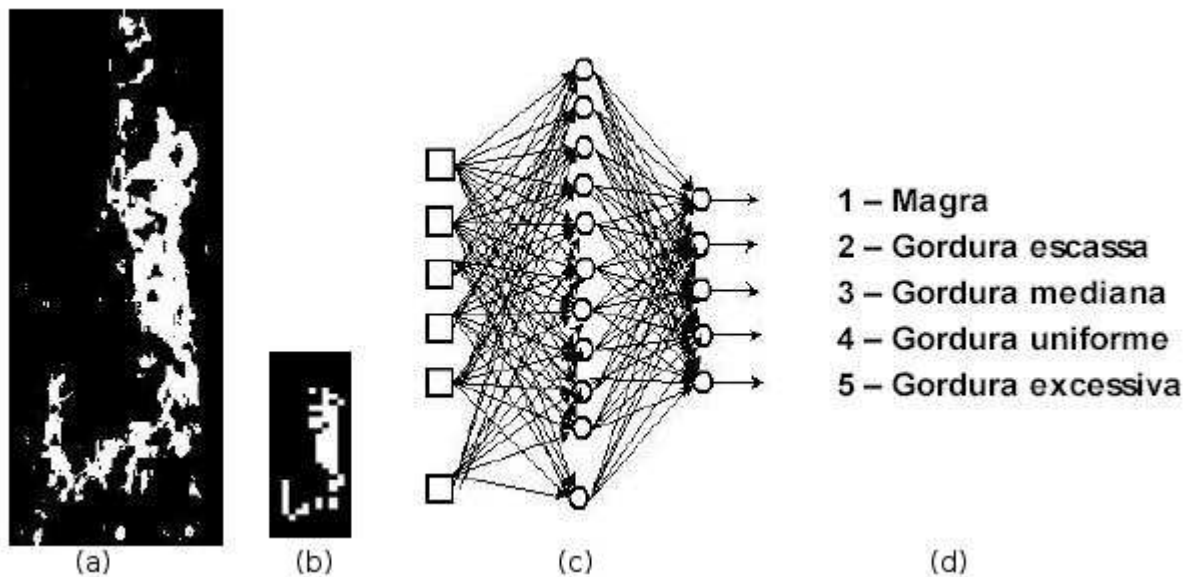


Figura 3.7: (a)Imagem segmentada (b)Pré-processamento (c)Rede neural (d)Saída

3.4.1 Base de dados

É oportuno ressaltar que, até o momento da realização desta pesquisa, não foram obtidas imagens de carcaças com classificação do acabamento de gordura do tipo 5. Um dos fatores que pode explicar a baixa ocorrência de abate de animais desse tipo

é o fator financeiro, pois pode ser inviável para o produtor engordar em demasia o seu gado bovino.

Nesta etapa de classificação do acabamento de gordura foram utilizadas as mesmas imagens usadas na etapa de segmentação, ou seja 4.710 imagens. O conjunto total de imagens foi inicialmente dividido em dois subconjuntos (Tabela 3.6), sendo eles destinados ao treinamento e a avaliação. Para a divisão dos subconjuntos, foi utilizada uma amostragem aleatória estratificada para se manter as frequência dos tipos de acabamento de gordura observadas no conjunto do total das imagens coletadas. As imagens contidas em cada categoria de 1 a 4 serão denominadas, daqui em diante, tipo 1, tipo 2, tipo 3 e tipo 4, respectivamente.

Tabela 3.6: Distribuição das imagens por categoria

Conjunto	Tipo1	Tipo2	Tipo3	Tipo4	Total
Treinamento	157	2.250	728	03	3.138
Avaliação	79	1.126	365	02	1.572
Total	236	3.376	1.093	05	4.710

Como solução para a classificação do acabamento de gordura, é apresentado a seguir, o desenvolvimento de um classificador baseado em uma rede neural do tipo *perceptron* de múltiplas camadas, com treinamento do tipo retropropagação do erro, capaz de classificar as regiões de gordura segmentadas da imagem digital, de acordo com as 4 categorias estabelecidas na Portaria MAPA N.º 612/89.

3.4.2 Preparação dos dados

Como as imagens digitais possuem uma dimensão espacial de 352x132, totalizando 46.464 pixels, se cada pixel fosse modelado como uma entrada para a rede neural, o número de neurônios da rede seria muito grande, dificultando o seu processamento. Para permitir modelagem de redes neurais de tamanhos mais adequados, foi realizada uma redução de tamanho destas imagens por meio da aplicação de uma máscara de MxM bits. Tal redução é aqui denominada como pré-processamento.

A aplicação da máscara à imagem segmentada resulta em uma nova matriz. O valor de cada posição desta nova matriz é função da quantidade de pixels de gordura existentes na máscara aplicada à imagem segmentada (Figura 3.8). Caso a quantidade de pixels de gordura na área mascarada seja maior que a metade dos pixels existentes nela mesma, a posição correspondente na nova matriz recebe valor 1, caso contrário recebe valor 0. Cada posição nesta nova matriz (Figura 3.8) servirá de entrada para as redes neurais utilizadas para realizar a classificação do acabamento de gordura.

Para o treinamento das redes neurais utilizadas na etapa de classificação do acabamento foram realizados experimentos com máscaras de diversos tamanhos, sendo que foi a de tamanho 11x11 (11 pixels x 11 pixels) a que apresentou melhor performance na classificação do acabamento da gordura. Com a aplicação dessa máscara, a matriz da imagem segmentada passa a ter a dimensão de 32 linhas por 12 colunas. Cada elemento da matriz tem o valor 0 ou 1.




Figura 3.8: Carcaça segmentada (esq.) e carcaça submetida a máscara (dir.)

3.4.3 Treinamento da rede neural

O treinamento da rede foi feito a partir das 3.138 imagens do conjunto de treinamento (TreinaClass), após a aplicação da máscara (Tabela 3.7).

Tabela 3.7: Conjunto treinamento usado para classificação

Conjunto	Tipo1	Tipo2	Tipo3	Tipo4	Total
TreinaClass	157	2.250	728	03	3.138

Para o conjunto de treinamento, TreinaClass, foi criado uma matriz de saída correspondente. Tal matriz possui dimensões 4x3.138 sendo 4 linhas representando as categorias do acabamento e 3.138 colunas representando cada uma das imagens amostradas.

A Tabela 3.8 apresenta o resultado ideal esperado na saída da rede para cada uma das categorias do acabamento de gordura possíveis existentes.

Tabela 3.8: Resultados esperados para a classificação

	Tipo 1	Tipo 2	Tipo 3	Tipo 4
Saída esperada	1	0	0	0
	0	1	0	0
	0	0	1	0
	0	0	0	1

A rede foi treinada utilizando-se os parâmetros de treinamento apresentados na Tabela 3.9. Os demais parâmetros tiveram seus valores mantidos inalterados em relação aos valores padrões da ferramenta computacional utilizada (MATLAB[®], versão 7).

Tabela 3.9: Parâmetros de treinamento da rede neural usados na classificação

Parâmetro	Valor
Taxa de aprendizado	0.4
Iterações	10.000
Erro médio	0.001

3.4.4 Configuração da rede neural

Para avaliar o possível impacto da distribuição espacial dos pixels de gordura nas carcaças, o número de neurônios da camada de entradas foi estudado. Em todos

esses estudos se utilizou uma MLP *feedforward*, com treinamento baseado na retropropagação do erro. O número ideal de neurônios da camada intermediária foi obtido por experimentação. A análise do impacto da distribuição espacial dos pixels de gordura abrangeu experimentos inspirados em “projeções” na horizontal e na vertical dos elementos da imagem segmentada da imagem reduzida para as dimensões 32 x 12, considerando:

- 384 neurônios: sem informação espacial (total de elementos da imagem reduzida);
- 44 neurônios: 32 (cada um representando a soma das 12 colunas para cada uma dada linha) + 12 (cada um representando a soma das 32 linhas para uma dada coluna);
- 32 neurônios: cada um representando a soma das 12 colunas para cada uma dada linha;
- 12 neurônios: cada um representando a soma das 32 linhas para uma dada coluna;

Tanto na camada intermediária como na camada de saída foi utilizada a função de ativação sigmóide.

3.4.5 Métricas para avaliação dos resultados

Matriz de confusão

Por se tratar de classificadores foram utilizados índices obtidos através da matriz de confusão. Para classificação multiclases, as classificações no conjunto de avaliação são apresentadas na forma de uma matriz bidimensional com uma linha e uma coluna para cada classe. Cada elemento desta matriz, chamada matriz de confusão, apresenta o número de casos avaliados na qual a classe real (R) é a linha

e a classe predita (P) pelo classificador é a coluna. Bons resultados são caracterizados por valores altos na diagonal principal e valores nulos para elementos fora da diagonal principal. Suponha que um classificador está sendo utilizado para classificar uma instância que possui apenas duas classes, por exemplo, “sim” e “não”. A Tabela 3.10 ilustra a nomenclatura utilizada para as classificações possíveis.

Tabela 3.10: Matriz de Confusão com duas classes

R/P	SIM	NÃO
SIM	Verdadeiro Positivo (VP)	Falso Negativo (FN)
NÃO	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Nessa análise foram utilizados os índices apresentados na Tabela 3.11. Todos eles assumem valores no intervalo [0,1] e podem ser calculados a partir da matriz de confusão.

Tabela 3.11: Índices para discriminação entre classificadores dicotômicos

Sensibilidade (S)	Especificidade (E)	Acurácia (Ac)	F-measure (F_1)
$S = \frac{VP}{VP+FN}$	$E = \frac{VN}{VN+FP}$	$Ac = \frac{VP+VN}{VP+FP+VN+FN}$	$F_1 = \frac{2*S*E}{(S+E)}$

A sensibilidade é a habilidade de classificar corretamente as carcaças pertencentes à determinada categoria, é a taxa de verdadeiro positivo; a especificidade é a habilidade de classificar corretamente as carcaças que não pertencem à determinada categoria, é a taxa de verdadeiro negativo e a acurácia é a probabilidade de acerto do classificador. O melhor classificador é o que possui maior acurácia. F_1 é uma média harmônica entre sensibilidade e especificidade. Por esse produto, o melhor classificador é aquele que maximiza a taxa de verdadeiro positivo e, simultaneamente, minimiza a taxa de falso positivo, ou seja o lixo associado aos casos selecionados como positivo. O ponto de máximo para as métricas de acurácia e F_1 ocorre quando VP e VN tendem para 1.

3.5 Conclusão do capítulo

Nesse capítulo foi apresentado o desenvolvimento de uma metodologia para segmentar as áreas de gordura de imagens digitais de carcaças bovinas e de classificar o acabamento de gordura.

Capítulo 4

Resultados obtidos

Neste capítulo serão feitas considerações acerca do treinamento de cada uma dessas redes e serão apresentados os resultados do protótipo de aquisição de imagens, bem como os resultados obtidos pela referida metodologia, com a aplicação do conjunto de testes e avaliação.

4.1 Protótipo de aquisição de imagens

O dispositivo de aquisição proposto para a coleta das imagens utilizadas nesta pesquisa é composto por uma câmera de vídeo blindada (VDI 2001, CCD color de alta resolução, 420 linhas, lente de 3,6mm auto íris eletrônica), fixada a um ângulo de 90° em relação ao chão, luminosidade proveniente da própria câmera e de lâmpadas fluorescentes presentes no ambiente. A câmera é posicionada a uma distância de 5 metros à frente do trilho onde passam as carcaças bovinas. A captura da imagem ocorre com o acionamento de uma chave eletro-mecânica que está fixada no suporte das roldanas que transportam a carcaça na linha de abate. Dessa forma, toda vez que uma roldana passa pela chave, ocorre o acionamento automático da câmera capturando a imagem da carcaça. A chave eletro-mecânica está ligada a uma das portas PS/2 do computador no qual as imagens capturadas pela câmera

são armazenadas em formato JPEG, padrão de cores RGB, com a dimensão espacial de 352 linhas x 132 colunas.

O esquema do protótipo de aquisição de imagens desenvolvido pode ser demonstrado conforme Figura 4.1. Para a coleta das imagens foi desenvolvido um software em linguagem Delphi. As imagens são armazenadas em um servidor de dados localizado na UFSM e disponibilizados para os experimentos por meio de FTP. Foram coletadas um total de 4.710 imagens e a coleta das imagens continua em andamento.

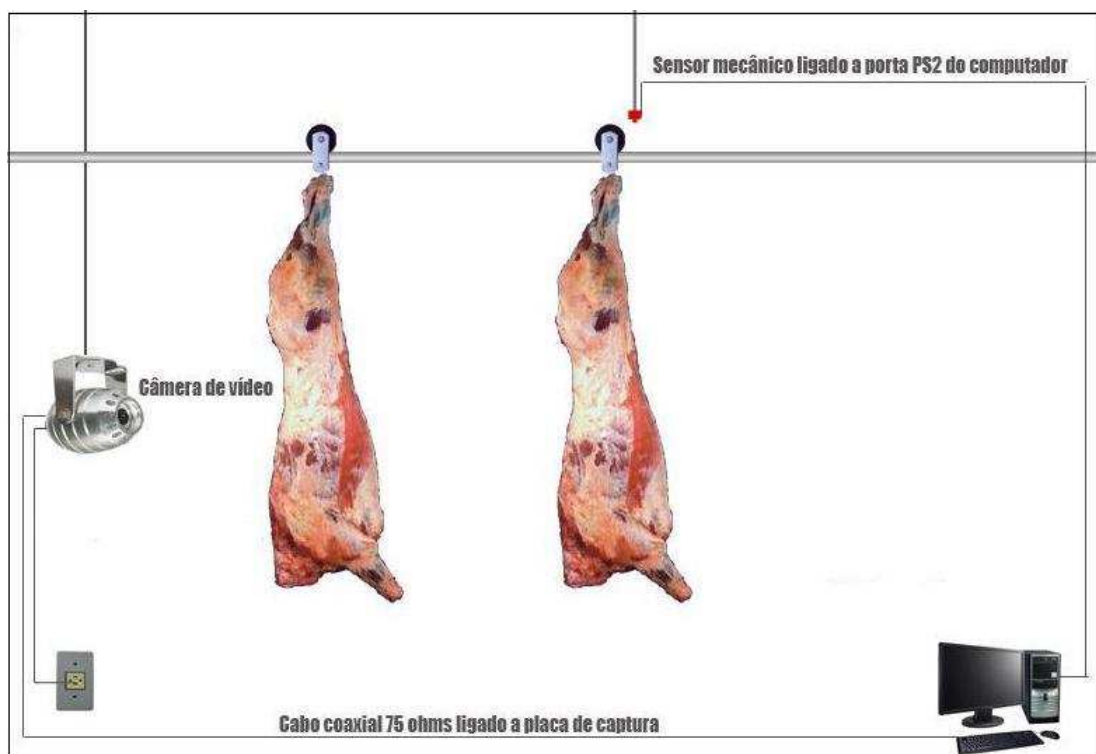


Figura 4.1: Mecanismo de aquisição *in loco* das imagens digitais

4.2 Segmentação

Para o treinamento da rede neural capaz de segmentar as áreas de gordura, foi utilizado o software MATLAB®. Conforme abordado no capítulo anterior foi prepa-

rado o conjunto de treinamento TreinaCj (Tabela 3.4) composto de 3.528 amostras. Todos os dados foram normalizados no intervalo [0,1].

Para avaliar a capacidade de segmentação da área correspondente a gordura da imagem digital da carcaça bovina foram propostas diversas topologias de redes do tipo *perceptron* de múltiplas camadas que são apresentadas na Tabela 4.1. O número mínimo de neurônios na camada intermediária, no caso 2, foi estimado com a heurística da semi-soma dos neurônios das camadas de entrada e de saída.

Tabela 4.1: Topologias de redes submetidas para a segmentação

Rede	Camada de Entrada	Camada intermediária	Camada de Saída
Net321	3	2	1
Net371	3	7	1
Net381	3	8	1
Net391	3	9	1

O processo de treinamento de cada uma das redes ocorreu em uma etapa. O conjunto de treinamento TreinaCj foi submetido a rede com o seu respectivo vetor de saída.

Como resultado do treinamento das redes, é apresentado o gráfico da rede Net371 na Figura 4.2. Esse treinamento ocorreu com 73 épocas atingindo um erro médio de 0.0045.

Pelo fato dessa rede ter obtido um desempenho mais satisfatório perante as demais topologias propostas, é apresentado na Figura 4.3, o resultado da segmentação de uma imagem realizado por essa rede. No que se refere aos resultados obtidos na segmentação não foi utilizado nenhuma métrica para analisar se o resultado estava correto ou não, pois como pretende-se automatizar o processo que é feito de forma subjetiva, o parâmetro que seria usado para comparação seria a classificação visual realizada pelo profissional, e isto poderia gerar resultados imprecisos. Dessa forma, a avaliação da qualidade da segmentação será feita na etapa de classificação do acabamento com a avaliação dos resultados finais de classificação.

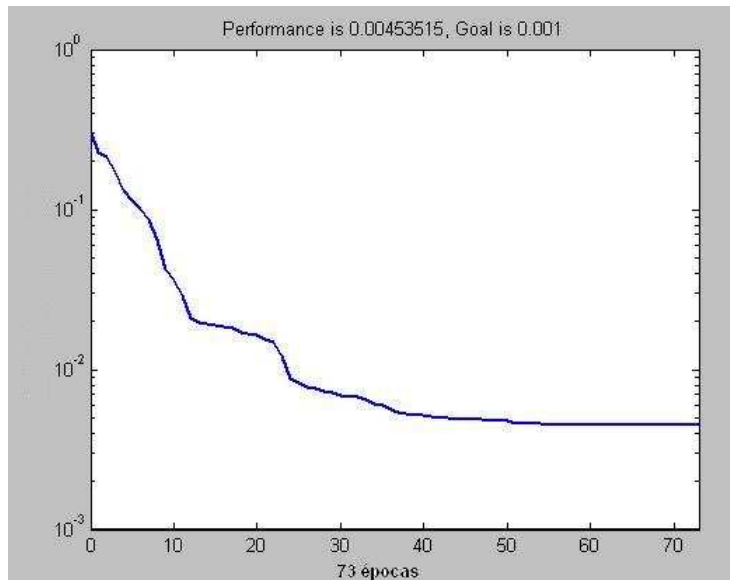


Figura 4.2: Gráfico do treinamento utilizando o conjunto T1Cj1



Figura 4.3: Imagem original e imagem resultante da segmentação

4.3 Classificação do acabamento

Partindo das imagens segmentadas durante a etapa da segmentação, é realizada a classificação do acabamento de gordura. A Figura 4.4 apresenta exemplos de imagens segmentadas pertencentes aos quatro tipos de classificação (1, 2, 3 e 4 respectivamente). Quanto ao tipo 5, gordura excessiva, devido ocorrer abate deste tipo de animal com menor incidência não foi possível obter imagem da carcaça para realização desta pesquisa. Por esta razão, não são consideradas nesta pesquisa

imagens do tipo 5.




Figura 4.4: Exemplo de segmentação conforme acabamentos de gordura

Com o objetivo de reduzir o número de entradas na rede neural utilizada para realizar a classificação do acabamento foi realizado o pré-processamento, conforme descrito na Seção 3.4.2. A Figura 4.5 e a Figura 4.6 apresentam exemplos do acabamento de gordura da imagem segmentada com a respectiva matriz de entrada gerada pelo pré processamento.



Figura 4.5: Exemplos de Tipo 1 e 2 após pré-processamento

Realizada esta redução, as imagens foram submetidas ao treinamento da rede neural, de acordo com os parâmetros discutidos na Seção 3.4.3.



Figura 4.6: Exemplos de Tipo 3 e 4 após pré-processamento

Para avaliar a capacidade de classificação do acabamento de gordura da imagem digital da carcaça bovina foram propostas diversas topologias de redes do tipo *perceptron* de múltiplas camadas. A determinação do número de neurônios ocorreu conforme abordado na Seção 3.4.4. Por meio de experimentos realizados, foram definidas algumas topologias de rede, conforme Tabela 4.2.

Tabela 4.2: Topologias de redes submetidas para classificação

Rede	Camada de Entrada	Camada intermediária	Camada de Saída
01	384	24	04
02	32	18	04
03	32	14	04

Para avaliação dos resultados obtidos pelas redes propostas, elas foram aplicadas ao conjunto de avaliação (Tabela 3.6), contendo informações referentes a 79 imagens do tipo 1, 1.126 imagens do tipo 2, 365 imagens do tipo 3 e 02 imagens do tipo 4, correspondendo a um total de 1.572 imagens. O número de classificações corretas, obtido com essas redes, está apresentado na Tabela 4.3.

Considerando que a resposta esperada da rede é uma variável booleana (sim/não) e que as redes treinadas para realizar a tarefa de classificação possuem na camada de saída a função de ativação sigmóide com o seu intervalo de saída variando en-

Tabela 4.3: Classificações corretas obtidas com as redes

Categorias	Tipo 1	Tipo2	Tipo 3	Tipo4
Imagens	79	1.126	365	02
Rede01	00	1.126	00	00
Rede02	00	1025	276	00
Rede03	60	1.011	271	00

tre 0 (zero) e 1 (um), foi utilizada como a categoria de saída da rede a categoria associada ao neurônio com maior valor de saída.

A Tabela 4.4, Tabela 4.5 e Tabela 4.6 apresentam as matrizes de confusão obtidas com as respectivas redes para a classificação do acabamento de gordura. Os valores na diagonal principal representam as quantidades de carcaças que foram classificadas corretamente pela rede neural.

Tabela 4.4: Resultado classificação - Rede 01

R/P	Tipo 1	Tipo2	Tipo 3	Tipo4	Real
1	00	79	00	00	79
2	00	1.126	00	00	1.126
3	00	365	00	00	365
4	00	02	00	00	02
Previsto	00	1.572	00	00	1.572

Tabela 4.5: Resultado classificação - Rede 02

R/P	Tipo 1	Tipo2	Tipo 3	Tipo4	Real
1	00	79	00	00	79
2	00	1.025	101	00	1.126
3	00	89	276	00	365
4	00	00	02	00	02
Previsto	00	1.193	379	00	1.572

Os índices apresentados na Tabela 3.11 podem ser facilmente generalizados para classificadores n-classes a partir de uma análise de cada classe com a abordagem um-contra-todos. A Tabela 4.7, Tabela 4.8 e Tabela 4.9 apresentam as matrizes de confusão geradas, a partir da Tabela 4.4, Tabela 4.5 e Tabela 4.6, respectivamente com a abordagem um-contra-todos.

Tabela 4.6: Resultado classificação - Rede 03

R/P	Tipo 1	Tipo2	Tipo 3	Tipo4	Real
1	60	19	00	00	79
2	10	1.011	105	00	1.126
3	00	94	271	00	365
4	00	00	02	00	02
Previsto	70	1.124	378	00	1.572

Tabela 4.7: Matriz de confusão por tipo do acabamento - Rede 01

R/P	1	-1	R/P	2	-2	R/P	3	-3	R/P	4	-4
1	00	79	2	1.126	00	3	00	365	4	00	02
-1	00	1.493	-2	446	00	-3	00	1.207	-4	00	1.570

Tabela 4.8: Matriz de confusão por tipo do acabamento - Rede 02

R/P	1	-1	R/P	2	-2	R/P	3	-3	R/P	4	-4
1	00	79	2	1.025	101	3	276	89	4	00	02
-1	00	1.493	-2	168	278	-3	103	1.104	-4	00	1.570

Tabela 4.9: Matriz de confusão por tipo do acabamento - Rede 03

R/P	1	-1	R/P	2	-2	R/P	3	-3	R/P	4	-4
1	60	19	2	1.011	115	3	271	94	4	00	02
-1	10	1.483	-2	113	333	-3	107	1.100	-4	00	1.570

A Tabela 4.10, Tabela 4.11 e Tabela 4.12 apresentam os índices de desempenho obtidos para cada tipo de acabamento de carcaça bovina e os índices médios na classificação obtidos.

Tabela 4.10: Performance obtida com a Rede 01

Categoria	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Média esperada
Sensibilidade	0.0000	1.0000	0.0000	0.0000	0.7163
Especificidade	1.0000	0.0000	1.0000	1.0000	0.2837
Acurácia	0.9497	0.7163	0.7678	0.9987	0.7403
F_1	0.0000	0.0000	0.0000	0.0000	0.0000

Face a pouca quantidade de imagens do tipo 4 existentes, optou-se por analisar o impacto sobre tais índices e retirá-las do conjunto de treinamento e avaliação e recalculando os índices. Esses novos índices estão mostrados na Tabela 4.13. Para

Tabela 4.11: Performance obtida com a Rede 02

Categoria	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Média esperada
Sensibilidade	0.0000	0.9103	0.7562	0.0000	0.8276
Especificidade	1.0000	0.6233	0.9147	1.0000	0.7104
Acurácia	0.9497	0.8289	0.8779	0.9987	0.8465
F_1	0.0000	0.7400	0.8279	0.0000	0.7222

Tabela 4.12: Performance obtida com a Rede 03

Categoria	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Média esperada
Sensibilidade	0.7595	0.8979	0.7425	0.0000	0.8537
Especificidade	0.9933	0.7466	0.9114	1.0000	0.7976
Acurácia	0.9816	0.8550	0.8721	0.9987	0.8655
F_1	0.8608	0.8153	0.8183	0.0000	0.8172

os experimentos, foi mantida a mesma configuração do número de neurônios da camada de entrada (32), da camada intermediária (12) e a função de ativação logarítma sigmóide.

Tabela 4.13: Performance obtida com a rede contendo 3 saídas

Categoria	Tipo 1	Tipo 2	Tipo 3	Média esperada
Sensibilidade	0.7595	0.9076	0.7425	0.8618
Especificidade	1.0000	0.7455	0.9137	0.7974
Acurácia	0.9879	0.8618	0.8739	0.8709
F_1	0.8633	0.8186	0.8192	0.8210

Analisando os dados obtidos na Tabela 4.12 e na Tabela 4.13, foram obtidos um índice de acurácia de 86% e 87%, respectivamente na tarefa de classificação do acabamento de gordura. Tais resultados demonstram que apesar de haver pouca quantidade de imagens do tipo 4 a rede neural conseguiu extrair conhecimento. Esses índices apresentam valores animadores mas que ainda precisam ser melhorados.

4.4 Conclusão do capítulo

Nesse capítulo foram os resultados obtidos com aplicação de redes neurais para segmentação e classificação do acabamento de gordura em carcaças bovinas. Os resultados obtidos indicam que é possível realizar a segmentação de gordura em imagens de carcaças bovinas e classificar o acabamento de gordura, através do uso de redes neurais.

Capítulo 5

Conclusões e Trabalhos Futuros

Essa pesquisa abordou o desenvolvimento e teste de uma metodologia, baseada em redes neurais artificiais, para segmentar a área correspondente a gordura de carcaças bovinas em imagens digitais e classificar o acabamento de gordura destas carcaças.

As contribuições desta dissertação são a proposição de um protótipo para aquisição de imagens digitais em uma linha de abate de bovinos, o uso de redes neurais artificiais para segmentar gordura em imagens digitais de carcaças bovinas e para a classificação automática do acabamento da gordura nestas mesmas imagens. Não se tem conhecimento da existência de sistema similar no Brasil ou no exterior. O método atualmente utilizado no Brasil para classificar o acabamento de gordura em carcaças bovinas baseia-se na observação visual dos padrões de distribuição da gordura de cobertura, realizado por um especialista humano (tipificador). Tal método, por ser baseado na análise subjetiva do tipificador, é sujeito a erros de classificação. No exterior existem tecnologias que eliminam o problema da subjetividade, como por exemplo o uso de ultra sonografia, que, apesar de apresentar bons resultados na classificação de gordura, possui um custo muito elevado, tornando o seu uso inviável no Brasil.

Os testes de avaliação do desempenho das redes neurais artificiais propostas

para a tarefa de classificação do acabamento de gordura apresentaram 86% de acurácia. Esses resultados demonstram, apesar do baixo número de amostras utilizadas, ser o uso de redes neurais viável nesta tarefa.

É importante ressaltar que a qualidade da imagem a ser tratada é de grande influência na tarefa de extrair suas informações, e que técnicas de tratamento de imagens devem ser aplicadas no sentido de melhorar o desempenho das redes neurais que se proponham a realizar esta tarefa. Um sistema de obtenção de informações de uma imagem digital engloba vários aspectos desde a captura da imagem passando pelo seu armazenamento, pré-processamento e processamento propriamente dito, e sua eficiência depende da qualidade de cada uma destas etapas. Ressalta-se também que a obtenção de melhores resultados depende de uma quantidade significativa de imagens para a sua utilização nos conjuntos de treinamento e testes das redes neurais utilizadas. Com base nas experimentações desta pesquisa há bons indícios de que a metodologia proposta é adequada.

5.1 Trabalhos futuros

As linhas a seguir podem ser exploradas como trabalhos futuros. O melhoramento do protótipo visando aumentar a qualidade das imagens durante o processo da aquisição, tornar o equipamento mais resistente ao ambiente hostil da linha de abate, em função da elevada temperatura e nível de saturação de vapor d'água no ar e melhoramento da instrumentação. Realização de treinamentos e avaliação que envolvam uma quantidade maior de imagens digitais de carcaças bovinas. Estudar técnicas de minimização de ruídos nas imagens digitais.

A metodologia ora proposta serve como parâmetro inicial para o desenvolvimento de metodologias que visam diminuir o problema da subjetividade na classificação do acabamento de gordura de carcaças bovinas.

Pode-se, ainda, realizar pesquisas no sentido de utilizar as redes neurais na tarefa de obtenção de outras informações relevantes, tais como a identificação de lesões e a conformidade do animal abatido conforme parâmetro da Portaria N.º 612/89 do MAPA.

Referências Bibliográficas

- [Almeida, 1999] Almeida, M. A. F. (1999). *Introdução ao Estudo de Redes Neurais Artificiais*. Universidade Federal de Santa Catarina, Florianópolis.
- [AMPAZIS, 2002] AMPAZIS, N.; PERANTONIS, S. J. (2002). Two highly efficient second-order algorithms for training feedforward networks. *IEEE Transactions on Neural Networks*, 13(5):1064–1074. Digital Object Identifier 10.1109/TNN.2002.1031939.
- [AMSA, 2001] AMSA (2001). *Meat Evaluation Handbook*. Savoy, IL.
- [Beef, 2008] Beef, C. (2008). *Canadian and U.S. Beef Grading Standards*. The Beef Information Centre.
- [BOHUSLAVEK, 2000] BOHUSLAVEK, Z. (2000). Estimation of europ- conformation and fatness of beef carcasses by bioelectrical impedance analysis. International Commission of Agricultural Engineering, Prague, Czech Republic.
- [BRITO et al., 2006] BRITO, G. et al. (2006). Métodos para predecir el rendimiento carnicero de una canal vacuna. *Revista INIA*, 209(8):10–12.
- [BUSBOOM, 1991] BUSBOOM, J.R.; REEVES, J. (1991). Japanese meat grading. *Beef Info*, page 5. Yakima, WA.
- [FAGGIN, 1991] FAGGIN, F. (1991). Vlsi implementation of neural networks. In *International Joint Conference on Neural Networks*, Seattle, WA.
- [FELICIO, 2005] FELICIO, P. d. (2005). Classificação e tipificação de carcaças bovinas. In *Palestra proferida no Congresso CBNA*, page 12, Goiânia - GO - Brasil. Porto Alegre - RS - Brasil, GPPD.
- [GONZALES, 2000] GONZALES, R. C.; WOODS, R. E. (2000). *Digital image processing*. Reading: Addison-Wesley Publishing Company, Inc.
- [HAGAN, 1994] HAGAN, M.T.; MENHAJ, M. B. (1994). Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6):989–993. Digital Object Identifier 10.1109/72.329697.
- [HAYKIN, 2001] HAYKIN, S. (2001). *Redes Neurais: Princípios e Prática (Tradução Paulo Martins Engel)*. Bookman, Porto Alegre, 2ª edition.

- [HEBB, 1949] HEBB, D. O. (1949). *The Organization of Behavior*. New York : John-Wiley Sons Inc.
- [HECHT-NIELSEN, 1988] HECHT-NIELSEN, R. (1988). *Applications of Counter-propagation Networks*, volume Vol. 1. Neural Networks Journal.
- [JORGE, 2007] JORGE, A. M. (2007). Sistema de avaliação da carcaças. Universidade Estadual Paulista. Faculdade de Medicina Veterinária e Zootecnia, São Paulo.
- [LIU, 1996] LIU, Y. (1996). Calibrating an industrial microwave six-port instrument using artificial neural network technique. *IEEE Transactions on Instrumentation and Measurement*, 45(2):651–656. Digital Object Identifier 10.1109/19.492804.
- [McCULLOCH, 1988a] McCULLOCH, W. S.; PITTS, W. (1988a). *How we know universals: the perception of auditory and visual forms*. MIT Press Cambridge, MA, USA.
- [McCULLOCH, 1988b] McCULLOCH, W. S.; PITTS, W. (1988b). *A logical calculus of the ideas immanent in nervous activity*. MIT Press Cambridge, MA, USA.
- [MENDES, 2009] MENDES, D. Q.; OLIVEIRA, M. F. d. S. (2009). Tutorial de redes neurais - aplicações em bioinformática. http://www.lncc.br/~labinfo/tutorialRN/frm4_backpropagation.htm. Acesso em 23/01/2009.
- [MORAIS, 2007] MORAIS, L. (2007). Gordura sob medida - exame de ultra-som para bovinos ganha adeptos na pecuária nacional. Revista Dinheiro Rural, Disponível em <http://www.terra.com.br/revistadinheiro rural/edicoes/32/artigo52649-1.htm>. Acesso em 20/02/2009.
- [MSA, 2005] MSA (2005). *Beef Carcase Grading System*. Red Meat Industry. ISBN 0 9578793 69.
- [ROSENBLATT, 1962] ROSENBLATT, F. (1962). *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Spartan Books, Washington, DC,.
- [RUMELHART, 1986] RUMELHART, D. E.; HINTON, G. E. W. R. J. (1986). *Learning Internal Representations by Error Propagation*. In : *Parallel Distributed Processing : exploration in the microstructure of cognition.*, volume 1. Cambridge : MIT Press, Cambridge, MA, USA.
- [SAINZ, 2001] SAINZ, R. D.; ARAUJO, R. C. (2001). Tipificação de carcaças de bovinos e suínos. pages 22–25, São Pedro, São Paulo. In: Anais do I Congresso Brasileiro de Ciência e Tecnologia de Carne.
- [SHEPHERD, 1994] SHEPHERD, G. M.; KOCH, C. (1994). *Introduction to synaptic circuits*. New York.

[WERBOS, 1998] WERBOS, P. J. (1998). *Backpropagation: Basics and New Development. The Handbook of Brain Theory and Neural Networks*,. MIT Press, Cambridge.

Apêndice A

Algoritmo de Levenberg-Marquardt

Enquanto o algoritmo de retropropagação do erro utiliza a descida de gradiente como método de aproximação do mínimo da função de erro, o algoritmo de Levenberg-Marquardt é uma aproximação do método de Newton. Sendo uma determinada função $V(x)$ que se deseja minimizar com respeito a uma variável x (x pode ser um vetor de variáveis), então o método de Newton seria:

$$\Delta x = -[\nabla^2 V(x)]^{-1} \nabla V(x) \quad (1)$$

onde $\nabla^2 V(x)$ é a matriz hessiana e $\nabla V(x)$ é o gradiente de $V(x)$. Se for assumido que $V(x)$ é uma soma de quadrados:

$$V(x) = \sum_{i=1}^N e_i^2(x) \quad (2)$$

pode ser mostrado que:

$$\nabla V(x) = J^T(x)e(x) \quad \text{e} \quad \nabla^2 V(x) = J^T(x)J(x) + S(x) \quad (3) \text{ e } (4)$$

onde $J(x)$ é a matriz jacobiana:

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \cdots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \cdots & \frac{\partial e_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \cdots & \frac{\partial e_N(x)}{\partial x_n} \end{bmatrix}$$

e

$$S(x) = \sum_{i=1}^N e_i(x) \nabla^2 e_i(x)$$

(5) e (6)

Para o método de Newton-Gauss é assumido que $S(x) \approx 0$ e, então, (1) fica:

$$\Delta x = [J^T(x)J(x)]^{-1}J^T(x)e(x) \quad (7)$$

Levenberg-Marquardt:

$$\Delta x = [J^T(x)J(x) + \mu I]^{-1}J^T(x)e(x) \quad (8)$$

Se a nova soma dos quadrados dos erros para $x = x + \Delta x$ for maior que a antiga, ou seja, $V(x + \Delta x) > V(x)$, então μ , que é um escalar, é multiplicado por um fator β . Caso contrário, quando $V(x + \Delta x) < V(x)$, então divide-se μ por β .