CAROLINA MELLEIRO GIMENEZ

**IDENTIFICAÇÃO DE BOVINOS ATRAVÉS DE
RECONHECIMENTO DE PADRÕES DO ESPELHO
NASAL UTILIZANDO REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada à
Faculdade de Zootecnia e
Engenharia de Alimentos da
Universidade de São Paulo,
como parte dos requisitos
para a obtenção do Título de
Mestre em Zootecnia.

Área de Concentração: Qualidade e
Produtividade Animal

Orientador: Prof. Dr. Ernane José
Xavier Costa

Pirassununga

2011

Dedico,

Ao meu pai **Eduardo** e minha mãe **Valéria** que cada um a sua maneira e com seus esforços contribuíram para o desenvolvimento de meu caráter e me proporcionaram a oportunidade de galgar os degraus já alcançados até hoje.

AGRADECIMENTOS

À Deus, poder supremo que rege minha vida, a quem devo minhas forças para galgar os degraus da evolução de meu espírito.

À minha família que me ajudou a me tornar o ser humano que sou hoje e que me ajudaram a chegar até aqui.

À minha irmã Carla pelos exemplos de garra proporcionados.

Ao meu sobrinho Guilherme pelos momentos de felicidade que você proporciona em minha vida a cada dia de sua existência.

Ao meu namorado Márcio pelo apoio, paciência e compreensão desprendidos todos os momentos estressantes, de jaulinha e de ausência, além do carinho, amor e dedicação.

Ao Prof. Dr. Ernane José Xavier Costa, por ter me dado a oportunidade de desenvolver este projeto de pesquisa, pela sua paciência e principalmente pela amizade e ótima convivência.

Aos técnicos do LAFAC, Aldo Ivan Céspedes Arce e Gustavo Voltani Von Atzingen, pela pronta ajuda em todos os momentos do desenvolvimento do projeto e pela amizade.

Ao Prof. Dr. Adriano Bruno Tech pela ajuda no projeto, por ter me dado a oportunidade de participar do PAE abrindo-me novos horizontes de conhecimentos e pela amizade.

À Prof. Dra. Ana Carolina de Souza Silva, e colega, que me ajudou nos momentos de aperto e desespero.

À Nina, minha fiel companheira de tantos anos e com quem aprendo a cada dia o significado de amor incondicional.

Aos amigos do LAFAC, pelo apoio e companheirismo.

Aos graduandos Renan Antoneli e Marcos Vieira, pelo auxílio na parte experimental.

Aos colegas Mauro Ricardo da Silva e Cleber Campos Barreira, pela ajuda prontamente desprendida.

À dona Sandra e à Juliana pela amizade.

Aos funcionários e amigos da Biblioteca da FZEA – USP.

Aos colegas da pós – graduação.

À Faculdade de Zootecnia e Engenharia de Alimentos, pela oportunidade de realização deste trabalho.

À FAPESP, pela concessão da Bolsa de Mestrado.

À todos aqueles que, de uma forma ou de outra, contribuíram para minha formação e a realização deste trabalho.

***"Nenhuma grande vitória é possível sem que tenha sido precedida de
pequenas vitórias sobre nós mesmos."***

(L. M. Leonov)

RESUMO

GIMENEZ, C.M. **Identificação de bovinos através de reconhecimento de padrões do espelho nasal utilizando redes neurais artificiais**. 2010. 114 f. Dissertação (Mestrado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2011.

As Redes Neurais Artificiais (RNA) são modelos matemáticos associados à inteligência computacional capaz de aprender e generalizar informações, podendo assim ser utilizada como um classificador de imagens. O presente trabalho objetiva analisar o espelho nasal bovino com o intuito de comprovar que é uma característica única e permanente do animal podendo assim, ser sua identificação única. O experimento foi dividido em duas etapas. Para compor o banco de dados da primeira etapa foram utilizados 51 bovinos da raça Nelore com idade média de 11 meses, dos quais foram coletadas para a formação do banco de dados dezesseis imagens de cada animal, totalizando uma base de 816 imagens. Na segunda etapa do experimento foram utilizados 16 bovinos do banco de dados inicial, escolhidos de forma aleatória, com idade média de 23 meses. Destes foram coletadas 11 imagens para verificar se os padrões do espelho nasal, com o passar dos meses, mantêm seu padrão tornando possível, assim, a identificação do animal. Os algoritmos de processamento digital de imagens foram implementados utilizando o software MATLAB®. Após o processamento das imagens, as características vetorizadas foram utilizadas para treinamento e teste de uma rede neural artificial utilizando o algoritmo MLP, implementado usando o compilador C DGW, que serviu como classificador das mesmas. Também foi utilizado o algoritmo do K vizinhos mais próximos (K-nn), para realizar os testes de classificação, usando um método estatístico. A validação do classificador foi realizada mediante análise estatística dos seus erros e acertos. O erro médio quadrático utilizado neste estudo foi menor que 1%. Os resultados apresentados pelo classificador K-nn foram maiores que o da Rede Neural Artificial, porém ambos não alcançaram acertos acima de 90%, o que é considerado adequado a um classificador. pode-se concluir que o método utilizado para extração de características não apresentou uma boa representatividade, porém ainda assim foi possível observar a tendência classificatória dos animais através das características do espelho nasal, assim como a tendência da permanência dos padrões com o envelhecimento do animal.

Palavra - Chave: processamento digital de imagens, biometria animal, rastreabilidade, zootecnia de precisão.

ABSTRACT

GIMENEZ, C.M. **Identification of bovines through recognition of images patterns of the muzzle using artificial neural nets.** 2010. 114 p. Dissertation (Mastering Course) – College of Animal Science and Food Engineering, University of São Paulo, Pirassununga, 2011.

Artificial Neural Networks (ANN) are mathematical models associated with artificial intelligence that can learn and generalize information, therefore they can be used as images classifiers. This paper aims to analyze the cattle muzzle in order to prove that it is a unique and permanent characteristic of the animal thus, being used as its unique identification. The experiment was divided into two stages. To make the database of the first phase were used 51 Nelore bovines with an average age of 11 months, from which sixteen images of each animal were collected totalling of 816 images for the database. In the second stage of the experiment 16 bovines from the initial database were used, chosen randomly, with an average age of 23 months. From those 11 images were collected to verify if the standards of the muzzle remain the same after a couple of months, so the animal can be identified. The processing digital image algorithms were implemented using MATLAB® software. After the images processing, vectorized features were used to train and test an artificial neural network using the MLP algorithm, implemented using the C compiler DGW, and was used as a classifier. We also used the algorithm of K nearest neighbors (K-nn) to perform the classification tests using a statistical method. The validation of the classifier was performed using statistical analysis of their mistakes and successes. The average square error used in this study was less than 1%. The results presented by K-nn classifier were higher than the one of Artificial Neural Network; nevertheless, both failed to reach above 90% success, which is considered suitable for a classifier. It can be concluded that the method used for feature extraction did not show a good performance, although it was possible to observe the trend of classification of animals through the characteristics of the muzzle, as well as the tendency of the permanence of the standards with the animal aging.

Key – Words: digital image processing, biometrics animal, traceability, animal precision.

LISTA DE FIGURAS

<i>Figura 1- Esquema da estrutura do neurônio (Amorin, 2011). .....</i>	<i>35</i>
<i>Figura 2 - Representação esquemática de uma sinapse (Krivkin, 2009). .....</i>	<i>36</i>
<i>Figura 3- Modelo de um neurônio artificial projetado por McCulloch e Pitts (Adaptado de Tatibana & Kaetsu, 2011). .....</i>	<i>37</i>
<i>Figura 4- Gráfico da função de ativação limiar. ....</i>	<i>38</i>
<i>Figura 5: Modelo de neurônio artificial (Haykin, 2001). ....</i>	<i>40</i>
<i>Figura 6- Representação da arquitetura de uma RNA de propagação para frente (a) e uma RNA de realimentação de Hopfield (b) (Gonçalves et al., 2005; Anônimo 2011). ....</i>	<i>41</i>
<i>Figura 7- Exemplo de contenção, posicionamento e numeração para aquisição da imagem do espelho nasal. ....</i>	<i>61</i>
<i>Figura 8- Contenção manual para posicionamento da cabeça do animal. ....</i>	<i>62</i>
<i>Figura 9- O retângulo vermelho evidencia a área de seleção do software e a imagem do interior será a imagem que sofrerá processamento com o intuito de destacar e estudar as características desejáveis do focinho. ....</i>	<i>66</i>
<i>Figura 10- Kernels de pseudo convolução usado para calcular rapidamente magnitude do gradiente aproximado. ....</i>	<i>55</i>
<i>Figura 11- Interface do MatLab® exemplificando o processo que o segundo programa realiza para geração da matriz única de ângulos para cada animal do experimento em ambas as fases do experimento. ....</i>	<i>69</i>
<i>Figura 12- Forma de associação das saídas numéricas originais e das saídas binárias. ....</i>	<i>70</i>
<i>Figura 13- Arquivo texto a ser utilizado pela rede neural cujos animais encontram-se misturados e as saídas em forma binária. ....</i>	<i>71</i>
<i>Figura 14: Representação do vetor ortogonal utilizado como saída na RNA. ..</i>	<i>72</i>
<i>Figura 15- Modelo da rede neural MLP, do tipo utilizado neste trabalho. ....</i>	<i>73</i>
<i>Figura 16- Fluxograma das etapas percorridas durante metodologia deste trabalho. ....</i>	<i>76</i>
<i>Figura 17- Diferença da luminosidade entre a primeira fase do experimento (imagem A) e a segunda fase (imagem B) para o mesmo animal. ....</i>	<i>78</i>

<i>Figura 18- Mapa direcional representando as imagens vetorizadas da Figura 18, respectivamente, demonstrando que a diferença de luminosidade não altera o resultado.....</i>	<i>78</i>
<i>Figura 19- Esquema das etapas do programa de tratamento de imagem. ....</i>	<i>79</i>
<i>Figura 20- Interface do software desenvolvido para o pré-processamento das imagens do banco de dados ilustrando a forma que de seleção da área a ser estudada.....</i>	<i>80</i>
<i>Figura 21- Interface do software mostrando a área selecionada já recortada e convertida para escala de cinza. ....</i>	<i>80</i>
<i>Figura 22- As figuras (a) e (b) estão comparando o uso da segmentação e da equalização da imagem, ambas com a utilização do filtro de Sobel, mostrando que a imagem segmentada associada a este filtro representa a imagem original com menos informações, porém sem perda da informação de borda original.</i>	<i>82</i>
<i>Figura 23- As figuras (a) e (b) estão comparando o uso da equalização e da segmentação da imagem, ambas com a utilização do filtro Log, mostrando que ainda a imagem segmentada associada ao filtro de Sobel é a que melhor representa a imagem original com menos informações, porém sem perda da informação de borda original.....</i>	<i>83</i>
<i>Figura 24- Interface do programa mostrando a imagem original do espelho nasal do animal da primeira fase do experimento selecionada e segmentada, com limiar de segmentação 7 e tamanho do bloco 16, o filtro utilizado, o mapa direcional e a identificação utilizada. ....</i>	<i>84</i>
<i>Figura 25- Interface do programa mostrando a imagem original do espelho nasal do animal da segunda fase do experimento selecionada e segmentada, com limiar de segmentação 4 e tamanho do bloco 16, o filtro utilizado, o mapa direcional e a identificação utilizada. ....</i>	<i>85</i>
<i>Figura 26- Matriz única da repetição de 1 ao 9 do animal número 1 que será utilizada para treinar a rede neural artificial associada a outros dois animais escolhidos de forma aleatória.....</i>	<i>86</i>
<i>Figura 27- Matriz única da repetição de 10 a 17 de um conjunto de animais escolhido de forma aleatória que será utilizado no teste da rede neural.....</i>	<i>86</i>
<i>Figura 28- Comportamento da queda do erro médio quadrático tendendo a 1% durante o treinamento da rede neural. ....</i>	<i>87</i>

<i>Figura 29- Média de acertos da RNA como classificador.....</i>	<i>89</i>
<i>Figura 30- Comparação da média de acerto da RNA entre o experimento1 (animais com 11 meses de idade) e o experimento 2 (testando o reconhecimento do animal aos 23 meses de idade), ambos vetores com dimensão 10.....</i>	<i>90</i>
<i>Figura 31- Comparação da média de acerto da RNA entre o experimento1 (animais com 11 meses de idade) e o experimento 2 (testando o reconhecimento do animal aos 23 meses de idade), ambos vetores com dimensão 20.....</i>	<i>90</i>
<i>Figura 32- Mapas direcionais representando o espelho nasal de bovinos das duas etapas do experimento. ....</i>	<i>92</i>
<i>Figura 33- Comparação da porcentagem de acertos na classificação realizada pela RNA e pelo K-nn para o grupo de dados do primeiro experimento com vetores com dimensão 10. ....</i>	<i>93</i>
<i>Figura 34- Comparação da porcentagem de acertos na classificação realizada pela RNA e pelo K-nn para o grupo de dados do primeiro experimento com vetores com dimensão 20. ....</i>	<i>94</i>
<i>Figura 35- Matriz das distâncias gerada pelo classificador k-nn. ....</i>	<i>94</i>
<i>Figura 36- Comparação da eficiência do classificador K-nn quando compara-se os grupos de imagens com seus pares aos 23 meses, utilizando o banco de dados de vetores com dimensão 10.....</i>	<i>96</i>
<i>Figura 37- Comparação da eficiência do classificador K-nn quando compara-se os grupos de imagens com seus pares aos 23 meses, utilizando o banco de dados de vetores com dimensão 20.....</i>	<i>96</i>

LISTA DE TABELAS

<i>Tabela 1- Tabela de associação do número de experimento ao número do brinco e da tatuagem contida em cada animal. ....</i>	<i>61</i>
<i>Tabela 2- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pela rede neural, para o grupo de dados dos vetores com dimensão 10. ....</i>	<i>88</i>
<i>Tabela 3- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pela rede neural, para o grupo de dados dos vetores com dimensão 20. ....</i>	<i>88</i>
<i>Tabela 4- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pelo K-nn para o grupo de dados dos vetores com dimensão 10. ....</i>	<i>95</i>
<i>Tabela 5- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pelo K-nn para o grupo de dados dos vetores com dimensão 20. ....</i>	<i>95</i>

LISTA DE ABREVIATURAS E SIGLAS

eq. = Equação

IA = Inteligência Artificial

RNA = Rede Neural Artificial

K-nn = K-Nearest Neighbor (K-vizinhos mais próximos)

MLP = Multi-layer perceptron

SUMÁRIO

RESUMO

ABSTRACT

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

1 INTRODUÇÃO.....	15
2 REVISÃO DA LITERATURA	19
2.1 Rastreabilidade	19
2.2. Identificação.....	25
2.2.1 Identificação Biométrica	30
2.3 Rede Neural Artificial.....	33
2.3.1 Rede Perceptron de Múltiplas Camadas (MLP)	45
2.4 Algoritmo K-Nearest Neighbor (K-nn).....	47
3 OBJETIVO GERAL	59
3.1 Objetivos Específicos	59
4 MATERIAIS E MÉTODOS.....	60
4.1 Obtenção do banco de dados.....	60
4.2 Processamento das Imagens	64
4.2.1 Etapas do Primeiro Programa	65
4.2.2 Segundo Programa	67
4.3 Preparação dos Dados para Utilização na Rede Neural Artificial.....	69
4.4 Reconhecimento de padrões	71
4.4.1 A Rede Neural Artificial.....	72

4.4.2 Método do K-nn	74
5 RESULTADOS E DISCUSSÃO	76
5.1- Manejo dos animais e Aquisição de Imagens.....	76
5.2 Programa para tratamento das imagens do focinho	78
5.2.1 Seleção	79
5.2.2 Redução de Dimensionalidade	81
5.3 Extração de Características	85
5.3 Rede Neural Artificial como Classificador	87
5.4 K-nn como Classificador	93
6 CONCLUSÃO	98
7 REFERÊNCIAS BIBLIOGRÁFICAS.....	100
8 ANEXO	113
8.1 Anexo 1- Algoritmo do Primeiro Programa de Processamento de Imagens.....	113
8.2 Anexo 2- Algoritmo do Segundo Programa de Processamento de Imagem.....	125
8.3 Anexo 3- Algoritmo do Classificador K-nn	129

1 INTRODUÇÃO

Um dos maiores desafios do Brasil atualmente é intensificar a oferta de produtos de qualidade, além de atender às demandas do mercado interno e externo no quesito “origem da carne” (FRANCO, 2002).

Produzir alimentos para o mundo requer uma responsabilidade muito grande em virtude dos riscos de contaminação e seguridade dos alimentos, dos procedimentos adotados para esta produção, das condições em que este alimento é produzido; todos estes fatores devem ser considerados para promover um padrão produtivo dentro das expectativas do mercado.

De acordo com os resultados preliminares do Instituto Brasileiro de Geografia e Estatística, o Brasil abateu durante o período de janeiro a junho de 2010, mais de 14,6 mil bovinos, totalizando mais de 3,5 milhões de toneladas em carcaças provenientes de estabelecimentos sob inspeção federal, estadual ou municipal (IBGE, 2010).

Durante o período de janeiro a setembro de 2010 foram destinadas à exportação mais de 1,36 milhões de toneladas de equivalente carcaça (ABIEC, 2010), o que corresponde a mais de 977,5 mil toneladas de carne bovina (ABIEC, 2010).

A partir destes dados, conclui-se que o volume de exportação brasileira de carne bovina e a produção brasileira para 2010 correspondem a mais de 2,3% e 13,2%, respectivamente, do consumo mundial previsto pela OECD/FAO de cerca de 68 milhões de toneladas em equivalente carcaça para o ano de 2010.

De acordo com o Agricultural Outlook 2008 - 2017 publicado pela OECD/FAO em 2008, o Brasil tem uma perspectiva de assumir cerca de 30% do volume de

exportação de carne ao final de 2017, o que ilustra o potencial produtivo do Brasil e ressalta a importância do país como produtor de alimento para o mundo.

O Agricultural Outlook 2008 - 2017 cita o potencial de crescimento produtivo do Brasil, contudo, coloca em questão a sustentabilidade envolvida neste processo de expansão.

Dada esta persistente preocupação com o esgotamento de recursos naturais, o aumento da temperatura global, a modificação de biomas, determinação de cotas de emissão de carbono, entre outros fatores, o Conselho da União Européia publicou em 2006 uma revisão das estratégias para o desenvolvimento sustentável para o bloco, onde foram reavaliadas as ameaças ainda persistentes desde a elaboração da primeira estratégia adotada em 2001.

Nas duas estratégias publicadas, a segurança alimentar foi levantada como um fator importante. Em 2001, a Comissão de Comunidades Europeias classifica as ameaças à segurança alimentar como preocupações crescentes e o Conselho da União Européia, em 2006, determina os objetivos operacionais a serem adequados para a inclusão da atividade dentro dos conceitos de sustentabilidade, que agrega a segurança alimentar como responsabilidade de saúde pública.

De acordo com o White Paper on Food Safety (2000), fabricantes de alimentação, fazendeiros e operadores de alimento têm a responsabilidade primária na segurança alimentar e este é o conceito em que se baseia a política do “From the Farm to the Fork”, onde a segurança alimentar começa na fazenda, de qualquer que seja a procedência.

Com base neste conceito, a rastreabilidade e a análise de riscos dos componentes que integram a cadeia produtiva dos alimentos são ferramentas

fundamentais para fazer uma avaliação geral da segurança adotada nos processos produtivos.

O regulamento EC 178/2002 (2002) da Comissão Europeia define rastreabilidade como a habilidade de rastrear e seguir o alimento, a alimentação animal e seus ingredientes através de todos os estágios de produção, processamento e distribuição e é caracterizada como exigência para uma política alimentar bem sucedida (WHITE PAPER ON FOOD SAFETY, 2000).

Se um alimento é para ser seguro, ele deve ser proveniente de animais saudáveis. Segundo Silva (2004), Cada segmento da produção é controlado de maneira a alcançar a otimização na totalidade do sistema, tornando-se de extrema importância que o produtor tenha controle do manejo dos animais, realize uma implementação do controle ambiental, controle das doenças, controle da nutrição, informação, preocupação em garantir o bem-estar animal, identificação e conseqüentemente a busca de uma metodologia ideal para rastrear, de maneira geral, estes eventos.

Dentro deste processo de controle de qualidade do animal pré-abate encontra-se a monitoração de diversos dados e o acompanhamento minucioso do animal desde seu nascimento até o abate (BARCELOS, 2003).

O Brasil ainda é um país suscetível a embargos de exportação, pois países que se sentem ameaçados pela competitividade de produtos como a carne brasileira recorrem, com crescente ênfase, a barreiras não-tarifárias, ditas "ambientais", "sociais" e "sanitárias".

Adotar o manejo sanitário correto, dentro das exigências do mercado consumidor, garante ao produtor a integridade do seu rebanho, além de proporcionar a colocação do produto final em mercados que podem remunerar

melhor. Para os produtos da agropecuária brasileira o valor econômico está relacionado com a sua aceitação no mercado, desta forma o investimento científico e tecnológico implica no aumento da capacidade dos produtos brasileiros de competirem no mercado externo (YASSU, 2004) e na melhoria da qualidade do produto consumido no mercado nacional.

Por todos estes motivos existe a necessidade de agregar tecnologia na produção agro-industrial brasileira através de investimento em pesquisas científicas interdisciplinares, para que o Brasil consiga adequar o sistema produtivo nacional aos mais altos padrões de qualidade de produção internacionais.

A inserção definitiva das carnes brasileiras na economia mundial e seu fortalecimento no mercado interno dependem da assimilação destes conceitos pelos diferentes elos da cadeia produtiva e da agilidade em atender essas novas demandas.

2 REVISÃO DA LITERATURA

2.1 Rastreabilidade

Há várias definições para o termo rastreabilidade ou fonte de verificação, oriundo do inglês “Traceability”, entretanto o mais genérico e utilizado é o acompanhamento do trajeto de um produto - sejam objetos, animais, rações, alimentos de origem animal ou vegetal, mercadorias ou qualquer substância que poderá ser incorporada ao produto final - desde sua origem até o seu consumidor final.

No campo da zootecnia este conceito pode ser traduzido no acompanhamento desde o nascimento de um animal até seu corte que irá compor a refeição de um consumidor, sendo possível, assim, conhecer e voltar à origem de qualquer corte cárneo a venda no mercado alimentar. Sendo possível acompanhar toda a vida de um animal de produção alimentícia independente de sua finalidade zootécnica, ou seja, é possível garantir a qualidade e a seguridade do alimento ao consumidor, independente de ser um corte de carne, um litro de leite, ovos, dentre outros produtos derivados dos animais (SILVA, 2004; NÄÄS, 2001; FAO, 2007; RIJSWIJK et al., 2008).

Para Faveret Filho e Paula (1997), a rastreabilidade é base para a difusão da preocupação com a qualidade ao longo da cadeia produtiva.

A rastreabilidade possibilita traçar um histórico do produto dependendo da complexidade dos objetivos almejados, pois, como certifica qualidade, possui dados relevantes para que sejam identificados para o produtor, para a indústria, para o consumidor e organizações como data de nascimento, sexo, raça, origem,

informações sobre manejos sanitários, reprodutivos e alimentares, métodos de bem estar animal entre outras (MAYRINK, 2002).

As normativas internacionais ISO 9000 definem rastreabilidade como sendo a aptidão para encontrar a história, a utilização de um artigo ou de uma atividade, ou de artigos ou atividades semelhantes, ou meios de identificação registrados. Conforme a norma ISO 8402, rastreabilidade é a capacidade de traçar o histórico, a aplicação ou a localização de um item por meio de informações previamente registradas. Rezende & Lopes (2004) a descrevem como parte da qualidade total e base de todos os programas de certificação, sendo o produtor o primeiro envolvido e o que demanda a adequada identificação dos animais, fazendo com que toda a cadeia da carne mantenha documentação que comprove a sua aplicação.

De acordo com Silva (2002), pode-se definir rastreabilidade como a correspondência única entre uma referência e um produto, identificado por lote ou individualmente.

Com a implantação do sistema de rastreabilidade haverá um aumento na qualidade das informações e do produto final, pois este permite seguir os dados de diferentes tipos e elos da cadeia possibilitando a localização dos produtos desde sua origem até o fim da cadeia de comercialização. Sendo assim, possível através dos registros, identificação e transmissão de informações, rotulagem, impressões, documentos de acompanhamento inseridos, pois ele contém elementos de identificação de animais e localidades, um banco de dados central e um processo de verificação, independente do sistema ser informatizado ou não (DULLEY & TOLEDO, 2002; EAN BRASIL, 2005; SILVA & NÄÄS, 2006).

Desta forma pode-se definir um sistema de rastreabilidade como sendo um conjunto de medidas que possibilitam o controle e monitoramento sistemático de

todas as entradas e saídas das unidades produtoras, processadoras e distribuidoras, garantindo assim a origem, qualidade e segurança alimentar do produto final (SILVA, 2010).

Como descrito por Mello (2003) e Vinholis & Azevedo (2002) este sistema utiliza elementos que facilitam o rastreamento do animal ou produto, tais como, formas que identifiquem os animais e sua localidade, um banco de dados central e um processo para verificação, garantindo assim um histórico do produto. Contudo a complexidade do histórico do produto rastreado depende dos objetivos aos quais se destina e que podem sofrer influências do ambiente externo em que a empresa se insere e das estratégias traçadas pela mesma (VINHOLIS & AZEVEDO, 2002).

Segundo Mendes (2006) e Prá Junior (2006) a rastreabilidade não é uma ferramenta que por si só garante a qualidade dos alimentos, entretanto auxilia na maior visibilidade das boas práticas aplicadas ao longo da cadeia produtiva dos alimentos comercializados.

Mundialmente, desde 1970, há uma crescente movimentação dos consumidores pela procura de alimentos saudáveis, sustentáveis, de melhor qualidade, de boa procedência, produzido de maneira socialmente correta e no caso dos cárneos também há preocupação quanto ao bem-estar do animal e quanto à sua forma de produção, buscando-se desta forma a garantia da segurança alimentar de seus familiares. Assim, os produtores e fabricantes, de todo o mundo, foram obrigados a se adequar às normas de boas práticas de produção e fabricação para conseguir suprir esta demanda, cada vez mais alta, de consumidores cada vez mais exigentes (NÄÄS et al. 2001; RIJSWIJK et al. 2008).

Segundo estudo recente da FAO, Organização das Nações Unidas para Agricultura e Alimentação, vem se acentuando nos últimos anos a contaminação de

seres humanos por alimentos de origem animal, como a gripe aviária, a BSE (doença da vaca louca), a aftosa, entre tantas outras. Segundo Silva & Nääs (2006), estes problemas de segurança alimentar levaram à busca de estratégias de rastreabilidade e criação de regulamentos para garantir a qualidade dos produtos no mercado europeu.

Diante deste cenário, os organismos que cuidam dos interesses dos consumidores passaram a exigir dos fornecedores, garantias quanto à origem e a qualidade nos processos de produção de alimentos e segundo Rijswijk et al. (2008), várias empresas do ramo alimentício europeu estão se adequando à exigência do consumidor e consideram a rastreabilidade como uma etapa inicial à segurança alimentar.

Rodrigues e Nantes (2010) ressaltam que os procedimentos de rastreabilidade, além de constituírem um instrumento essencial de gestão de risco e permanente retroalimentação de processos produtivos de sistemas de qualidade são imprescindíveis a objetivos como:

- Monitoramento e controle de sistemas de avaliação de conformidade;
- Garantia da oferta de alimentos inócuos a saúde humana;
- Prevenção da propagação de pontos críticos de contaminação.

A Conferência da Organização Mundial da Saúde Animal (OIE) em março de 2009, mostrou que a melhoria da produção animal mundial, a diminuição de riscos de doenças garantindo a seguridade do alimento que o consumidor encontra nas prateleiras de supermercados são vantagens proporcionadas pela identificação e rastreabilidade na cadeia produtiva e que proporcionam maior confiança ao consumidor final.

Segundo Lirani (2001), a ausência de um programa de rastreabilidade impede a devida responsabilização e a tomada de ações preditivas, preventivas e corretivas, nos casos de contaminação alimentar, sendo os programas de rastreabilidade as únicas ferramentas eficazes para a perfeita identificação da fonte causadora do problema, já que se observa que o tempo entre a ocorrência do problema e a identificação da fonte causadora deve ser a mínima possível, visto que quanto maior for este período maior serão as proporções da problemática tanto no que se refere à segurança alimentar quanto às questões financeiras dentro da cadeia produtiva.

Diante das necessidades internas e as exigências do mercado externo frente a esta necessidade de identificar, rastrear e certificar produtos agropecuários o governo brasileiro através do Ministério da Agricultura, Pecuária e Abastecimento criou em Janeiro de 2002 o SISBOV - Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina, que tem como objetivo identificar, registrar e monitorar todos os bovinos e bubalinos nascidos no Brasil ou importados (LIMA, 2007).

Segundo Machado & Nantes (2005) o processo de rastreabilidade no Brasil ainda encontra-se no início, contudo cabe ao governo, à indústria e ao varejo agirem em conjunto através de ações coordenadas para que a rastreabilidade brasileira tenha a força desejada e o reconhecimento de sua devida importância.

Lirani (2001); Rocha (2001) e Moura (2010) destacam a princípio, que não se pretende com a rastreabilidade criar uma diferenciação para se conseguir uma melhor remuneração dos produtos, mas sim atender a uma exigência do mercado de exportação. Contudo, os rebanhos cadastrados em programas de rastreabilidade serão diferenciados dos demais, o que deverá gerar maior procura pelo produto e conseqüentemente maior valorização, podendo ainda chegar a ser, em um futuro

próximo, os únicos a conseguir compradores tanto no mercado interno quanto, principalmente, no mercado internacional.

Segundo Ries (2002), atualmente a rastreabilidade tem sido encarada como um fator de custo a mais para os pecuaristas. Entretanto, segundo Schiefer et al. (2000); Rezende & Lopes (2004); Machado & Nantes (2000), isso não é propriamente correto e existem dois pontos a serem considerados em relação aos valores despendidos na rastreabilidade. Primeiro seria que a necessidade de fazer rastreabilidade decorre por uma demanda de mercado, ou seja, para poder vender a carne, é necessário fazer o rastreamento dos animais desde o nascimento até o abate, o que torna os valores despendidos um investimento para que o pecuarista possa se manter no mercado ou até mesmo abrir novos mercados. O segundo seria os dados e informações necessárias à rastreabilidade estando, portanto, relacionados com a gestão e administração da atividade da pecuária propriamente dita.

Assim sendo, independente desta nova demanda de mercado gerada pela rastreabilidade o produtor já necessita coletar, processar e controlar esses dados zootécnicos a fim de garantir o sucesso e a rentabilidade em sua atividade de bovinocultura, portanto esse custo já é, ou deveria ser, existente nas atividades diárias de tomada de decisão da bovinocultura.

Concluindo assim, que os valores despendidos para a adaptação dos pecuaristas a essa realidade da rastreabilidade bovina nada mais é que na realidade custos marginais.

A intenção em praticar-se a rastreabilidade é pela necessidade de gerenciamento, visando o controle de riscos, a garantia da qualidade dos produtos gerados e poder, a qualquer momento, a partir de um determinado histórico, adotar

ações preventivas ou corretivas durante algum processo corrente, como ocorreu quando se deu a doença da vaca louca em 1997 (MOTA, 2008).

O governo brasileiro buscando ampliar o número de compradores de carne bovina, principalmente do mercado externo, além de iniciativa para utilizar e divulgar dados de animais no mercado brasileiro o MAPA impôs aos pecuaristas o ano de 2007 como data limite para que todo o rebanho bovino brasileiro estivesse devidamente identificado e rastreado, contudo esta meta não foi atingida estando o processo ainda hoje em andamento. Diante deste fato evidencia-se uma falha da promoção adequada do programa de rastreabilidade brasileira pelo seu maior interessado que é o próprio governo e este fato se deve a falta de estrutura principalmente no que tange os recursos humanos para fiscalização (MACHADO & NANTES, 2004; ABCHIT, 2009).

Perante este cenário a abertura de novos mercados, assim como, a manutenção do já existente, dependerá diretamente da adequação do Brasil às normas impostas pelo mercado internacional, principalmente a União Européia que apresenta um grande poder de compra por ser um bloco de países de grande importância mundial. Devido a este fato os países que desejam exportar sua carne a este bloco econômico devem atender às exigências impostas pela Comunidade Européia (STÄRK et al. 1998).

2.2. Identificação

A identificação segura dos animais é a base para a maior parte das funções do sistema de manejo que resultam em progressos zootécnicos, controle e

economia da produção (LOPES, 1997; PIRES, 2002; SILVA, 2004). Entretanto, freqüentemente é apontada como uma problemática de considerável importância dentro de todos os sistemas de produção (SILVA, 2004).

A identificação animal objetiva, principalmente, possibilitar e facilitar a coleta e reunião de dados de um indivíduo, do meio em que se insere, além de tudo mais que tenha sido nele realizado (KORTHALS et al. 1992; FERREIRA & MEIRELLES, 2002; SILVA, 2004), sendo assim parte principal de todo o sistema, devido ao fato de ser o pré-requisito para todos os outros controles e procedimentos.

Devido a este fato, a identificação deve ser única, inequívoca, inviolável e permanente, ou seja, ela deve estar presente no rebanho uma única vez, não correr risco de perda ou estrago de qualquer natureza, estar sempre legível e acompanhar o animal em todo o seu ciclo dentro da propriedade rural e posteriormente na produção (RESENDE & LOPES, 2002, ROCHA & LOPES, 2002).

Segundo Clark (1996); Ajimastro Jr. & Paz (1998) tecnologias de identificação de origem do produto representam uma dessas facilidades de acesso a informações úteis e necessárias aos trabalhos de rastreabilidade. É exatamente por isso que se torna indispensável à identificação prévia dos processos produtivos. Estes processos produtivos devem estar especificados, formalmente descritos e homologados, mediante protocolos de normas técnicas.

Como descrito por Silva et al. (2002a), a identificação também é uma exigência do consumidor final, pois estes desejam ter informações quanto às características do produto quanto ao controle sanitário, o ambiental, a produção socialmente correta, o bem-estar animal, dentre outros pontos.

O fato da rastreabilidade requerer um método para identificação é indispensável e indiscutível com base nas discussões anteriores e para isto, existem

dois caminhos para aplicar os conceitos de rastreabilidade em rebanhos: manual e eletrônico. A rastreabilidade manual vincula-se ao registro manual dos dados e eventos ocorridos ao longo da vida do animal e podendo vincular-se também à data do abate e eventualmente alcançar a distribuição da cadeia alimentar, contudo este tipo de registro de dados não é totalmente seguro e confiável, pois pode gerar erros ou mesmo fraudes. A rastreabilidade eletrônica utiliza dispositivos externos, tais como brincos ou colares, e internos como microchips (NÄÄS, 2001, MACHADO et al. 2001).

A Identificação Animal Individual (IAID) até o abate pode ser conseguida através de sistemas tradicionais que resultam em uma identificação prática de cada animal do rebanho como brincos, colares, tatuagens, marcações a ferro quente (a fogo ou elétrico) nos chifres, pele e orelha, ou ainda utilizar uma tecnologia mais avançada como os implantes de microchip sob a pele, imagem da retina, perfil genético e imunológico.

Entretanto, as identificações tradicionais comumente apresentam algumas problemáticas como dificuldade de visualização à distância, necessidade de contenção do animal, problemas na leitura devido à abrasão dos caracteres, sujeiras e erros de transcrição e a possibilidade de duplicação de número, isto é, dois animais com a mesma identificação (JARDIM, 1973; BLANCOU, 2001; EBERT, 2006). Além da ocorrência de perdas de brincos ou mesmo a perda da identificação no abate quando cabeça, chifre ou pele são removidos, exceto quando sistemas de identificação posteriores são empregados.

Assim, com tais perdas geradas, apenas análise genética e pesquisa de anticorpos podem ser usadas para identificar cortes de carne de um animal específico. Com a identificação eletrônica, elimina-se essa preocupação, pois existe

maior segurança nas informações. A IAID pode ser mantida ao longo de abate pelo uso de ordem na seqüência de abate e marcação de carcaças e seu acompanhamento em carnes nos postos de venda é feito através da utilização de códigos de barras (PACHECO, 1995; LOPES, 1997; SMITH et al., 2000; MACHADO et al., 2001, LARA et al., 2003).

O governo brasileiro, visando estabelecer normas para a produção de carne bovina com garantia de origem e qualidade, tendo em vista a segurança sanitária e o incremento das exportações de carne, instituiu o Sistema Nacional de Rastreabilidade, o Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina (SISBOV) criado pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) na Instrução Normativa nº 1, em 10/01/2002, sendo alterado para Serviço de Rastreabilidade da Cadeia Produtiva de Bovinos e Bubalinos (SISBOV), publicado na Instrução Normativa nº 17, em 14/07/2006, tendo a Normativa nº 24, em 30/04/2008, como emenda.

A Instrução Normativa nº 21, em 2 de abril de 2004, especifica que os animais devem ser duplamente identificados, podendo ser usadas combinações de brincos, marcações a fogo, tatuagens e dispositivos eletrônicos.

Segundo Machado et al. (2001), qualquer método de identificação deve atender a um mínimo de requisitos:

- Único: cada número deve ser encontrado apenas uma vez no rebanho;
- Permanente: não deve correr riscos de perda;
- Insubstituível: ao receber uma identificação ao nascimento ou na aquisição do animal, esse deve permanecer com o mesmo número até o momento do abate;
- Positiva: a identificação dos animais não pode gerar dúvidas

Contudo, a rastreabilidade não é baseada somente na identificação animal, num “micro chip” ou brinco de orelha, o sistema exige o processo completo, amarrado por um banco nacional de dados, ao acessar um determinado numero todos os dados a respeito do animal enumerado são obtidos automaticamente: produção, progênie, controle sanitário etc. (FUNDEPEC,1999).

Os brincos de plástico, marcação comumente encontrada nos rebanhos espalhados por todo o país, surgiram como uma alternativa de identificação de baixo custo, além de serem bastante práticos e indolores. Porém, segundo Ferreira e Meirelles (2001), no caso dos brincos, têm ocorrido uma perda que varia de acordo com a raça e tipo de ambiente entre 3 e 15%, anualmente, o que corrobora com as pesquisas de Machado et al. (2001) que cita perdas de 5% ao ano.

Estes percentuais podem ser considerados altos por alguns pecuaristas e insignificantes por outros, mas o principal problema que tais perdas propiciam e que devem ser levadas em consideração são os erros no processo de rastreabilidade, além de perdas econômicas, inegáveis, para o produtor rural. Geralmente, os casos mais comuns de perdas de brincos se devem ao enrosco em cercas e arbustos quando o animal tenta se coçar ou mesmo na disputa por espaço, por comida ou por fêmea (MACHADO et al., 2001).

A marcação a ferro quente é a forma mais tradicional atualmente adotada pelos produtores; porém, esse sistema, além de danificar o couro permanentemente, desvalorizando seu preço no momento da comercialização, constitui-se num método doloroso para o animal (MACHADO et al., 2001).

Outro método de identificação bastante utilizado no Brasil é a identificação eletrônica. Esta vem de forma a promover a qualidade, economia da produção

animal e futuramente obter e organizar todos os dados do produto e de toda cadeia produtiva (SILVA & NÄÄS, 2006).

Estes identificadores eliminam erros devido à segurança nas informações, pois estas são transferidas diretamente do chip para o terminal computacional (PACHECO, 1995). Outro aspecto positivo desta identificação, segundo Pandorfi et al. (2005) se deve ao fato que as expectativas com a utilização desses microchips baseiam-se na grande quantidade de informações comportamentais que podem se obter no monitoramento digital diário, auxiliado por um sistema informatizado.

Contudo Silva (2004) ressalta a grande dificuldade existente nas propriedades rurais em se coletar tais informações, devido o difícil acesso aos locais de criação dos animais, que se agrava ainda mais em certas regiões do país, como a região do Pantanal sul mato grossense. Dificultando desta forma a utilização de equipamentos de informática, como notebooks, no auxílio da coleta de informações.

Na busca de alternativas de identificação que mantenham o conceito básico de unicidade, permanência, insubstituibilidade e da não geração de dúvidas, além da tentativa de reduzir o custo com perdas, como ocorre com os brincos, os métodos biométricos, tais como a exploração retinal, a cópia do espelho nasal, e o DNA, se tornam uma alternativa de grande importância.

2.2.1 Identificação Biométrica

Biometria é a ciência que estuda a medida dos seres vivos, ou seja, é a identificação de um indivíduo através de suas características físicas e comportamentais (FERREIRA, 2002).

A natureza desenvolveu diversos mecanismos biométricos para o reconhecimento entre os seres vivos, por meios sensoriais combinados com registros em memória, os quais são considerados pela ciência como habilidades de altíssima sofisticação, que servem como parâmetro de referência de crescentes pesquisas e desenvolvimento de cunho tecnológico na área de biometria (THERRIEN & TRONCO, 2004).

Esta tecnologia é considerada a forma mais segura de identificação e autenticação de pessoas.

Os esforços para uma identificação precisa em animais, já estão atingindo níveis tecnológicos bem mais seguros, a exemplo dos estudos realizados em seres humanos (MARTIN, 2005).

Shadduck e Golden (2002) definiram um identificador biométrico para animais como sendo mensurável, robusto e capaz de distinguir características físicas que podem ser usadas para identificar ou verificar a identidade de um animal.

Os meios de identificação de animais através de marcadores biométricos incluem DNA, leitura da íris, a imagem da retina, impressão do focinho (Smith et al., 2005) e, mais recentemente, reconhecimento facial (Corkery et al., 2007).

A identificação por características biológicas está amplamente em desenvolvimento, como por exemplo, ocorre na Universidade de Cambridge – Reino Unido, onde o reconhecimento de padrões da íris é uma realidade, assim como na University College Dublin – Irlanda; Kitasato University – Japão e University of Minnesota – Estados Unidos que também realizam pesquisas biométricas para o reconhecimento de padrões do espelho nasal bovino como forma de identificação individual do animal.

A identificação pelo DNA é possível devido ao fato de cada animal diferir de seus congêneres em uma série de planos biológicos. No plano estrutural mais básico, cada exemplar é portador de uma combinação única de ácido desoxirribonucléico (DNA), cuja transcrição gera variações nas proteínas, o que, por sua vez, origina a diversidade individual que é expressa fisicamente. As técnicas de identificação biológica constituem, assim, uma alternativa para o rastreamento de animais vivos e de produtos de origem animal (CUNNINGHAM & MEGHEN, 2001).

Os neozelandeses e os sul-africanos aprofundaram-se na busca de um método de rastreabilidade à prova de fraudes, capaz de garantir a maior confiança possível no comprador da carne proveniente dos seus rebanhos substituindo as formas tradicionais de marcação passíveis de fraude pelo o código genético de cada animal, impossíveis de serem adulterados, adotando assim este método de identificação oficialmente nestes países (FORTES e JOSÉ, 2002).

Os australianos também já adotaram o sistema de identificação pelo DNA, preocupados em garantir 100% de acurácia ao resultado de identificação de origem (FORTES e JOSÉ, 2002).

Bezerra (2001) cita a técnica de identificação através da utilização do padrão vascular da retina. Esse padrão, assim como a impressão digital, é único para cada animal, está presente desde o nascimento e não muda com o avanço da idade. O aparelho de leitura registra simultaneamente as imagens das veias, hora, data e coordenadas geográficas de localização, que podem ser transferidas e armazenadas em bancos de dados. Entretanto, a grande limitação é o alto custo, além do fato de ainda não ser encontrado facilmente no Brasil.

Segundo Ebert (2006), o princípio básico do método para reconhecimento de padrões do espelho nasal bovino é a constatação que nenhum outro animal tem um

padrão idêntico a outro animal da mesma raça, pois observando-se a área entre a borda superior do lábio e a borda superior da narina será visto uma série de cumes e sulcos, que provavelmente através de testes, estes padrões serão considerados diferentes entre os animais.

Mulvihill (2008) descreve que as linhas e os sulcos no focinho dos animais são únicos e um identificador biométrico bem estabelecido do gado, vem sendo utilizado para o controle da qualidade no Japão.

Minagawa et al. (2002) verificaram que os testes de padrões do focinho de animais jovens e adultos são muito similares, em um teste do padrão do sulco situado na parte mais inferior do focinho.

O uso de método biométrico pela imagem do espelho nasal para a identificação de animais não é invasivo, o que seria além de eficaz um método que poderia prevenir o estresse sofrido durante e após o manejo, garantindo desta forma a manutenção do bem-estar do mesmo (BARRY et al. 2007).

2.3 Rede Neural Artificial

A Rede Neural Artificial (RNA) é uma técnica de inteligência computacional que utiliza um modelo matemático inspirado na estrutura neural do cérebro humano que é considerado um sistema de processamento de informações altamente complexo e não linear capaz de realizar cálculos em paralelo.

Segundo Dandolini (1997) a Inteligência Artificial (IA) é um termo que abrange muitas definições, contudo uma definição bastante adequada é a IA como a área das ciências da computação que visa o projeto de sistemas inteligentes, ou seja,

sistemas que tentam emular algum tipo de inteligência, semelhante à de um ser humano, em termos de processos computacionais.

Segundo Haykin (2001), pode-se definir Rede Neural vista como uma máquina adaptativa:

Um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos: (1) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; (2) forças de conexão entre neurônios (os pesos sinápticos) são utilizadas para armazenar o conhecimento adquirido.

A estrutura cerebral e organização dos neurônios proporcionam ao ser humano a capacidade de realizar tarefas complexas como o reconhecimento de padrões, percepção e controle motor, aprendizagem, raciocínio, comunicação e atuação em ambientes complexos de forma tão rápida que supera a computação mais rápida existente (NILSSON, 1998; HAYING, 2001; GOUVEIA, 2008). Isto se deve ao fato de uma grande rede neural artificial poder ter centenas ou milhares de unidades de processamento, enquanto o processamento local de informação no cérebro efetua-se em cerca de 10^{11} unidades (os neurônios).

O sistema nervoso é formado por um conjunto extremamente complexo de células que são os neurônios, que apresentam essencial função na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central e pelos axônios que são longos terminais de saída (Figura 1).

Figura 1- Esquema da estrutura do neurônio (Amorin, 2011).

O neurônio é uma célula com núcleo e corpo (soma) onde reações químicas e elétricas representam o processamento de informação. A saída da informação do soma é realizada por impulsos elétricos que se propagam através do axônio. No final do axônio existem inúmeras ramificações que distribuem a informação para outros neurônios vizinhos. A ligação com outros neurônios é realizada através de sinapses que estão conectadas a um dendrito do neurônio receptor. A sinapse (Figura 2) dispara uma substância química quando excitada pelo impulso do axônio. A substância se transmite entre sinapse e dendrite realizando a conexão entre dois neurônios vizinhos. Conforme as excitações ou inibições que células vizinhas transmitem para a célula em consideração ela processa a informação novamente e a transmite via seu axônio (KOVÁCS, 1996; CORTEZ & NEVES, 2000).

As redes neurais artificiais apresentam um modelo computacional que segue o modelo biológico, ou seja, são formadas por neurônios e conexões entre eles. O

neurônio é uma unidade de processamento e representa uma região onde as informações são processadas, sendo a estrutura de fundamental importância para a operação da RNA (HAYKIN, 2001).

Figura 2 - Representação esquemática de uma sinapse (Krivkin, 2009).

Em 1940, McCulloch e Pitts, propuseram um modelo simplificado do neurônio artificial (Figura 3), que compreendia:

- Estímulo de entrada: componentes representadas pelo vetor X .
- Ligações sinápticas: componentes representadas pelo vetor W . O conjunto destas ligações compõe o conjunto de sinapses e cada

ligação possui um valor (peso), que representa a sua força, ou seja, os estímulos de entrada são multiplicados pelos respectivos pesos de cada ligação, podendo gerar um sinal tanto positivo (excitatório) quanto negativo (inibitório).

- **Combinador linear:** Executa o somatório dos sinais produzidos pelo produto entre os pesos sinápticos e as entradas fornecidas ao neurônio. Em outras palavras, é o integrador dos sinais que chegam ao neurônio.
- **Saída:** componentes representadas pelo vetor y , produzida segundo o valor de ativação alcançados pelos neurônios.

Figura 3- Modelo de um neurônio artificial projetado por McCulloch e Pitts (Adaptado de Tatibana & Kaetsu, 2011).

Neste modelo, os pesos sinápticos eram fixos e a saída obtida pela aplicação de uma função de limiar, que modela a característica “tudo-ou-nada”, ou seja, binária, deste neurônio que é expressa pela eq. (1):

$$f(v) = \begin{cases} 1, & \text{se } v \geq 0; \\ 0, & \text{se } v < 0; \end{cases} \quad (1)$$

Nos neurônios construídos com essa função, a saída y será igual a 0 (zero), caso o valor de ativação v (composto pelo combinados lineares e pelo bias (eq. (2)) seja negativo e 1(um) nos casos em que o valor de ativação seja positivo, gerando o gráfico de degraus (Figura 4).

$$v_j = \sum_{i=1}^m w_{ji}x_i + b \quad (2)$$

Onde;

v_j : valor de ativação do neurônio k ;

w_{ji} : pesos das conexões do neurônio k ;

x_i : valor de cada um dos m estímulos que chegam ao neurônio k ;

b : valor do bias que será somado ao valor do combinador linear para compor o valor de ativação.

Figura 4- Gráfico da função de ativação limiar.

Além da função de ativação limiar existem outros tipos de ativação, como a função sigmóide, função sinal e função tangente hiperbólica.

McCulloch e Pitts consideraram a resposta neural como sendo equivalente a uma proposição (se A então B) adequada para estimular o neurônio. Sendo assim, eles estudaram o comportamento de diversas redes neurais utilizando a notação simbólica da lógica das proposições. A característica binária dos neurônios era suficiente para garantir que a atividade de qualquer neurônio possa ser expressa sob a ótica da lógica das proposições (BARRETO, 2002).

Após o modelo de McCulloch e Pitts, surgiram outras abordagens, dando flexibilidade aos pesos sinápticos e maior capacidade à Rede Neural através dos neurônios com funções de ativação não-lineares, das arquiteturas com mais de uma camada e algoritmos apropriados para alterar os pesos.

O peso sinápticos, são as conexões entre os neurônios de entrada e os neurônios da camada do meio, é responsável pelo armazenamento das informações, sendo também o responsável pela definição do efeito que a saída de um neurônio exerce sobre a entrada do neurônio seguinte e pela determinação de toda a manipulação dos valores da RNA (ALVES, 2001).

O elemento computacional básico empregado na maioria das RNAs é um integrador. Trata-se de um elemento processador de informações que é fundamental para a operação das RNAs. Os três elementos básicos do neurônio artificial genérico (HAYKIN, 2001) são:

- As sinapses, caracterizadas pelos seus pesos associados;
- A junção somadora;
- A função de ativação.

Além desses três elementos básicos, o neurônio pode ainda apresentar um bias (Figura 5) que tem o efeito de aumentar ou diminuir a entrada líquida da função

de ativação (HAYKIN, 2001). O termo bias age como um peso extra nas conexões das unidades cuja entrada é sempre 1(um) (FAUSETT, 1994).

Figura 5: Modelo de neurônio artificial (Haykin, 2001).

O potencial e flexibilidade do cálculo baseado em redes neurais vêm da criação de conjuntos de neurônios que estão interligados entre si. Esse paralelismo de elementos com processamento local cria a “inteligência” global da rede (RAUBER, 2006).

Uma categorização fundamental da topologia dos neurônios pode ser feita em relação ao método de propagação da informação recebida. Pode-se distinguir entre redes de propagação para frente (feedforward) e redes realimentadas (recurrent), como demonstrado na Figura 6.

No caso das redes de propagação para frente o fluxo de informação é unidirecional. Os neurônios que recebem a informação simultaneamente agrupam-se em camadas. Camadas que não estão ligadas às entradas e nem às saídas da rede chamam-se camadas escondidas. Exemplos para esse tipo de rede são o perceptron (ROSENBLATT, 1958), o perceptron multicamada (RUMELHART et al., 1986) e o ADALINE (WIDROW & HOFF, 1960). Uma rede que adicionalmente tem uma relação topológica de vizinhança entre os neurônios é o mapa auto-organizável de Kohonen (KOHONEN, 1972; KOHONEN, 1990).

Redes realimentadas têm ligações entre os neurônios sem restrições. Ao contrário das redes sem realimentação, o comportamento dinâmico desempenha o papel fundamental nesse modelo. Em alguns casos os valores de ativação da rede passam por um processo de relaxação até chegarem a um estado estável (HOPFIELD, 1982).

Figura 6- Representação da arquitetura de uma RNA de propagação para frente (a) e uma RNA de realimentação de Hopfield (b) (Gonçalves et al., 2005; Anônimo 2011).

A rede neural deve ter a capacidade de generalização, ou seja, ela deve ser capaz não apenas de classificar as entradas para as quais ela recebe treinamento, mas também de generalizar e classificar entradas que não tenham sido

apresentadas. Isto é possível graças a um processo de aprendizagem ao qual a rede é submetida. Esta propriedade permite que a rede encontre respostas corretas mesmo quando os dados disponíveis para as entradas encontram-se incompletos ou danificados. O processo acima descrito faz parte das etapas de modelagem da rede que envolve 3 fases básicas, sendo elas:

- 1) Treinamento e Aprendizado: obtido pelo ambiente gerador dos dados.
- 2) Associação: que é o reconhecimento de padrões distintos.
- 3) Generalização: relacionado a capacidade da rede de reconhecer com sucesso o ambiente que origina os dados e não propriamente os dados utilizados no treinamento.

A modelagem inicia-se escolhendo os dados a serem usados para o treinamento da rede. Esses dados podem ser do tipo “rotuladas” ou não, ou seja, no primeiro tipo haverá um conjunto de pares de entrada-saída desejável, além de dados pré-selecionados que validarão o modelo no momento de testar a sua capacidade de generalização.

A escolha das variáveis de entrada é de grande importância, pois apesar da rede ter a capacidade de modelar problemas difíceis de especificar, é preciso que existam dados e observações suficientes e representativos para o conhecimento ser extraído e para que o aprendizado da RNA ocorra com sucesso.

Através de um algoritmo de treinamento o conhecimento é transmitido à RNA, sendo o aprendizado transformado e armazenado em densidades de conexões, ou seja, durante o processo de treinamento, os pesos sinápticos da rede gradualmente convergem para determinados valores, de modo que a aplicação dos vetores de entrada produza as saídas necessárias. Os algoritmos diferem entre si pela forma como se dá o ajuste dos pesos (HAYKIN, 2001; VELLASCO, 2007).

Assim, o aprendizado se torna o resultado das muitas apresentações de um determinado conjunto de dados de treinamento à rede.

O aprendizado é mantido de época em época (sendo a época uma apresentação completa de todo o conjunto de treinamento) até que os pesos e o polarizador se estabilizem e o erro médio quadrado sobre todo o conjunto de treinamento convirja para um valor mínimo e o objetivo pretendido seja atingido. Contudo, a minimização do erro quadrado médio é um dos critérios para o ajuste de pesos, porém existem outros critérios que podem ser utilizados, como por exemplo, a maximização da informação mútua que objetiva a maximizar a informação entrada-saída (VELLASCO, 2007).

Os procedimentos existentes para se realizar o treinamento e aprendizado de uma RNA são o supervisionado e não supervisionado.

O procedimento supervisionado é realizado através da interrelação de um ambiente na qual as características estatísticas não mudam com o tempo, ou seja, é estacionário; de um supervisor, denominado professor, que conhece a resposta desejável e que realiza sempre que necessário ajustes para obtê-la e o algoritmo de aprendizado que ajusta os pesos para fazer o mapeamento entrada-saída (HAYKIN, 2001; VELLASCO, 2007).

O funcionamento deste processo se dá através da aplicação de um vetor de entrada e, então, a saída fornecida pela rede é comparada com o vetor de resposta desejado, obtendo-se desta comparação um sinal de erro. O erro encontrado é realimentado através da rede e os pesos atualizam-se segundo um algoritmo determinado cujo objetivo é a redução deste erro. Portanto, o aprendizado supervisionado pressupõe um erro de saída. O algoritmo de aprendizado supervisionado mais utilizado é o Backpropagation.

No treinamento não supervisionado, não existe um vetor de resposta desejada, portanto, não existem comparações que forneçam um sinal de erro.

Para tal processo são fornecidas à rede condições para realizar uma medida independente da tarefa que deve ser aprendida e os parâmetros livres da rede são otimizados em relação a esta medida. Uma vez que a RNA esteja ajustada às regularidades estatísticas dos dados de entrada, a rede desenvolve a habilidade de formar representações internas para codificar as características de entrada e criar automaticamente novas classes. Pode-se exemplificar tal treinamento através da rede de Kohonen (HAYKIN, 2001; VELLASCO, 2007).

Após a fase de treinamento, apresenta-se à rede um padrão que nunca antes apresentado, porém pertencente a população de padrões utilizados para o treinamento. A RNA deve ser capaz de identificar a categoria correta deste padrão particular devido à informação extraída no aprendizado.

A obtenção de um mapeamento entrada-saída correto mesmo se a entrada é um pouco diferente dos dados apresentados, ou seja, analisando os resultados fornecidos pela rede, através dos dados do conjunto para o treinamento e dos dados selecionados para validar o modelo, demonstra que a rede apresentou boa capacidade de aprendizado dos dados de validação.

Entretanto, caso seja apresentado um número excessivo de dados durante a fase de treinamento a RNA perde a capacidade de generalização dos padrões de entrada-saída similares, obtendo-se assim um excelente resultado de treinamento, porém um péssimo ajuste dos dados de validação. Isto também ocorre quando são utilizados mais neurônios ocultos que o necessário, pois isso faz com que contribuições indesejáveis da entrada fiquem armazenadas nos pesos fazendo com que a RNA aprenda ruídos.

2.3.1 Rede Perceptron de Múltiplas Camadas (MLP)

As redes neurais Perceptron multicamadas ou Multilayer Perceptrons (MLP) são uma importante classe de redes neurais. Possuem sua estrutura em camadas, normalmente estruturada por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, com o sinal se propagando sempre para a frente, seu treinamento é realizado de forma supervisionada com o algoritmo de retropropagação do erro que é baseado na regra de correção de erro (RUMELHART et al., 1986; BENDER, 1996; MICHALEWICZ, 2000).

Segundo Haykin (2001), são características da MLP:

- O modelo de cada neurônio da rede incluir uma função de ativação não-linear, do tipo suave (quando se há diferenciação em qualquer ponto);
- Sua estrutura apresenta uma ou mais camadas de neurônios ocultos que não são parte da entrada e nem da saída da rede, capazes de capacitar a rede na aprendizagem de tarefas complexas, extraíndo progressivamente as características mais significativas dos padrões de entrada;
- Alto grau de conectividade determinado pelos seus pesos, sendo que se ocorrer uma modificação na conectividade da rede haverá a necessidade da realização de modificações nos pesos.

Introduzindo-se uma camada extra no perceptron, altera-se qualitativamente o formato das funções discriminantes, sendo que o número máximo de regiões distintas no espaço de entrada é controlado pelo número de neurônios escondidos.

Um MLP com duas ou mais camadas escondidas é um aproximador universal, ou seja, realiza qualquer mapeamento entrada-saída, pois os neurônios de saída criam regiões de decisão que não são mais convexas, fazendo com que

exista mais de um conjunto de pesos para uma combinação particular de regiões de decisão.

Segundo Nievola (2005), a rede MLP estruturada com apenas uma camada escondida e neurônios com função de ativação sigmoidal é considerado um mapeador universal, ou seja, pode aproximar com uma precisão arbitrária qualquer região de decisão contínua.

O uso do algoritmo de retro-propagação (“backpropagation”) para o treinamento de redes MLP é sistemático, podendo ser aplicado a qualquer topologia do tipo direta.

O algoritmo de retro-propagação do erro é o algoritmo de treinamento supervisionado mais difundido, cuja entrada é apresentada e propagada para frente através da rede, calculando as ativações para cada unidade de saída, que é comparada com o valor desejado, resultando em um valor de erro. Na seqüência, são calculados os erros em cada unidade e são realizadas alterações nos pesos sinápticos.

Segundo Bishop (1995), os erros de classificação e o erro médio quadrático podem variar em sentidos opostos, pois o erro médio quadrático é sensível à diferença entre a resposta desejada e a atual, enquanto que o número de classificações erradas é uma quantidade digital que depende somente da maior saída.

Segundo Haykin (2001), a aprendizagem por retro-propagação do erro pode ser descrita como sendo:

- a) Propagação (um passo para a frente): Ocorre quando o vetor de entrada é aplicado aos neurônios da rede e seu efeito se propaga através dela,

camada por camada, até finalmente produzir o conjunto de saída, permanecendo fixos os pesos da rede.

b) Retro-propagação (um passo para trás): Ocorre quando os pesos são ajustados de acordo com uma regra de correção de erro. A resposta real da rede é subtraída da resposta desejada para produzir um sinal de erro, que é propagado para trás, sendo assim, os pesos são ajustados para aproximar a resposta da rede a resposta desejada.

Apesar do algoritmo de retro-propagação ser uma técnica muito difundida, existem problemas na sua implementação, como os mínimos locais e a paralisia da rede. Contudo, algumas heurísticas tentam melhorar o desempenho da rede como a constante de aprendizagem, o termo momento, a normalização dos dados de entrada, a utilização da função de ativação hiperbólica (o algoritmo aprende mais rápido), entre outras.

Um classificador ótimo deve criar funções de discriminação arbitrárias que separem os agrupamentos de dados de acordo com a probabilidade a posteriori. A rede MLP pode fazer isto desde que hajam neurônios suficientes para fazer o mapeamento, hajam dados em quantidade e qualidade, a aprendizagem convirja para o mínimo global e as saídas estejam entre 0 e 1 com a soma das mesmas com valor unitário.

2.4 Algoritmo K-Nearest Neighbor (K-nn)

O algoritmo de classificação baseado no vizinho mais próximo (Nearest Neighbor – NN) é uma técnica amplamente empregada para reconhecer padrões. Seu ideal geral consiste em encontrar os k exemplos rotulados (vizinhos) mais

próximo de um exemplo não classificado, ou seja, descobrir o k vizinho mais próximo de uma dada instância. Este algoritmo pertence a um grupo de técnicas denominada de Aprendizagem Baseada na Instância (Instance-based Learning).

Durante a fase de classificação do KNN, algumas vezes ocorre um problema, onde, dado um padrão de teste X , os seus K -vizinhos mais próximos são de uma mesma classe e o algoritmo não consegue decidir com qual classes dos K -vizinhos ele deve comparar o padrão X . Para resolver essa situação, o padrão que teve o problema citado anteriormente será rodado de forma recursiva pelo algoritmo, o qual agora usará apenas $(K-1)$ vizinhos para o cálculo, até que uma das classes dos K -vizinhos apareça com maior frequência em relação às demais (BEZERRA, 2006).

Apesar de melhorar o desempenho de classificação em relação ao algoritmo original em alguns problemas, o KNN apresenta como deficiência o armazenamento de todos os padrões de treinamento na memória, como também ainda exige um grande esforço computacional.

O KNN é conhecido como sendo um método simples de estimação de densidade (WEBB, 2002) , devido ao fato dele estimar a densidade local de padrões de treinamento na vizinhança de um padrão desconhecido durante a classificação.

Este método classifica um dado elemento de acordo com as respectivas classes dos k ($k \geq 1$) vizinhos mais próximos – pertencentes a uma base de treinamentos dada. O algoritmo calcula a distância do elemento dado para cada elemento da base de treinamento e então ordenar os elementos da base de treinamento do mais próximo ao de maior distância. Dos elementos ordenados selecionam-se apenas os k primeiros, que servem de parâmetro para a regra de classificação.

Segundo Ferrero (2009), há 3 importantes parâmetros que devem ser determinados para a execução do k-nn, são eles:

- a) Quais exemplos rotulados devem ser lembrados;
- b) Qual a medida que quantifica a similaridade entre o exemplo não classificado e os exemplos treinados;
- c) Quantos/quais vizinhos mais próximos devem ser considerados.

O KNN possui um parâmetro chamado K, que indica o número de vizinhos que serão usados pelo algoritmo durante a fase de teste. O parâmetro K faz com que algoritmo consiga uma classificação mais refinada, porém o valor ótimo de K varia de um problema para o outro, o que faz com que, para cada base de dados, sejam testados vários valores diferentes de forma a descobrir qual o melhor valor de K para determinado problema.

Para $k = 1$ a regra de classificação é irrelevante, pois só existe um elemento só tem uma classe, logo atribui-se a classe desse elemento àquele que se pretende classificar. Porém, com $k > 1$, é preciso haver uma regra para discernir a qual classe se atribuirá o elemento. Wang (2006), descreve as duas regras de classificação clássicas: maioria na votação e peso pela distância. Na primeira, cada elemento tem uma influência igual, a classe escolhida é aquela que possuir mais representantes entre o k-NN. Já no peso pela distância cada k-vizinho tem um peso inversamente proporcional à sua distância.

Segundo Wilson & Martinez (1997); Wang (2006) e Paredes & Vidal (2006), as funções de distância possibilitam as maiores variações no resultados obtidos pelo algoritmo.

Quanto a distância entre dois elementos, há a necessidade de defini-los, sendo assim, cada elemento tem uma classe – usada na regra de classificação – e

um vetor de atributos, e cada um desses atributos tem um tipo que indica quais operações se pode realizar sobre o atributo. E é por meio dessas operações que se torna possível o cálculo das distâncias.

Dois elementos do mesmo domínio possuem o mesmo número n de atributos, seja i uma posição no vetor de atributos de um elemento qualquer, $1 \leq i \leq n$, se dois elementos pertencem ao mesmo domínio os atributos da posição i de cada elemento têm o mesmo tipo.

Wang (2006), lista quatro tipos de atributos:

- Nominal ou categórico;
- Ordinal;
- Intervalar;
- Racional ou numérico.

Contudo apenas o nominal e o racional são considerados. Um atributo categórico é um nome ou um rótulo, e permite somente as operações de “igualdade” e de “diferença”. O numérico é um número, portanto, pode-se comparar não só a igualdade, mas também “maior”, “menor”, “adição”, “subtração”, “multiplicação” e “divisão”.

Wilson & Martinez (1997) enumeram várias funções de distâncias entre atributos, sendo o exemplo mais clássico a distância Euclidiana para atributos numéricos e a distância de Hamming para atributos categóricos. Essas distâncias por si só não resolvem o problema de calcular a diferença entre dois vetores de atributos, é preciso combinar estratégias para realizar tal tarefa.

2.5 Processamento Digital de Imagem

Segundo Perelmuter et. al (1995), pode-se definir processamento digital de imagens como sendo o processo de cognição de uma imagem, que pertence à área do Reconhecimento e Análise de Padrões.

Este autor ainda cita em seu trabalho que os avanços tecnológicos que ocorreram na eletrônica, a partir da década de 80, fizeram com que as técnicas digitais passassem a ser empregadas com o intuito de se obter um mecanismo para classificação de imagens e que a área de processamento e reconhecimento de imagens, nos últimos anos, obteve uma grande visibilidade devido ao amadurecimento das técnicas de inteligência artificial, que atualmente vêm sendo empregadas, permitindo novas abordagens para a problemática.

As técnicas utilizadas para o reconhecimento de imagens, geralmente, usam técnicas de processamento de imagens para pré-processar os dados contidos na imagem e apresentá-los de forma que possam passar pela etapa de tratamento pelo algoritmo de treinamento.

Quando observado do ponto de vista da ótica, uma imagem é um conjunto de pontos que converge para formar um todo, mas pode-se afirmar de uma maneira mais ampla que uma imagem é o suporte para efetuar troca de informações (ALBUQUERQUE et. al, 2010).

Filgueras et al. (1987) define tratamento de imagem como sendo a síntese, a análise e o processamento de imagem.

Segundo Marques Filho & Vieira Neto (1999), os elementos de um sistema digital de imagens abrange as principais operações que se pode efetuar sobre uma imagem que são: aquisição, armazenamento, processamento e exibição.

A aquisição consiste na conversão de uma imagem em uma representação numérica adequada para o processamento digital subsequente.

O armazenamento de imagens digitais é considerado um dos maiores desafios no projeto de sistemas de processamento de imagens, devido a grande quantidade de bytes necessário, devido a este fato o armazenamento pode ser de curta duração (compreende apenas o período em que as imagens estão sendo utilizadas), armazenamento de massa (para operações de recuperação de imagens relativamente rápidas) e arquivamento de imagens (com objetivo de futura recuperação caso haja necessidade) (MARQUES FILHO & VIEIRA NETO, 1999).

A etapa que compreende o processamento de imagens digitais envolve procedimentos normalmente expressos sob forma algorítmica e abrange diversas sub etapas como: pré-processamento, segmentação e extração de características.

Durante o pré-processamento a imagem adquirida pode apresentar diversas imperfeições, como: presença de pixels ruidosos, contraste e/ou brilho inadequado, dados interrompidos ou indevidamente conectados, entre outros. Assim, esta etapa tem por finalidade aprimorar a qualidade da imagem para as etapas subsequentes, sendo a imagem resultante uma imagem digitalizada de melhor qualidade que a original. (MARQUES FILHO & VIEIRA NETO, 1999).

A segmentação consiste na primeira etapa de processamento da imagem, quando se considera uma análise do ponto de vista da informação nela presente. O termo segmentação vem do termo em inglês "image segmentation", criado durante os anos 80 (FU et. al, 1980).

Segmentar consiste em dividir a imagem em diferentes regiões, que serão posteriormente analisadas por algoritmos especializados em busca de informações ditas de "alto-nível". Devido às grandes facilidades na manipulação deste tipo de

imagens, principalmente porque reduz-se significativamente a quantidade de dados, elas são freqüentemente utilizadas no processo de tratamento dos dados. Globalmente, uma imagem em níveis de cinza pode ser segmentada de duas maneiras: ou considera-se a semelhança entre os níveis de cinza ou as suas diferenças (NEVES, et.al,1998).

A detecção de borda é uma técnica de processamento de imagens que determina pontos de uma imagem digital na qual ocorrem mudanças repentinas de intensidade luminosa, ou seja, os pontos de borda podem ser entendidos como as posições dos pixels de uma imagem com variações abruptas de níveis de cinza (GONZALEZ, 2002). Mudanças repentinas em imagens geralmente refletem eventos importantes no cenário, como a descontinuação da profundidade, descontinuação da orientação da superfície, mudança das propriedades do material ou variações na iluminação da cena.

A detecção de borda é bastante usada na área de extração de características. Sua utilização reduz significativamente a quantidade de dados a serem processados, e descarta elementos que são considerados menos relevantes, ainda que preservando importantes propriedades estruturais de uma imagem. Existem várias técnicas de segmentação baseadas em bordas, tais como Sobel, Roberts, Laplaciano, entre outros (GONZALEZ, 2002).

O uso de filtros permite reduzir os ruídos da imagem através da segmentação que subdivide uma imagem em suas partes ou objetos constituintes para que mais padrões possam ser encontrados.

Este filtro consiste em um operador que calcula diferenças finitas, dando uma aproximação do gradiente da intensidade dos pixels da imagem. Em cada ponto da imagem, o resultado da aplicação do filtro Sobel devolve o gradiente ou a norma

deste vetor. Com isto consegue-se estimar a presença de uma transição claro-escuro e qual a orientação desta. Como as variações claro-escuro intensas correspondem a fronteiras bem definidas entre objetos, conseguiu-se, assim, fazer a detecção de contornos.

Segundo Kimmel *et al.* (2005), matematicamente este operador utiliza duas matrizes 3×3, uma para as variações horizontais e uma para as verticais, que são convoluídas com a imagem original para calcular aproximações das derivadas. Sendo A a imagem inicial, então, G_x e G_y (eq. 3 e eq.42) serão duas imagens que em cada ponto contêm uma aproximação às derivadas horizontal e vertical de A.

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * A \quad (3)$$

$$G_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} * A \quad (4)$$

Portanto, a magnitude (G) e a direção (θ), do gradiente são dadas pelas eq. (5) e eq. (6):

$$G = \sqrt{G_x^2 + G_y^2} \quad (5)$$

$$\theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (6)$$

Neste caso, a orientação θ , entende-se que a direção do máximo contraste do preto ao branco corre da esquerda para a direita na imagem, e outros ângulos são medidas no sentido anti-horário a partir deste.

Os dois componentes do gradiente são convenientemente calculados e adicionados em uma única passagem sobre a imagem original, usando o operador de pseudo convolução mostrado na Figura 7.

P_1	P_2	P_3
P_4	P_5	P_6
P_7	P_8	P_9

Figura 7: Kernels de pseudo convolução usado para calcular rapidamente magnitude do gradiente aproximado.

Usando este kernel a magnitude aproximada é dada pela eq. 7:

$$|G| = |(P_1 + 2xP_2 + P_3) - (P_7 + 2xP_8 + P_9)| + |(P_3 + 2xP_6 + P_9) - (P_1 + 2xP_4 + P_7)| \quad (7)$$

Embora o processo de percepção de cor pelo sistema nervoso central humano ainda não seja totalmente compreendido, os aspectos físicos da cor vêm sendo estudados há muitos anos por inúmeros cientistas e engenheiros, constituindo hoje um sólido conjunto de conhecimentos teóricos.

Quando trata-se de cor de um ponto de vista físico, na realidade trata-se de luz, que é uma radiação eletromagnética que possui uma certa energia para cada comprimento de onda. Sendo a função que informa o valor dessa energia chamada de Distribuição Espectral de Potência (SCURI, 1999).

A teoria de percepção cromática pelo olho humano baseia-se em hipótese formulada por Young em 1801, que estabelece que os cones (células fotossensíveis que compõem a retina juntamente com os bastonetes) se subdividem em três classes, com diferentes máximos de sensibilidade situados em torno do vermelho (R - Red), do verde (G - Green) e do azul (B - Blue). Assim, todas as sensações de cor percebidas pelo olho humano são na realidade combinações das intensidades dos estímulos recebidos por cada um destes tipos de cones (MARQUES FILHO & VIEIRA NETO, 1999).

Um modelo de cores é uma representação tridimensional na qual cada cor é representada por um ponto no sistema de coordenadas 3-D. Os modelos mais utilizados para representação de cores são: RGB (red (vermelho), green (verde), blue (azul)), CMY (cyan (ciano), magenta (magenta), yellow (amarelo)), CMYK (variante do modelo CMY, onde K denota black (preto)), YCbCr (padrão normalizado pela recomendação ITU-R BT.601 e utilizado em várias técnicas de compressão de vídeo), YIQ (padrão NTSC de TV em cores) e HSI (hue (matiz), saturation (saturação), intensity (intensidade)), às vezes também denominado HSV (hue(matiz), saturation (saturação), value (valor)) (MARQUES FILHO & VIEIRA NETO, 1999).

O modelo RGB baseia-se em um sistema de coordenadas cartesianas (Figura 8), que pode ser visto como um cubo onde três de seus vértices são as cores primárias, outros três as cores secundárias, o vértice junto à origem é o preto e o mais afastado da origem corresponde à cor branca. A escala de cinza, neste modelo, se estende através da diagonal do cubo que sai da origem (preto) até o vértice mais distante dela (branco). Por conveniência, geralmente assume-se que os valores máximos de R, G e B estão normalizados na faixa de 0 a 1 (MARQUES FILHO & VIEIRA NETO, 1999).

Figura 8- Representação do modelo RGB (Marques Filho & Vieira Neto, 1999).

A cor monocromática ideal é também chamada de cor espectral, já que possui apenas um único comprimento de onda.

A Figura 9 exemplifica as variações dos comprimentos de ondas para cores cromáticas, monocromática real e ideal.

Figura 9- Comprimento de ondas de cores monocromáticas e cromáticas (SCURI, 1999).

O termo imagem monocromática, segundo Gonzales (2002), refere-se à função bidimensional de intensidade da luz $f(x,y)$, onde x e y denotam as coordenadas espaciais e o valor f em qualquer ponto (x,y) é proporcional ao brilho (ou níveis de cinza) da imagem naquele ponto.

A utilização de imagens binárias para extração de características de é bastante simples, sendo as propriedades geométricas medidas diretamente sobre elas. As de luminância são obtidas da imagem original, a partir da informação de posição dos diversos objetos, fornecida pela imagem binária (SCURI, 1999).

3 OBJETIVO GERAL

O presente trabalho tem por objetivo testar a seguinte hipótese:

Características extraídas de imagens do espelho nasal de bovinos podem ser utilizadas como identificação biométrica na bovinocultura.

3.1 Objetivos Específicos

Esta hipótese será testada mediante a realização dos seguintes objetivos específicos:

- 1- Coletar imagens do espelho nasal dos animais para formação do banco de dados.
- 2- Analisar e processar as imagens digitais.
- 3- Usar as características obtidas na etapa anterior para treinamento de uma rede Multi Layer Perceptron (MLP), que servirá como classificador para as características extraídas das imagens na etapa anterior.
- 4- Comparar uma amostragem dos animais para verificar se houve diferenciação dos padrões com o passar dos meses.

4 MATERIAIS E MÉTODOS

Os materiais utilizados neste experimento, bem como os métodos empregados estão divididos em tópicos para melhor organização do conteúdo.

4.1 Obtenção do banco de dados

A composição do banco de dados deste trabalho foi dividido em duas etapas: a primeira com captura das imagens dos espelhos nasais dos animais com idade média de 11 meses; a segunda com captura das imagens dos espelhos nasais dos mesmos animais com idade média de 23 meses, objetivando avaliar se houve ocorrência de alterações na identificação dos animais com seu envelhecimento.

Na primeira etapa do experimento foram coletadas e catalogadas as imagens do espelho nasal de 51 bovinos da raça Nelore com aproximadamente 11 meses de idade, pertencentes à Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo (FZEA/USP), localizada no campus de Pirassununga, interior do Estado de São Paulo.

Na aquisição das imagens do espelho nasal os bovinos foram contidos individualmente em tronco de contenção, a cabeça foi posicionada manualmente com o auxílio de cabresto feito de corda tornando possível a captura das imagens com o mínimo de movimento possível por parte do animal, como mostra a figura 10. Cada animal recebeu ainda uma numeração de 1 a 51 para possibilitar a identificação do animal no trabalho assim como suas repetições. Esta numeração foi ainda associada ao seu número do brinco e tatuagem, objetivando facilitar sua

identificação dentre os animais do rebanho do campus da FZEA, para posterior repetição do experimento, conforme mostra a tabela 1.

Figura 10- Exemplo de contenção, posicionamento e numeração para aquisição da imagem do espelho nasal.

Tabela 1- Tabela de associação do número de experimento ao número do brinco e da tatuagem contida em cada animal.

EXP	BRI	TAT	EXP	BRI	TAT	EXP	BRI	TAT	EXP	BRI	TAT	EXP	BRI	TAT
1	107	1593	11	101	1664	21	248	1600	31	384	1715	41	39	1555
2	104	1557	12	103	1620	22	251	1580	32	391	1659	42	26	1677
3	102	1634	13	128	1595	23	241	1599	33	382	1553	43	38	1630
4	109	1568	14	127	1706	24	259	1577	34	392	1623	44	28	1621
5	106	1572	15	125	1565	25	261	1710	35	371	1682	45	50	1674
6	105	1643	16	SN	1626	26	256	1573	36	389	1036	46	40	1578
7	110	1548	17	252	1631	27	246	1717	37	390	1552	47	49	1544
8	108	1597	18	242	1601	28	258	1554	38	379	1606	48	35	1583
9	126	1704	19	253	1613	29	249	1611	39	386	1581	49	32	1612
10	99	1652	20	243	1624	30	366	1642	40	37	1607	50	30	1616
												51	27	1628

LEGENDA: **EXP:** Número do experimento, **BRI:** Número do brinco, **TAT:** Número da tatuagem

Os animais foram fotografados com uma câmera digital Sony Cybershot – *super SteadyShot DSC-H5*, de resolução máxima de 7.2 Megapixel, a um metro de distância com a utilização do zoom óptico, que aproximou em 3 vezes a imagem. Os

animais tiveram o focinho limpos e secos com folhas de papel toalha. Esta limpeza não incluiu nenhum método asséptico ou de lavagem da área e assim apenas a remoção da sujidade e da umidade passando-se a folha seca de papel toalha na área. Tal procedimento foi realizado objetivando evitar que gotículas de suor e outros artefatos alterassem os contornos das vilosidades dos mesmos.

Após tais procedimentos, cada animal teve em média 18 imagens capturadas de seu espelho nasal, das quais foram selecionadas as 16 melhores imagens, totalizando um banco de dados de 816 imagens para serem posteriormente processadas e analisadas.

Na segunda etapa do experimento, que também ocorreu nas dependências da Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo, foram escolhidos aleatoriamente 16 bovinos para nova coleta e catalogação das imagens dos espelhos nasais, para analisar a ocorrência ou não de alterações nos padrões do espelho nasal dos bovinos (Figura 11).

Figura 11- Contenção manual para posicionamento da cabeça do animal.

A identificação nesta etapa foi realizada através da comparação da numeração do brinco e da tatuagem com a tabela feita na primeira etapa do experimento. Este procedimento foi adotado para otimizar o tempo de coleta dos dados, evitando que o animal ficasse muito tempo contido, aumentando assim seu estresse e reatividade, fato este que aumentaria a dificuldade na imobilização da cabeça do animal.

As imagens foram capturadas com a mesma câmera fotográfica, visando anular diferenças que possam ocorrer devido câmeras de marcas diferentes e a resolução utilizada foi de 3 Megapixel para todos os animais, pois observou-se que o processamento de imagem realizado anula o efeito da diferença de resolução, possibilitando desta forma o uso de uma resolução menor sem que ocorra uma influência negativa nos resultados.

A distância para captação das imagens manteve-se de um metro e a aproximação da imagem com a utilização do zoom óptico, manteve-se em 3 vezes, objetivando diminuir ao máximo as diferenças entre os experimentos que pudessem ocasionar erros.

Nesta etapa os animais não tiveram o espelho nasal limpos e secos, devido ao tempo de manejo e objetivando verificar se este fato realmente seria um fator limitante à identificação do animal, visto que se esta técnica fosse aplicada comercialmente a campo, a identificação sem a limpeza otimizaria o tempo de coleta das imagens.

Após tais procedimentos cada animal teve em média 18 imagens capturadas de seu espelho nasal, das quais foram selecionadas as 11 melhores imagens, totalizando um banco de dados de 198 imagens para serem posteriormente processadas e analisadas.

Em nenhuma das etapas do experimento houve a utilização de flash para correção da luminosidade, correção que será realizada durante o processamento das imagens.

4.2 Processamento das Imagens

O objetivo do uso das técnicas de processamento digital de imagens é melhorar o aspecto visual de certas características estruturais do espelho nasal, para o analista humano e fornecer outros subsídios para a sua interpretação.

Para o processamento das imagens do banco de dados foram desenvolvidos dois softwares. O primeiro, desenvolvido em ambiente MATLAB® consiste nas seguintes etapas:

1. Seleção: selecionar a imagem do banco de dados a receber pré-processamento, determinar a região do espelho nasal a ser estudada e recortá-la, gerando a imagem da figura selecionada já em escala de cinza, ou seja, binarizada;
2. Segmentação: avaliar o efeito de filtros Log e Sobel em imagem conhecida e na imagem da área selecionada do espelho nasal, escolhendo o mais adequado;
3. Equalização: Avaliar os efeitos da equalização e segmentação da imagem;
  - a. Caso a imagem seja segmentada deve-se definir seu limiar.
4. Redução de Dimensionalidade: gerar um mapa direcional da imagem;
  - a. Armazenar a imagem segmentada.
  - b. Armazenar o mapa direcional da imagem selecionada.

O segundo software, desenvolvido em ambiente MATLAB®, tem a finalidade de extrair características do mapa direcional e normalizar a quantidade de dados. A metodologia usada foi a de dividir as direções em 10 regiões de 0 a π radianos. Para cada região, um vetor direcional médio representando tal região foi calculado, gerando uma única matriz de ângulos que represente a imagem. Estas direções serão usadas para treinar a rede neural.

Os algoritmos dos programas desenvolvidos em ambiente MATLAB® encontram-se nos Anexos 1 e 2.

4.2.1 Etapas do Primeiro Programa

4.2.1.1 Seleção

A área pré-estabelecida do espelho nasal dos bovinos a ser analisada refere-se à área que compreende a tangente da borda superior do lábio e as tangentes da curvatura interna e superior das aberturas da narina do animal, evidenciado na Figura 12.

Nesta etapa, o programa executa um algoritmo (Anexo 1) que permite a seleção da área da imagem onde serão analisadas as características do focinho. Após a escolha da área a mesma é visualizada em painel ao lado da imagem original usando um processo de segmentação e equalização.

Figura 12- O retângulo vermelho evidencia a área de seleção do software e a imagem do interior será a imagem que sofrerá processamento com o intuito de destacar e estudar as características desejáveis do focinho.

4.2.1.2 Segmentação e Equalização

O processo de segmentação e equalização é o “enhancement” da imagem. Este termo está associado à melhoria da qualidade de uma imagem, com o objetivo posterior de ser julgado por um observador humano. Esta etapa constitui o pré-processamento das imagens, melhorando-as para aumentar a chance de sucesso das etapas seguintes do processamento.

Neste trabalho, cada pixel na imagem foi segmentado em duas regiões: aqueles pertencentes às células e aqueles pertencentes ao fundo da imagem. A imagem obtida neste caso é composta por 256 tons de cinza, também denominada como imagem binária, variando da região branca (fundo e vales) até a região preta (vilosidades e culmes).

O tipo de segmentação adequado para o fim a que se destina esse trabalho é o reconhecimento de bordas.

As técnicas testadas para verificação de maior eficiência a detecção de estrias, rugosidade, vales, culmes e outras possíveis formas que compõe as bordas das imagens estudadas foram os filtros de Sobel e Log.

Durante este processo a imagem da área selecionada é transformada em uma imagem monocromática, objetivando sua melhoria.

4.2.1.3 Redução de Dimensionalidade

As quantidades de dados nas imagens selecionadas não são homogêneas e possuem ruídos e redundâncias. Nesta etapa o programa usa a metodologia de mapa direcional para reduzir a dimensão das imagens para posterior extração de características. O mapa direcional é obtido pelo cálculo do gradiente existente entre picos e vales na imagem segmentada. Desta forma cada conjunto de pixels na imagem é substituído por um ângulo que indica uma direção dos vales em relação aos picos na imagem.

4.2.2 Segundo Programa

Este segundo software, foi desenvolvido com a finalidade de gerar uma única matriz de ângulos, que represente a imagem de forma que tais direções possam ser

utilizadas no treino e teste da rede neural, conforme descrito anteriormente na metodologia.

Considerando-se que na primeira fase do experimento têm-se os dados de 51 animais, sendo que cada animal possui 16 repetições e que na segunda fase do experimento têm-se 16 animais com 10 repetições, e que para o treinamento da rede neural necessita-se de um percentual maior de imagens do que para o teste, realizou-se a divisão das informações das imagens, sendo 60% para a utilização do treinamento da rede e, 40% para o teste da mesma.

Assim, foi gerada pelo programa a matriz única de ângulos para cada um dos animais da primeira etapa do experimento, sendo destinadas para o treino as repetições de 1 a 9 e para o teste as repetições de 10 a 16. Para a segunda etapa do experimento utilizou-se as repetições de 1 a 6, para a formação da matriz única de ângulos de cada animal para treino da rede e as repetições de 7 a 10 para o teste da rede, como mostra a Figura 13.

Figura 13- Interface do MatLab® exemplificando o processo que o segundo programa realiza para geração da matriz única de ângulos para cada animal do experimento em ambas as fases do experimento.

4.3 Preparação dos Dados para Utilização na Rede Neural Artificial

Após a matriz única de ângulos, que representa a imagem de cada bovino, ser gerada pelo segundo programa, conforme metodologia descrita anteriormente, elaborou-se uma planilha na qual foram compilados os dados dos animais separados em grupos de treinamento e teste.

Os dados de cada animal, de ambas as fases do experimento, foram treinados e testados, pela rede neural, com os dados de 10 animais escolhidos de forma aleatória. Formou-se, assim, 5 (cinco) agrupamentos, em arquivo de texto, composto pelos dados do animal base de treino ou teste e os dados de outros dois

boi1_6_40 - Bloco de notas

Arquivo Editar Formatar Exibir Ajuda

27 11 3

0.1096	0.3719	0.5716	0.9124	12.127	14.705	17.050	20.239	24.913	27.809	30.063	0 0 1
0.1304	0.3665	0.6446	0.9246	11.805	14.473	17.014	20.530	24.819	27.276	30.202	1 0 0
0.1237	0.3536	0.5650	0.9887	11.900	14.402	16.795	20.605	25.183	27.338	30.146	0 0 1
0.1324	0.3706	0.6743	0.9230	11.670	14.495	16.925	20.442	25.086	27.591	30.084	1 0 0
0.1245	0.3687	0.6301	0.8913	11.967	14.758	16.972	19.998	24.888	27.649	30.257	1 0 0
0.1173	0.3894	0.6142	0.9191	11.418	14.196	16.953	20.542	25.126	27.661	30.071	0 1 0
0.1245	0.3687	0.6301	0.8913	11.967	14.758	16.972	19.998	24.888	27.649	30.257	1 0 0
0.1231	0.3841	0.6274	0.9476	11.702	14.413	17.145	20.560	25.058	27.449	30.254	1 0 0
0.1261	0.3516	0.6467	0.9462	11.794	14.451	16.802	19.411	25.244	27.794	30.313	0 0 1
0.1056	0.3643	0.6442	0.9339	11.692	14.435	17.024	20.483	25.219	27.647	30.170	0 0 1
0.1109	0.3950	0.5755	0.9411	11.569	14.661	16.955	20.689	25.158	27.738	30.147	0 0 1
0.1264	0.3630	0.6522	0.9030	11.802	14.719	17.308	20.534	25.221	27.604	30.070	0 1 0
0.1270	0.3922	0.6412	0.9321	12.034	14.539	16.830	20.098	24.992	27.742	30.136	0 0 1
0.1245	0.3576	0.6238	0.0000	12.398	14.482	16.829	20.228	25.663	27.995	30.330	0 0 1
0.1280	0.3824	0.6149	0.9150	12.030	14.587	16.896	20.636	24.846	27.741	30.224	1 0 0
0.1146	0.3674	0.6394	0.9545	12.027	14.469	17.270	20.981	25.201	27.641	29.988	0 1 0
0.1066	0.3652	0.5907	0.9707	12.003	14.676	17.136	20.860	25.058	27.520	29.874	0 1 0
0.1212	0.3996	0.5742	0.9505	11.630	14.229	16.879	20.678	25.100	27.621	30.028	0 1 0
0.1286	0.3823	0.6600	0.9539	11.625	14.497	16.873	20.565	25.059	27.468	30.162	1 0 0
0.1226	0.3834	0.6490	0.9030	11.814	14.271	17.122	20.898	25.159	27.590	30.027	0 1 0
0.1108	0.3802	0.6549	0.8817	11.748	14.589	17.074	20.408	25.126	27.665	30.279	0 0 1
0.1197	0.3855	0.6716	0.9605	11.927	14.393	17.234	21.167	25.537	27.657	30.241	0 1 0
0.1004	0.3613	0.6385	0.9145	11.655	14.583	17.013	20.443	25.146	27.704	30.201	0 0 1
0.1220	0.3746	0.6649	0.9349	11.868	14.378	16.944	20.426	24.805	27.617	30.142	1 0 0
0.1375	0.3628	0.6221	0.8720	11.806	14.398	17.131	21.155	25.207	27.541	29.932	0 1 0
0.1144	0.3733	0.6196	0.8872	11.582	14.549	17.011	20.767	25.323	27.724	30.141	0 1 0
0.1338	0.3830	0.6340	0.9247	11.799	14.503	17.216	20.688	25.049	27.414	29.903	1 0 0

Constata-se a intercalação dos animais através das saídas que encontram-se misturadas.

Figura 15- Arquivo texto a ser utilizado pela rede neural cujos animais encontram-se misturados e as saídas em forma binária.

4.4 Reconhecimento de padrões

Para testar a eficiência do mapa direcional foram utilizados dois modelos de reconhecimento de padrões: um usando uma rede neural, do tipo MLP, treinada com as médias das dez principais direções angulares retiradas do mapa direcional obtido da imagem e outro usando o método estatístico do vizinho mais próximo, ambos no MATLAB®.

4.4.1 A Rede Neural Artificial

No presente trabalho a rede neural utilizada foi a Multi Layer Perceptron (MLP) ou multicamadas modelada em ambiente C++ e executada em modo “stand alone”. Como os vetores de treinamento possuem 10 e 20 dimensões, respectivamente a cada um dos dois métodos de extração das características, a rede possuirá 10 e posteriormente 20 neurônios na camada de entrada e como a saída será ortogonal com 3 dimensões (Figura 14), a saída da rede foi composta com 3 neurônios .

Figura 16: Representação do vetor ortogonal utilizado como saída na RNA.

A camada escondida foi composta por 9 neurônios na camada do meio respeitando uma relação entre o número de neurônios na camada de saída elevada ao quadrado (Figura 17). Aproximadamente dois terços do total da base de dados foram usados para treinar a rede e um terço restante foi usado para testar a rede. Sendo assim, na etapa de treinamento, foram utilizados 27 vetores e na etapa de teste 18 vetores. O algoritmo utilizado no treinamento foi o de retro-propagação do erro (“backpropagation”), em que os pesos são ajustados baseados na regra de aprendizagem por correção de erro, cujo paradigma baseia-se na aprendizagem

supervisionada na qual a saída desejada para cada padrão de entrada é fornecida pelo supervisor, neste caso, a saída é representada por um vetor ortogonal de três dimensões.

Figura 17- Modelo da rede neural MLP, do tipo utilizado neste trabalho.

O sinal de saída gerado pela rede é comparado com a resposta desejada, produzindo, assim, um sinal de erro quadrático médio (EQM). O EQM é determinado somando os erros de previsão ao quadrado e dividindo pelo número de erros usados no cálculo e pode ser expresso pela eq. 8. O EQM do total, para todos os n valores ajustados, é a soma de todos os n erros quadráticos médios individuais. Este sinal de erro é então utilizado para ajustar os pesos das conexões com o objetivo de aproximar o sinal de saída da resposta desejada reduzindo, assim, este erro.

$$EQM = \frac{\sum_{t=1}^n e_t^2}{n} \quad (8)$$

Durante o processo de aprendizagem da RNA a taxa de aprendizagem, a taxa de momentum e os parâmetros da função de ativação foram constantemente modificados, buscando manter um erro em 1%. Estes ajustes se fazem necessários devido ao fato de a combinação que resulta na melhor identificação de um animal, nem sempre ser a mesma para outro, sendo assim, é necessário ajustar constantemente a configuração da rede neural com parâmetros diferentes para cada bovino, possibilitando assim, o seu treinamento.

Posteriormente a esta etapa, foi feito o teste do aprendizado da rede com os pesos gerados para o conjunto de treinamento, o arquivo de padrões foi apresentado à rede sem as saídas e com os parâmetros da função de ativação utilizados no treinamento.

Após o teste da rede comparou-se a média de acertos entre as saídas fornecidas para a rede no treinamento e as saídas fornecidas pela rede, podendo-se assim verificar se a rede foi capaz de diferenciar os animais, e julgar se este foi um bom classificador ou não.

4.4.2 Método do K-nn

O método K-nn classifica um padrão de acordo com a distância entre o padrão e os K vizinhos mais próximos, dentro de uma distribuição estatística que

define a variabilidade do padrão. Basicamente o método K-nn usa a técnica de medida de similaridade, usando uma métrica que pode, por exemplo, ser uma métrica estatística ou a distância euclidiana.

Para testar o mapa direcional uma imagem formada pelas direções foi calculada em duas diferentes situações de luminosidade, conforme ilustram as Figuras 19 e 20. A seguir foi aplicado o k-nn nas imagens originais e na imagem do mapa direcional obtida das mesmas. O k-nn utilizado foi implementado usando como métrica a distância euclidiana no ambiente Matlab® (Anexo 3). Os resultados do K-nn foram comparados com os resultados do MLP.

5 RESULTADOS E DISCUSSÃO

Através do fluxograma representado na Figura 18 é possível retomar a metodologia utilizada, tendo uma noção geral da parte experimental cujos resultados serão expostos, analisados e discutidos neste tópico.

Figura 18- Fluxograma das etapas percorridas durante metodologia deste trabalho.

5.1- Manejo dos animais e Aquisição de Imagens

Segundo Eurides (1998), a contenção da cabeça é a atividade de contenção mais fácil de ser realizada no bovino e a metodologia de contenção da cabeça dos

bovinos utilizada neste trabalho, cabresto e utilização das mãos, corrobora com o descrito como formas de contenção de bovinos pelo autor.

A manipulação dos animais quanto à forma de contenção da cabeça utilizada na primeira fase do experimento, utilizando o cabresto, apresentou maior homogeneidade na posição em que o animal foi fotografado, quando comparado com a segunda fase do experimento, quando a contenção foi realizada com as mãos, pois nesta observa-se maior quantidade de variações na posição da cabeça do animal e conseqüentemente, na angulação do espelho nasal para posteriores análises.

O fato dos animais terem sido fotografados em áreas de manejo distintas, devido à disponibilidade da Universidade, acarretou uma diferença significativa na luminosidade entre os experimentos (Figura 19), contudo, este fato não prejudicou o resultado do experimento, pois o processamento de imagem utilizado corrigiu as alterações ocasionadas por tal diferença, como pode ser observado no mapa direcional (Figura 20), possibilitando assim a extração de características necessárias para análise.

Figura 19- Diferença da luminosidade entre a primeira fase do experimento (imagem A) e a segunda fase (imagem B) para o mesmo animal.

Figura 20- Mapa direcional representando as imagens vetorizadas da Figura 18, respectivamente, demonstrando que a diferença de luminosidade não altera o resultado.

5.2 Programa para tratamento das imagens do focinho

Este programa foi desenvolvido na plataforma MATLAB® e o código fonte algoritmo encontra-se no Anexo 1.

A figura 21 fornece uma visão geral das etapas percorridas pelo programa.

Figura 21- Esquema das etapas do programa de tratamento de imagem.

5.2.1 Seleção

A determinação da área do espelho nasal bovino para seleção e análise, como descrito na metodologia, foi realizada com base nas pesquisas realizadas por Minagawa *et al.* (2002), Blomeke *et al.* (2004) e Barry *et al.* (2007), que descrevem tal região como área de possível identificação biométrica dos bovinos, devido às características únicas pertencentes à região como vilosidades, culmes e vales.

No algoritmo desenvolvido no MATLAB®, todas as imagens do banco de dados foram selecionadas na área pré-estabelecida para análise (Figura 22) e convertidas para escala de cinza, ou seja, tornaram-se imagens monocromáticas após o recorte da área delimitada (Figura 23), pois transformando-as aumenta-se o contraste ou evidencia-se a região de interesse particular, o que corrobora com o descrito por Hecht (1998) e Carlin *et. al* (2004).

Nesse trabalho, o pré-processamento envolve técnicas para o realce de contrastes, remoção de ruído e isolamento de regiões cuja textura indique a probabilidade de informação alfanumérica.

Figura 22- Interface do software desenvolvido para o pré-processamento das imagens do banco de dados ilustrando a forma que de seleção da área a ser estudada.

Figura 23- Interface do software mostrando a área selecionada já recortada e convertida para escala de cinza.

5.2.2 Redução de Dimensionalidade

Comparando-se, apenas com a visão humana, o tamanho do contorno dos vetores periféricos do mapa direcional de uma imagem com padrão de borda conhecido com o tamanho do contorno da imagem segmentada, foi observado se esta mantém o mesmo padrão do contorno, tornando possível a determinação do limiar e do tamanho do bloco.

Neste trabalho a imagem conhecida utilizada foi a do número 1 retirado da imagem de identificação do animal 1, objetivando anular fatores que alterassem o resultado para a aplicação na imagem do espelho nasal.

Assim, foi determinado o limiar em 7 Mega pixel e o tamanho de bloco de 16 além de ficar nítido que o uso do filtro Sobel supera o Log, pois é o que compreende menor quantidade de informações mantendo o padrão da borda mais nítido possível ao analisador. Segundo os autores Marr (1982), Rosenfeld (1993), Guyon (1991), Binford *et. al* (1991), Albuquerque *et. al* (2010) é evidente que processar uma imagem, como é feito pelo sistema visual humano (SVH), é extremamente complexo, por isso que o método comparativo utilizado neste trabalho foi a visão humana.

Concomitantemente foi observado que o uso da segmentação da imagem supera a equalização da mesma, assim como a inviabilização da utilização da segmentação da imagem associado ao filtro Log, pois este conjunto anula a imagem. Tais análises são possíveis através da observação das figuras 24 e 25.

Estas observações induziram a utilização da segmentação de imagem com filtro de Sobel para processamento de todas as imagens que compõem o banco de dados.

(a)

(b)

Figura 24- As figuras (a) e (b) estão comparando o uso da segmentação e da equalização da imagem, ambas com a utilização do filtro de Sobel, mostrando que a imagem segmentada associada a este filtro representa a imagem original com menos informações, porém sem perda da informação de borda original.

(a)

(b)

Figura 25- As figuras (a) e (b) estão comparando o uso da equalização e da segmentação da imagem, ambas com a utilização do filtro Log, mostrando que ainda a imagem segmentada associada ao filtro de Sobel é a que melhor representa a imagem original com menos informações, porém sem perda da informação de borda original.

Após a definição do filtro a partir dos testes acima descritos, aplicou-se a técnica às imagens, utilizando segmentação com limiar 7 Mega pixel para as

imagens da primeira fase do experimento e limiar 4 para as imagens da segunda fase, para melhor representatividade da imagem e correção da luminosidade ; filtro do tipo Sobel e mapa direcional com tamanho de bloco definido em 16. Como resultado pode-se exemplificar o obtido com a imagem da figura 26 e 27.

Figura 26- Interface do programa mostrando a imagem original do espelho nasal do animal da primeira fase do experimento selecionada e segmentada, com limiar de segmentação 7 e tamanho do bloco 16, o filtro utilizado, o mapa direcional e a identificação utilizada.

Figura 27- Interface do programa mostrando a imagem original do espelho nasal do animal da segunda fase do experimento selecionada e segmentada, com limiar de segmentação 4 e tamanho do bloco 16, o filtro utilizado, o mapa direcional e a identificação utilizada.

5.3 Extração de Características

O algoritmo de extração de características (Anexo 2) calcula a média dos 10 e dos 20 principais ângulos dos mapas direcionais de cada animal. Esta extração normaliza os dados em relação à dimensão ou número de pontos, possibilitando, assim, o posterior treinamento e teste da rede neural artificial. A Figura 28 mostra o resultado do programa para o arquivo de treinamento e a Figura 29 evidencia o resultado do programa para o arquivo de teste da rede neural.

Mboi1_seg1_f - Bloco de notas											
Arquivo	Editar	Formatar	Exibir	Ajuda							
0.1220	0.3746	0.6649	0.9349	1.1868	1.4378	1.6944	2.0426	2.4805	2.7617	3.0142	
0.1338	0.3830	0.6340	0.9247	1.1799	1.4503	1.7216	2.0688	2.5049	2.7414	2.9903	
0.1324	0.3706	0.6743	0.9230	1.1670	1.4495	1.6925	2.0442	2.5086	2.7591	3.0084	
0.1245	0.3687	0.6301	0.8913	1.1967	1.4758	1.6972	1.9998	2.4888	2.7649	3.0257	
0.1245	0.3687	0.6301	0.8913	1.1967	1.4758	1.6972	1.9998	2.4888	2.7649	3.0257	
0.1304	0.3665	0.6446	0.9246	1.1805	1.4473	1.7014	2.0530	2.4819	2.7276	3.0202	
0.1231	0.3841	0.6274	0.9476	1.1702	1.4413	1.7145	2.0560	2.5058	2.7449	3.0254	
0.1286	0.3823	0.6600	0.9539	1.1625	1.4497	1.6873	2.0565	2.5059	2.7468	3.0162	
0.1280	0.3824	0.6149	0.9150	1.2030	1.4587	1.6896	2.0636	2.4846	2.7741	3.0224	

Figura 28- Matriz única da repetição de 1 ao 9 do animal número 1 que será utilizada para treinar a rede neural artificial associada a outros dois animais escolhidos de forma aleatória.

boi2_40_30 - Bloco de notas											
Arquivo	Editar	Formatar	Exibir	Ajuda							
0.1193	0.4104	0.6582	0.9116	1.1945	1.4482	1.6957	2.1095	2.4740	2.7432	3.0114	2
0.1217	0.3903	0.6468	0.9427	1.1889	1.4463	1.7026	2.0489	2.5131	2.7501	3.0291	2
0.1169	0.3711	0.6597	0.8988	1.1461	1.4348	1.7045	2.1131	2.4844	2.7545	3.0395	2
0.1266	0.3809	0.6259	0.9558	1.1553	1.4439	1.6909	2.0931	2.4921	2.7472	3.0099	2
0.1172	0.3659	0.6379	0.9128	1.2114	1.4388	1.6932	2.0967	2.5001	2.7474	3.0118	2
0.1212	0.3829	0.6547	0.9545	1.1836	1.4542	1.6865	2.0842	2.4978	2.7562	3.0273	2
0.1090	0.3556	0.6307	0.9436	1.1997	1.4352	1.7197	2.0759	2.4915	2.7546	3.0031	2
0.1132	0.3408	0.6753	0.9483	1.1943	1.4784	1.7098	2.1204	2.5127	2.7459	3.0004	40
0.1291	0.3876	0.6235	0.9610	1.2181	1.4565	1.6846	2.0447	2.4869	2.7710	3.0092	40
0.1156	0.3502	0.6553	0.9420	1.1994	1.4706	1.7025	2.0152	2.5204	2.7344	2.9914	40
0.1243	0.3758	0.6051	0.9624	1.2021	1.4444	1.6898	2.0375	2.5154	2.7713	3.0147	40
0.1309	0.3926	0.6359	0.9201	1.1692	1.4520	1.6956	1.9935	2.5687	2.7602	3.0437	40
0.1213	0.3648	0.6516	0.9455	1.1941	1.4365	1.6946	2.0322	2.5215	2.7631	3.0183	40
0.1120	0.3785	0.6468	0.9264	1.2170	1.4565	1.6900	1.9656	2.5064	2.7833	3.0271	40
0.1047	0.3845	0.6105	0.9069	1.2085	1.4635	1.7300	2.1248	2.5046	2.7485	2.9864	30
0.1285	0.3861	0.6415	0.9094	1.1922	1.4477	1.7045	2.0480	2.5014	2.7687	3.0153	30
0.1118	0.3811	0.6150	0.9067	1.1826	1.4415	1.7026	2.1060	2.4909	2.7703	3.0261	30
0.1407	0.3718	0.6184	0.9267	1.2284	1.4514	1.6999	2.0548	2.4905	2.7447	2.9925	30
0.1338	0.3716	0.6421	0.9294	1.1961	1.4310	1.6938	2.0187	2.5144	2.7669	3.0274	30
0.1125	0.4000	0.6355	0.9342	1.2201	1.4551	1.6744	2.0129	2.4460	2.7487	2.9736	30
0.1277	0.4087	0.6754	0.9476	1.1876	1.4572	1.6887	2.0310	2.4949	2.7821	3.0214	30

Figura 29- Matriz única da repetição de 10 a 17 de um conjunto de animais escolhido de forma aleatória que será utilizado no teste da rede neural.

Contudo, após o treinamento e teste da RNA esta técnica de extração de características não se mostrou a mais eficiente para classificar os animais, devido ao fato que quando se calcula a média dos ângulos muitas informações são perdidas, porém, mesmo com tais perdas, ainda assim foi possível verificar uma tendência percentual da diferenciação dos indivíduos, atingindo o objetivo deste trabalho.

5.3 Rede Neural Artificial como Classificador

A RNA foi utilizada neste trabalho como um classificador, realizando a diferenciação dos animais. Ela foi capaz de “aprender”, ou seja, encontrar uma função discriminante no espaço dos padrões através da fase de treinamento. As informações dos animais foram discriminadas para 100% do banco de dados com um erro quadrático médio de 1% (Figura 30).

Figura 30- Comportamento da queda do erro médio quadrático tendendo a 1% durante o treinamento da rede neural.

Através da tabela de confusão foi possível realizar uma análise geral da classificação realizada pela rede neural.

A primeira coluna representa as saídas desejadas fornecidas à rede neural durante o treinamento, sendo cada uma associada a um animal do experimento, neste caso a saída binária 1 0 0 representa o animal 1, 0 1 0 representa o animal 6 e a saída 0 0 1 o animal 40. A linha superior sinaliza a saída fornecida pela rede

neural, que ao ser comparado com a saída desejada fornece a porcentagem de acerto de classificação da RNA. A diagonal principal da tabela representa a saída desejada. No grupo exemplificado o percentual de acerto de classificação da rede foi de 57,14. Prosseguindo a análise desta tabela, também é possível verificar o percentual de acerto da rede neural para cada indivíduo, cuja média é de 75%, com exceção do animal que apresenta como saída desejada 0 1 0, apresentando um percentual de acerto de apenas 25% (Tabela 2) para os vetores com dimensão 10 (dez regiões angulares médias) e 66,7% de classificação para os vetores com dimensão 20 (vinte regiões angulares médias). As tabelas 2 e 3 demonstram esse comportamento estatístico, assim como a Figura 31.

Tabela 2- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pela rede neural, para o grupo de dados dos vetores com dimensão 10.

Saída Desejada\Saída obtida	1 0 0	0 1 0	0 0 1
1 0 0	5	2	0
0 1 0	5	2	0
0 0 1	2	0	5
Média=			57.14%

Tabela 3- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pela rede neural, para o grupo de dados dos vetores com dimensão 20.

Saída Desejada\Saída obtida	1 0 0	0 1 0	0 0 1
1 0 0	4	2	0
0 1 0	3	3	0
0 0 1	2	1	6
Média=			61,90%

Figura 31- Média de acertos da RNA como classificador.

O resultado obtido no teste da rede neural para os animais com idades diferentes apresenta uma média de acerto de 30,4% e desvio padrão de 6,73% para os dados dos animais utilizando vetores com dimensão 10 e 43,15% de média de acerto e desvio padrão de 5,39% para os vetores com dimensão 20 (Figuras 32 e 33).

Figura 32- Comparação da média de acerto da RNA entre o experimento1 (animais com 11 meses de idade) e o experimento 2 (testando o reconhecimento do animal aos 23 meses de idade), ambos vetores com dimensão 10.

Figura 33- Comparação da média de acerto da RNA entre o experimento1 (animais com 11 meses de idade) e o experimento 2 (testando o reconhecimento do animal aos 23 meses de idade), ambos vetores com dimensão 20.

A média de classificação dos animais relacionados nos mesmos grupos fornecidos para treinamento da rede neural foi de 57,36% associado a um desvio padrão de 9,% para dados com vetores com dimensão 10 e 66,7% associado a desvio padrão de 3,67%, superando os resultados obtidos por Minagawa et. al (2002), que para um grupo de 43 imagens, capturadas através de uma técnica de carimbo do espelho nasal, apresentou média de acerto de 31% associado ao desvio padrão de 11%.

Entretanto, quando comparado com o resultado obtido por Barry, et al. (2007), através da obtenção de fotografias digitais de focinhos de 29 bovinos e do uso de um programa de reconhecimento de teste padrão para armazenar e combinar as imagens dos mesmos, apresentando uma média de 98,85% de sucesso na identificação do gado, o resultado da classificação automática obtido neste trabalho usando a metodologia descrita, encontra-se significativamente abaixo do esperado, mas, os resultados dos mapas direcionais mostraram que mesmo diminuindo a dimensionalidade da imagem, pode-se verificar visualmente que mantém o padrão da mesma (Figura 34).

Figura 34- Mapas direcionais representando o espelho nasal de bovinos das duas etapas do experimento.

Através deste resultado podemos compreender melhor quando Baranov et al. (1993), citam que os traços dermatológicos do padrão do focinho do bovino podem ser considerados similares às digitais dos humanos, pois são características desiguais da superfície da pele. Por este motivo podem ser usados para identificar o gado.

5.4 K-nn como Classificador

O resultado da análise dos dados para os vetores de 10 dimensões utilizando o K-nn foi de 63,7% e desvio padrão 5,82% e 70.1% com desvio padrão de 3,77% para os vetores com dimensão 20, sendo ligeiramente superior ao resultado encontrado usando-se o MLP (Figuras 35 e 36).

Figura 35- Comparação da porcentagem de acertos na classificação realizada pela RNA e pelo K-nn para o grupo de dados do primeiro experimento com vetores com dimensão 10.

Figura 36- Comparação da porcentagem de acertos na classificação realizada pela RNA e pelo K-nn para o grupo de dados do primeiro experimento com vetores com dimensão 20.

A figura 37 mostra parte da matriz de distâncias usada pelo k-nn para efetivar a classificação dos padrões de teste.

0	0.7038	1.4006	2.1359	2.8552	3.5883	4.3533	5.5124	
0.7038	0	0.6997	1.4353	2.1534	2.8870	3.6512	4.8107	
1.4006	0.6997	0	0.7401	1.4586	2.1906	2.9545	4.1134	
2.1359	1.4353	0.7401	0	0.7267	1.4573	2.2201	3.3786	
2.8552	2.1534	1.4586	0.7267	0	0.7391	1.5035	2.6621	
3.5883	2.8870	2.1906	1.4573	0.7391	0	0.7799	1.9321	
4.3533	3.6512	2.9545	2.2201	1.5035	0.7799	0	1.1652	
5.5124	4.8107	4.1134	3.3786	2.6621	1.9321	1.1652	0	
6.4886	5.7866	5.0896	4.3544	3.6367	2.9053	2.1367	0.9827	
7.2149	6.5128	5.8157	5.0804	4.3625	3.6306	2.8627	1.7075	
7.8906	7.1885	6.4914	5.7558	5.0381	4.3061	3.5385	2.3813	
8.6441	7.9420	7.2449	6.5094	5.7914	5.0594	4.2916	3.1345	
9.3474	8.6453	7.9482	7.2128	6.4948	5.7623	4.9949	3.8375	
10.4580	9.7561	9.0589	8.3236	7.6054	6.8733	6.1066	4.9485	
11.5547	10.8527	10.1554	9.4201	8.7021	7.9698	7.2020	6.0440	
12.2443	11.5423	10.8450	10.1095	9.3915	8.6591	7.8918	6.7335	
12.9834	12.2814	11.5842	10.8486	10.1307	9.3982	8.6309	7.4727	
13.6782	12.9761	12.2788	11.5434	10.8252	10.0927	9.3255	8.1671	
0.3580	1.0598	1.7574	2.4931	3.2118	3.9451	4.7104	5.8695	
106.8046	106.3425	105.8831	105.4017	104.9230	104.4474	103.9518	103.1837	

Figura 37- Matriz das distâncias gerada pelo classificador k-nn.

A Tabela 4 demonstra o resultado para um grupo de animais para os vetores com 10 dimensões e a Tabela 5 para o mesmo grupo, porém para os vetores com 20 dimensões.

Tabela 4- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pelo K-nn para o grupo de dados dos vetores com dimensão 10.

Saída Desejada\Saída obtida	1 0 0	0 1 0	0 0 1
1 0 0	4	2	0
0 1 0	3	3	0
0 0 1	2	1	6
Média=			61,90%

Tabela 5- Matriz de confusão apresentando a média de acerto na classificação de um grupo de animais através da saída desejada apresentada a rede e a saída fornecida pelo K-nn para o grupo de dados dos vetores com dimensão 20.

Saída Desejada\Saída obtida	1 0 0	0 1 0	0 0 1
1 0 0	5	2	0
0 1 0	3	6	0
0 0 1	2	1	4
Média=			71,42%

As imagens dos animais quando testadas com seus pares de imagem aos 23 meses no Knn apresentam média de acerto de 43,55% e desvio padrão de 8,31% para os vetores com dimensão 10 (Figura 38) e 58,98% associado a desvio padrão de 8,2% para os vetores com dimensão 20 (Figura 39).

Figura 38- Comparação da eficiência do classificador K-nn quando compara-se os grupos de imagens com seus pares aos 23 meses, utilizando o banco de dados de vetores com dimensão 10.

Figura 39- Comparação da eficiência do classificador K-nn quando compara-se os grupos de imagens com seus pares aos 23 meses, utilizando o banco de dados de vetores com dimensão 20.

De uma forma geral, pode-se inferir que a metodologia deixa claro que existe uma diferença visual nos mapas direcionais obtidos após o processamento das imagens, conforme ilustrado na figura 34.

No entanto, o método usado para extrair as características dos dados do mapa direcional, apesar de simples, mostrou-se ineficiente para generalizar as informações dos mapas originais, apesar de ter sido possível diferenciá-los no MLP durante a fase de treinamento. Isto leva a supor que a média das direções angulares das imagens não conserva os padrões observados no mapa direcional e isso explica as taxas de classificação obtidas por ambos os classificadores quais sejam o MLP e o K-nn.

6 CONCLUSÃO

Através dos resultados foi possível obter as seguintes conclusões:

1. A metodologia utilizada para captura das imagens foi bem sucedida aos objetivos do experimento.
2. A escolha da área do espelho nasal para seleção e extração de características foi assertiva, pois através do processamento das imagens verificou-se que diferentes animais possuem diferentes padrões visuais. O resultado do treinamento da rede neural constatou a separabilidade dos mapas direcionais das imagens, validando a hipótese de existência de características únicas, pertencentes ao indivíduo.
3. A metodologia de extração de características utilizada neste trabalho não apresentou resultados que justifiquem seu uso como forma automática de identificação. Contudo, pode-se concluir que mesmo, utilizando tal método extrator é possível realizar a separação dos animais, este fato corrobora a hipótese da existência de padrões únicos do indivíduo na região do espelho nasal capaz de diferenciá-lo dos demais animais de sua espécie. Em pesquisas futuras deve-se abordar uma metodologia de extração de características mais significativa para a classificação dos animais.
4. Devido à baixa taxa de classificação usando a extração das características descrita, a rede neural artificial não generalizou a aprendizagem, obtendo como resposta, um baixo percentual de acertos na classificação dos animais. O mesmo foi observado para o classificador K-nn.

5. A diferenciação entre as idades foi observada e verificada como não prejudicial, ou seja, é um diferencial.

7 REFERÊNCIAS BIBLIOGRÁFICAS

ABICHIT, A. M. Percepções dos consumidores locais sobre a carne bovina certificada e rastreada. **Dissertação (Mestrado)**. Universidade Federal do Rio Grande do Sul. Centro de Estudos e Pesquisas em Agronegócios. Porto Alegre, RS, 2008.

ABIEC. **Importação mundial de carne bovina**. 2010. Disponível em: <http://abiec.com.br/download/stat_mercadomundial.pdf>. Acesso em: 28 outubro 2010.

ABIEC. **Exportações de carne bovina do Brasil, jan-set 2010**. 2010. Disponível em < <http://www.abiec.com.br/download/EXP%20JAN%20-%20SET%2010.pdf>>. Acesso em: 20 fevereiro 2011.

AJIMASTRO JR., C.; PAZ, M. E. da. Identificação Eletrônica. In: 3º CONGRESSO . BRASILEIRO DAS RAÇAS ZEBUÍNAS – A INTEGRAÇÃO DA CADEIA PRODUTIVA. **Anais...** Uberaba, MG. ABCZ, p.167-169, 1998.

ALBUQUERQUE, M. P.; ALBUQUERQUE, M. P. **Processamento de Imagens: Métodos e Análises**. Centro Brasileiro de Pesquisas Físicas – CBPF/MCT. Rio de Janeiro, RJ. 12p., 2010. Disponível em: <<http://www.cbpf.br/cat/pdsi/pdf/ProcessamentoImagens.PDF>>. Acesso em: 20 de janeiro de 2011.

AMORIM, J. **Sistema Nervoso**. Site, Sala de Aula. 2011. Disponível em: <http://www.passeiweb.com/na_ponta_lingua/sala_de_aula/biologia/biologia_animal/sistemas_humanos_sistema_nervoso/sist_nervoso>. Acesso em: 17 de fevereiro de 2011.

ANÔNIMO. **Modelos de Redes Neurais**. Disponível em: <http://www.lncc.br/~labinfo/tutorialRN/frm1_arquitetura.htm>. Acesso em 23 de fevereiro de 2011.

BARANOV, A. S.; GRAML, R.; PIRCHNER, F.; SCHMID, D. O. Breed differences and intra-breed variability of dermatoglyphic pattern of cattle. *Journal of Animal Breeding and Genetics*, v.110, n.5, 1993.

BARCELLOS, M. D. de; FERREIRA, G. C. .Análise de Marcas em Carne Bovina: Adequação entre Oferta e Demanda. **Agroanalysis**, Rio de Janeiro, v.23, n.4, p.1-16, 2003.

BARRETO, J. M. **Introdução às Redes Neurais Artificiais**. Universidade Federal de Santa Catarina, Florianópolis, SC, 57p., 2002. Disponível em: <<http://www.inf.ufsc.br/~barreto/tutoriais/Survey.pdf>>. Acesso em 13 de janeiro de 2011.

BARRY, B.; GONZALES-BARRON, U. A.; MCDONNELL, K.; BUTLER, F.; WARD, S. Using muzzle pattern recognition as a biometric approach for cattle identification. **American Society of Agricultural and Biological Engineers**, v.50, n.3, p. 1073-1080, 2007.

BEZERRA, J. A. Boi com marca de qualidade. **Globo Rural**. São Paulo, ano 17, n. 193, p. 43-49, nov. 2001.

BINFORD, T.O.; JAIN, R.C. **Ignorance, Myopia and naiveté in Computer Vision Systems**. Computer Vision Graphics and Image Processing – vol.53 p.112-117, 1991.

BLANCOU, J. A history of traceability of animals and animal products. **Rev. Sei. Tech. Office des International Epizooties**, v.20, 420p., 2001.

BLOMEKE, C. R.; RUSK, C. P., BALSCHWEID, M. A., ELLIOTT, S. J. Animal identification by retinal imaging and applications for biosecurity (poster). **5th Annual Information Security Symposium**. Purdue University. West Lafayette, Indiana. 2004. Disponível em: <http://www.cerias.purdue.edu/news_and_events/events/symposium/2004/posters/pdfs/Final%20Retinal%20Poster.pdf>. Acesso em: 25 de março de 2010.

CADIMA, J. **Algumas aplicações do Produto Interno Matricial Usual na Análise de Componentes Principais**”, in: A Estatística a Decifrar o Mundo, *Actas do IV Congresso Anual da Sociedade Portuguesa de Estatística*, Edições Salamandra, pg. 273-280, 1997.

CARDOSO E.E.; LIMA E.C.N.Z. **Reuniões técnicas sobre couros e peles.** Documento 127, Embrapa Gado de Corte, 114p., 2002.

CARLIN, N.; SZANTO, E. M.; SEALE, W. A.; JORGE, F. O.; SOUZA, F. A.; BECHTOLD, I.H.; GASQUES, L. R. Processamento de imagens: Conceitos básicos relacionados com o fenômeno de difração e uso de um computador óptico. **Revista Brasileira de Ensino de Física**, v. 26, n. 3, p. 241 - 245, 2004.

CLARK, J.J. Livestock recording systems incorporating eletronic identification methods. In: INTERNATIONAL CONFERENCE ON COMPUTESS IN AGRICULTURE, 6, 1996, Cancun. **Anais...** Cancun: ASAE, 1996. p.428-33.

CORKERY, G.; GONZALES BARRON U. A.; BUTLER, F.; MCDONNELL, K.; WARD, S. A preliminary investigation on face recognition as a biometric identifier of sheep. **Trans. ASABE** 50(1): 313-320, 2007.

CORTEZ, P.; NEVES, J. REDES NEURONAIAS ARTIFICIAIS. Unidade de Ensino, Departamento de Informática, Escola de Engenharia, Universidade do Minho, Braga, Portugal, 52p., 2000.

CUNNINGHAM, E. P.; MEGHEN, C. M. Sistemas de identificación biológica: marcadores genéticos. **Revue Scientifique et Technique Office International des Epizooties**, Paris, v. 20, n. 2, p. 491-499, août 2001.

DANDOLINI, G. A., Um procedimento para avaliação da saúde financeira de pequenas empresas: estudo de um caso usando redes neuronais artificiais. **Dissertação (Mestrado)** – Universidade Federal de Santa Catarina, Florianópolis. 1997.

EBERT, B. Identification of beef animals. **Extension Animal Scientist**, Animal Sciences, Auburn University. YANR-0170, Reprinted July 2006. Disponível em: <<http://www.aces.edu/pubs/docs/Y/YANR-0170/>>. Acesso em : 18 fevereiro 2010.

EIKVIL, L.; TAXT, T.; MOEN, K. **A fast adaptive method for binarization of document images.** Proc First Int'l Conf Document Analysis and Recognition, Saint Malo, France, pp. 435-443, 1991.

EURIDES, D. **Métodos de Contenção de Bovinos**. Rio Grande do Sul, Editora Agropecuária, 1998.

FACON, J. **Binarização de imagens**. Technical Report, PUCPR, 2003. Disponível em: <<http://www.ppgia.pucpr.br/~facon/IndexPrincipalBrBinarizacao.htm>>. Acesso em: 20 de fevereiro de 2011.

FAUSETT, L. **Fundamentals of Neural Networks - Architecture, Algorithms, and Applications**. [S.l.]: Prentice Hall International, Inc., 1994.

FAVERET FILHO, P. PAULA, S.R.L. **Cadeia da carne bovina: o novo ambiente competitivo**. BNDES Setorial. Rio de Janeiro: BNDES, n.6, p.97 -116, setembro de 1997.

FERREIRA, A. B. H. **Dicionário Aurélio Básico da Língua Portuguesa**, 2002.

FERREIRA, L. C. L.; MEIRELLES, M. B. **Avaliação da eficiência de quatro métodos para identificação de bovinos**. Campo Grande: UFMS, 60 p., 2002.

FERRERO, C. A. Algoritmo kNN para previsão de dados temporais: funções de previsão e critérios de seleção de vizinhos próximos aplicados a variáveis ambientais em limnologia . **Dissertação (Mestrado)**. Universidade de São Paulo, Instituto de Ciências Matemáticas e de Computação. São Carlos, 2009.

FORTES, G.; JOSÉ, M. Exame de DNA minimiza margem de erro e evita fraude. **DBO Rural**, São Paulo, n. 255, p. 116, fev. 2002.

FRANCO, M. **Especial rastreabilidade**. DBO Rural, São Paulo, n. 255, p. 102-117, fev. 2002.

FU, K. S.; MUI, J. K. **A survey on image segmentation**. Pattern Recognition, v. 13, p.3-16, 1980.

FUNDEPEC Controle individual de bovinos, passaporte para a UE. **Revista Fundepec**, n.9, abril. p.18-20, 1999.

GHAHRAMANI, Z., HINTON, G. E. The EM Algorithm for Mixtures of Factor Analyzers. **University of Toronto Technical Report CRG-TR-96-1**, 1996.

GONÇALVES, M.; LEMES, M. R.; JUNIOR PINO, A. D., **Redes Neurais Artificiais - Noções Básicas**. Site, Psychiatryonline Brasil. Disponível em: <<http://www.polbr.med.br/ano05/art0205a.php>>. Acesso em: 14 de março de 2011.

GONZALES, R. C.; WOODS, R. E., **Processamento de Imagens Digitais**. Editora Edgard Blücher, 2002.

GOUVEIA, W. R. Detecção de faces humanas em imagens coloridas utilizando redes neurais artificiais. **Dissertação (Mestrado)**. Escola de Engenharia de São Carlos. Universidade de São Paulo. São Carlos, 2008.

GUYON, I. **Neural Networks and application tutorial**. Physics Reports, v.207, p.215-259, 1991

HARALICK, R.M.; SHAPIRO, L.G. **Image Segmentation Techniques**. CVGIP, v. 29, 1985.

HAYKIN, S., **Redes Neurais, Princípios e Prática**. 2.ed. Porto Alegre: Bookman, 2001.

HECHT, E. **Optics**. Adison Wesley Longman, Inc. editors, 3a ed., 1998.

HOPFIELD, J. J., **Neural networks and physical systems with emergent collective computational abilities**. Proc. of the National Academy of Sciences, USA, v. 79, pp. 2554-2558, 1982, Reprinted in [Anderson and Rosenfeld, 1988].

IBGE. **Animais abatidos e peso total das carcaças**. 2010. Disponível em: <<http://www.ibge.gov.br/home/estatistica/indicadores/agropecuaria/producaoagropecuaria/defaulttab.shtm>>. Acesso em: 20 outubro 2010.

JARDIM, W. R. **Bovinocultura**. Campinas: Instituto Campineiro de Ensino Agrícola, 1973. p. 9-26.

JOHNSON, R. A., WICHERN, D. W. **Applied Multivariate Statistical Analysis**. New Jersey: Prentice Hall inc., 4 ed., 1998.

KIMMEL, R.; SHAKED, D.; ELAD, M.; SOBEL, I **Space-dependent color gamut mapping: a variational approach**. IEEE Transactions on Image Processing 14(6): 796-803, 2005.

KOHONEN, T. **The self-organizing map**. Proc. of the IEEE, vol. 78, no. 9, 1990.

KOHONEN, T. **Correlation Matrix Memories**. IEEE C-21 (4), pp. 353-359, 1972.

KORTHALS, R. L.; McDONALD, T. P.; EIGENBERG, R. A. Experiences with transponders for monitoring bioenergetics responses. **ASAE Meeting Presentation**.

KOVÁCS, Z. L. **Redes Neurais Artificias**. Segunda edição, editora Collegium Cognitio, 1996.

KRIVKIN, B. **Pesquisas mostram que a Internet faz bem para o cérebro e para a produtividade**. Disponível em:

<<http://www.portaldofranchising.com.br/site/content/Blogs/interna.asp?codA=4&CodC=24&origem=>>>. Acesso em 27 de março de 2011.

LARA, J. A. F. et al. Rastreabilidade da carne bovina: uma exigência para a segurança alimentar. **Semina: Ciências Agrárias**. Londrina, v. 24, n. 1, p. 143-148, jan./jun. 2003. Disponível em:

<<http://www.uel.br/revistas/uel/index.php/semagrarias/article/view/2138>>. Acesso: em 30 maio 2010.

LIMA, V. M. B. et al. SISBOV: entendendo o passado, planejando o futuro. In: CONGRESSO BRASILEIRO DE ECONOMIA, ADMINISTRAÇÃO E SOCIOLOGIA

RURAL, 45., Londrina, 2007. **Anais eletrônicos...** Londrina: UEL, 2007. Disponível em: <<http://www.sober.org.br/palestra/6/495.pdf>> Acesso em: 23 maio 2010.

LIRANI, A. C., **Rastreabilidade da carne bovina: uma proposta de implementação.** 2001. Disponível em:<http://www.ancp.org.br/Rastreab_Carne%20Segura.htm>. Acesso em: 15 julho de 2010.

LOMBARDI, M.C. Rastreabilidade: exigências sanitárias dos novos mercados. In: III CONGRESSO BRASILEIRO DE RAÇAS ZEBUÍNAS - A integração da cadeia produtiva, 10. , 1998, Uberaba, MG. **Anais...** Uberaba: Associação Brasileira de Criadores de Zebu, 1998. p.90-94.

LOPES, M. A. **Informática aplicada à bovinocultura.** Jaboticabal: FUNEP, 82p., 1997.

LOPES, M. A. **Informática aplicada à medicina veterinária e ao controle animal.** Juiz de Fora: UFJF, Apostila, 2001.

LOPES, M. A.; MARTINS, F. M. Rastreabilidade bovina no Brasil. **Boletim Agropecuário**, Lavras/MG, nº 55, p.1-72, ago. 2003.

MACHADO, J. G. de C. F.; NANTES, J. F. D.; MACHADO, C. G. de C. F. Avaliação de um sistema de identificação eletrônica de animais na rastreabilidade de informações. **Revista Brasileira de Agrocomputação**, Ponta Grossa, v. 1, n. 1, p. 13-21, junho 2010.

MACHADO, J. G. C.; NANTES, J. F. D. **A visão institucional do processo de rastreabilidade da carne bovina.** 2000 a. Disponível em: <http://www.agriculturadigital.org/agritec_2004/congresso/Seg_e_Qual_Aliment_Rastreab/A_Visão_Instit_Rastreabilid_Carne_Bovina.pdf> Acesso em: 12 de maio de 2010.

MARR, D. **Vision.** Freeman, New York, 1982.

MARTIN, N. **Retinal scans eyed for New Mexico show cattle**, 2005. Disponível em: <http://www.eurekalert.org/pub_releases/2005-10/nmsu-rse101905.php>. Acesso em: 3 março 2010

MENDES, R. E. O impacto financeiro da rastreabilidade em sistemas de produção de bovinos no Estado de Santa Catarina, Brasil. **Ciência Rural**, Santa Maria, v.36, n.5, p. 1524-1528, set-out, 2006.

MINAGAWA, H.; FUJIMURA, T.; ICHIYANAGI, M.; TANAKA, K. **Identification of beef cattle by analyzing images of their muzzle patterns lifted on paper**. p. 596-600. 2002 Disponível em: <<http://zoushoku.narc.affrc.go.jp/ADR/AFITA/afita/afita-conf/2002/part8/p596.pdf>>. Acesso em: 15 janeiro 2010.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO (MAPA). Disponível em: <<http://www.agricultura.gov.br/SISBOV>>. Acesso em: 29 agosto 2010.

MISHRA, S.; TOMER, O. S.; KALM, E. Muzzle dermatoglyphics: A new method to identify bovines. **Asian Livestock**, p. 91-96, 1995a.

MOTA, E. G. Origem e desenvolvimento do sistema brasileiro de rastreabilidade bovina - SISBOV. **Tese (doutorado)**. Faculdade de Agronomia e Medicina Veterinária. Universidade de Brasília. Brasília, DF. 79p. 2008.

MOURA, A. P. Identificação e Rastreabilidade de Produtos de Origem Animal ao Longo da Cadeia Alimentar. **Dissertação (Mestrado)** - Instituto de Ciências Biomédicas Abel Salazar, Universidade do Porto, Portugal, 2010.

MULVIHILL, B. **Tracking and tracing cattle, sheep and meat**. Replay Research For The Food Industry, October, 2008. Disponível em: <www.relayresearch.ie/dochandler/rel_dochandler.asp?id=469>. Acesso em: 24 outubro 2010.

MURAKAMI, E.; SARAIVA, A. M. Rastreabilidade da informação nas cadeias produtivas: padrões de troca de dados. **Revista Brasileira de Agroinformática**, v. 7, n. 1, p.58-66, 2005. Disponível em: <www.sbiagro.org.br/pdf/revista/RBIAgro-v7n1-artigo5.pdf>. Acesso em 25 maio 2010.

NÄÄS, I. A.; CURTO, F. P. F.; PEREIRA, D. F.; AMENDOLA, M. A. TRANSPONDERS FOR DETERMINING BREEDER BEHAVIOR VERSUS ENVIRONMENTAL TEMPERATURE. **VI Livestock Enviroment**, v. 06, p. 626-631, 2001.

NANTES, J. F. D.; MACHADO, J. G. C. F. Segurança dos alimentos e rastreabilidade: o caso da carne bovina no Brasil. In: BATALHA, M. O. **Gestão do agronegócio: textos selecionados**. São Carlos: EdUFSCar, 2005. cap. 8, p. 369 - 423.

NEVES, S. C. M.; PELAES, E. G. ESTUDO E IMPLEMENTAÇÃO DE TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS. **Revista Virtual de Iniciação Acadêmica da UFPA**, v. 1, n. 2, julho 2001. Disponível em: <http://www.ufpa.br/rcientifica/ed_anteriores/pdf/ed_02_scmn.pdf>. Acesso em 2 de fevereiro de 2011.

NILSSON, N. J. **Artificial Intelligence: A New Synthesis**. San Francisco: Morgan Kaufmann Publishers, Inc. 1998.

OECD-FAO Agricultural Outlook 2008-2017. 2008. Disponível em: <<http://www.fao.org/es/ESC/common/ecg/550/en/AgOut2017E.pdf>>. Acesso em: 7 agosto 2010.

OIE. Animal identification and product traceability from the farm to the fork must be progressively implemented worldwide. Disponível em: <<http://www.vetscite.org/publish/items/004454/index.html#>>. Acesso em 10 de fevereiro de 2010.

PACHECO, F. E. O boi entra na era dos chips. **A Granja**, Porto Alegre, p.42-43, mar. 1995.

PANDORFI, H.; SILVA, I. J. O.; SEVEGNANI, K. B.; CARO, I. W. Locais de implante de microchips de identificação eletrônica de leitões: seleção e validação por análise de imagem. **Eng. Agríc. Jaboticabal**, Jaboticabal, v. 25, n.1 , p.1-9, 2005.

PANDEY, S. N. Muzzle printometry in bovines. **Indian J. Animal Sci.**, v.49, n.12, p.1038-1042 , 1979.

Paredes, R.; Vidal, E. **Learning Weighted Metrics to Minimize Nearest-Neighbor Classification Error**. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.28, no.7, pp. 1100-1110, july 2006.

PIRES, P. P. IDENTIFICAÇÃO ELETRÔNICA E RASTREAMENTO DE BOVINOS. Embrapa, n. 49, ago. 2001. Disponível em: <<http://www.cnpqc.embrapa.br/publicacoes/divulga/GCD49.html>>. Acesso em: 15 de setembro de 2010.

POSTON, W. L., MARCHETTE, D. J. Recursive dimensionality reduction using Fisher's linear discriminant. *Pattern Recognition*, v. 31, Issue: 7, p. 881-888, 1998.

PRÁ JUNIOR, J. V. D. Coleta de dados para um sistema de rastreabilidade de suínos. **PDAExpert**, 2006. Disponível em: <<http://pdaexpert.net/arquivos/superwaba/>>. Acesso em: 30 de abril de 2010.

RAUBER, T. W. **Redes Neurais Artificiais**. Disponível em: <<http://www.lia.ufc.br/~eti/2003/menu/modulos/RNA/RNA-RedesNeuraisArtificiaisII.pdf>>. Acesso em: 9 de janeiro de 2011.

Regulamento (CE) n.º 178/2002, Traceability Laws, **European Commission (EC) guidance on Articles 11, 12 and 16 – 20 of the General Food Law Regulation EC 178/2002**. COMMISSION OF THE EUROPEAN COMMUNITIES, 25.7.2001. Disponível em: <<http://www.opsi.gov.uk/si/si2004/20043279.htm>>. Acesso em: 12 julho 2010.

REZENDE, E. H. S.; LOPES, M. A. Identificação, certificação e rastreabilidade na cadeia da carne bovina e bubalina no Brasil. **Boletim Agropecuário da Universidade Federal de Lavras** n. 58, 2004. Disponível em: <http://www.editora.ufla.br/site/_adm/upload/boletim/bol_58.pdf>. Acesso em 13 de maio de 2010.

RIES, L. **Rastreabilidade X Realidade**. [S.l.: s.n.], 2002.

RIJSWIJK, W. V., FREWER, L. J., MENOZZI, D., FAIOLI, G. Consumer perceptions of traceability: A cross-national comparison of the associated benefits. **Food Quality and Preference, Marketing and Consumer Behaviour**, Wageningen, The Netherlands. Reference: FQAP 2044, 2008.

ROCHA, H, J. **Rastreabilidade**, a nova chave para ganhos de credibilidade junto aos mercados consumidores, 17 nov. 2001. Disponível em: <www.agronegocios-e.com.br>. Acesso em 13 maio de 2010.

ROCHA, J. L. P; LOPES, M. A. RASTREABILIDADE E CERTIFICAÇÃO DA PRODUÇÃO DA CARNE BOVINA: UM COMPARATIVO ENTRE ALGUNS SISTEMAS. **Nota Técnica**. Revista Brasileira de Agroinformática, v.4, n.2, p.130-146, 2002.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, p.386–408, 1958.

ROSENFELD, A. Image Analysis and Computer Vision. **Computer Vision Graphics and Image Processing**, v. 59, p.367-404, 1993.

RUMELHART, D. E.; MCCLELLAND, J. L. & GROUP, P. **Parallel Distributed Processing**, v. 1: Foundations. The MIT Press, 1986.

SMITH, G. C., TATUM, J. D.; BELK, K. E.; SCANGA, J. A.; GRANDIN, T.; SOFOS, J. N. Traceability from a US perspective. **Meat Sci.**71(1): 174-193, 2005.

RODRIGUES, L. C.; NANTES, J. F. D. RASTREABILIDADE NA CADEIA PRODUTIVA DA CARNE BOVINA: situação atual, dificuldades e perspectivas para o Brasil. **Informações Econômicas**, SP, v.40, n.6, p. 31- 40, jun. 2010.

ROSENBLATT, F. **The perceptron: A probabilistic model for information storage and organization in the Brain**. Psychological Review, vol. 65, p. 386-408, 1958.

ROSENFELD, A. **Image Analysis and Computer Vision**. Computer Vision Graphics and Image Processing, vol 59, p.367-404, 1993

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J., **Learning internal representations by error Propagation**, in Rumelhart, D. E., and McClelland, J. L. (eds.), Parallel Distributed Processing: Explorations in the Microstructure of Cognition I, pp. 318-362, MIT Press, Cambridge MA, 1986.

SCHIEFER, G., **Environmental Management and Life-Cycle Assessment in Supply Chains Management** – The Case of the Meat Chain - Proceedings of the X World Food and Agribusiness Congress of the International Food and Agribusiness Management Association – IAMA, Chicago (USA), June, p. 24-28, 2000.

SCURI, A. E. **Fundamentos da Imagem Digital**, 1999. Disponível em: <http://3180888957367859277-a-1802744773732722657-s-sites.googlegroups.com/site/gcamarac/bcc-326---processamento-de-imagens/apostila20imagem20digital.pdf?attachauth=ANoY7coe2FN6uxlZR5UyCXXxhF3aueGNP0kIL1x3UI3CUrrSxXeHZlgVB61ndiymgHiC3syc24z2iinbayF7H8rgc7ZxiTiUV22sl-DrZP2WRdAIXXL3BMyk-Yl6ZC6b5_R1kluabxvaLk9aZWZVGihJK7rxN2NT8KQqb9IS2mcl96Zi6voAA-Yj1cOjBUVA1t46uZwarssskBD9Jc-rbmqlfZVKOkSBY8GQyTKzn2ceet0Ex1YsrB1fyoKOz629KSVP6t7ve5Cl&attredirects=0>. Acesso em: 02 de maio de 2011.

SHADDUCK, J. A.; GOLDEN, B. L. **Retinal imaging in secure identification and source verification of livestock**. In: Proceedings ID/INFO Expo 2002, Natural Institute for Animal Agriculture, IL, USA, 2002.

SILVA, K. O, NÄÄS, I.A., Avaliação do Uso de Identificadores Eletrônicos em Suínos, Eng. **Agríc. Jaboticabal**, v.26, n.1, p.11-19, jan./abr. 2006.

SILVA, K. O. VIABILIDADE DO USO DA RASTREABILIDADE ELETRÔNICA NA PRODUÇÃO DE SUÍNOS. **Tese (Doutorado)** - Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola. Campinas, SP: [s.n.], 2004.

SILVA, R. R. RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM EM RADIOGRAFIAS INDUSTRIAIS. **Tese (Doutorado)** – Universidade Federal do Rio de Janeiro, COPPE. Rio de Janeiro, RJ. 2003.

STÄRK, K. et al. Comparasion of eletronic and visual identification, systems in pigs. **Livestock Production Science**, Amsterdam, v. 53, p. 143-158, 1998.

YASSU, F. Brasil assume a liderança mundial. **DBO Rural**, n. 280, p. 30, mar., 2004

TATIBANA, C. Y.; KAETSU, D. Y. **Histórico das redes neurais**. Disponível em: <<http://www.din.uem.br/ia/neurais/>>. Acesso em: 17 de fevereiro de 2011.

THERRIEN, C.; TRONCO, M. Biometria e Identificação Civil: Aspéctos Técnicos e Questões Jurídicas. **Diário Jurídico**, n. 05, 2004.

WANG, H. **Nearest Neighbor by Neighborhood Counting**, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.28, no.6, pp. 942-953, june 2006.

WEBB, A. R. **Statistical Pattern Recognition**. 2. ed. Chichester: John Wiley & Sons, 2002.

WHITE PAPER ON FOOD SAFETY **Commission of the European Communities**, 2000. Disponível em:
<http://ec.europa.eu/dgs/health_consumer/library/pub/pub06_en.pdf>. Acesso em: 15 setembro 2010.

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

WILSON, D. R.; MARTINEZ, T. R. **Improved Heterogeneous Distance Functions**, J. Artificial Intelligence Research, vol.6, pp.1-34, 1997.

8 ANEXO

8.1 Anexo 1- Algoritmo do Primeiro Programa de Processamento de Imagens

```
function varargout = focinho(varargin)
% FOCINHO M-file for focinho.fig

%     FOCINHO, by itself, creates a new FOCINHO or raises the existing
%     singleton*.

%
%     H = FOCINHO returns the handle to a new FOCINHO or the handle to
%     the existing singleton*.

%
%     FOCINHO('CALLBACK',hObject,eventData,handles,...) calls the local
%     function named CALLBACK in FOCINHO.M with the given input arguments.
%
%     FOCINHO('Property','Value',...) creates a new FOCINHO or raises the
%     existing singleton*. Starting from the left, property value pairs
are
%     applied to the GUI before focinho_OpeningFcn gets called. An
%     unrecognized property name or invalid value makes property
application
%     stop. All inputs are passed to focinho_OpeningFcn via varargin.

%
%     *See GUI Options on GUIDE's Tools menu. Choose "GUI allows only one
%     instance to run (singleton)".

%
% See also: GUIDE, GUIDATA, GUIHANDLES

% Edit the above text to modify the response to help focinho
```

```

% Last Modified by GUIDE v2.5 16-Sep-2010 00:15:19

% Begin initialization code - DO NOT EDIT

gui_Singleton = 1;

gui_State = struct('gui_Name',       mfilename, ...
                  'gui_Singleton',   gui_Singleton, ...
                  'gui_OpeningFcn', @focinho_OpeningFcn, ...
                  'gui_OutputFcn',  @focinho_OutputFcn, ...
                  'gui_LayoutFcn',  [] , ...
                  'gui_Callback',    []);

if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargout
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end

% End initialization code - DO NOT EDIT

% --- Executes just before focinho is made visible.
function focinho_OpeningFcn(hObject, eventdata, handles, varargin)
% This function has no output args, see OutputFcn.
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles     structure with handles and user data (see GUIDATA)
% varargin    command line arguments to focinho (see VARARGIN)

% Choose default command line output for focinho
handles.output = hObject;

```

```

% Update handles structure
guidata(hObject, handles);

% UIWAIT makes fcinho wait for user response (see UIRESUME)
% uiwait(handles.figure1);

% --- Outputs from this function are returned to the command line.
function varargout = fcinho_OutputFcn(hObject, eventdata, handles)

% varargout  cell array for returning output args (see VARARGOUT);
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Get default command line output from handles structure
varargout{1} = handles.output;

% --- Executes on button press in pushbutton1.
function pushbutton1_Callback(hObject, eventdata, handles)

% hObject    handle to pushbutton1 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% --- Executes on button press in pushbutton2.
function pushbutton2_Callback(hObject, eventdata, handles)

% hObject    handle to pushbutton2 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

```

```

function bloco_Callback(hObject, eventdata, handles)

% hObject      handle to bloco (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

% handles      structure with handles and user data (see GUIDATA)


% Hints: get(hObject,'String') returns contents of bloco as text
%          str2double(get(hObject,'String')) returns contents of bloco as a
double

% --- Executes during object creation, after setting all properties.
function bloco_CreateFcn(hObject, eventdata, handles)

% hObject      handle to bloco (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

% handles      empty - handles not created until after all CreateFcns called


% Hint: edit controls usually have a white background on Windows.
%          See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

% -----

function Untitled_2_Callback(hObject, eventdata, handles)

% hObject      handle to Untitled_2 (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

% handles      structure with handles and user data (see GUIDATA)

% -----

function Untitled_1_Callback(hObject, eventdata, handles)

% hObject      handle to Untitled_1 (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

```

```

% handles      structure with handles and user data (see GUIDATA)

% -----

function uipushtool1_ClickedCallback(hObject, eventdata, handles)

% hObject      handle to uipushtool1 (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

% handles      structure with handles and user data (see GUIDATA)

% -----

function Abrir_Callback(hObject, eventdata, handles)

% hObject      handle to Abrir (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

% handles      structure with handles and user data (see GUIDATA)

im=LeImagem;

axes(handles.grafico1);

set(handles.uipanel2,'Visible','on');

set(handles.Som,'Visible','on');

set(handles.equa,'Visible','on');

set(handles.direcao,'Visible','on');

set(handles.bloco,'Visible','on');

set(handles.limiar,'Visible','on');

set(handles.seg,'Visible','on');

set(handles.filtro,'Visible','on');

imagesc(im);

if (isgray(im)==1)

MM = 255-double(im);

```

```

else
    p = ginput(2);
    sp(1) = min(floor(p(1)), floor(p(2)));
    sp(2) = min(floor(p(3)), floor(p(4)));
    sp(3) = max(ceil(p(1)), ceil(p(2)));
    sp(4) = max(ceil(p(3)), ceil(p(4)));
    MM = rgb2gray(im(sp(2):sp(4), sp(1): sp(3),:));
    MM = 255-double(MM);
end

set(handles.Tgrafico2,'String','Figura selecionada');
set(handles.text3,'String','Tamanho do Bloco');
axes(handles.grafico2);
colormap(gray);
set(hObject,'UserData',MM);%disponibiliza a imagem MM para ser
                             %usada em outras callbacks

imagesc(MM);

% -----
function Untitled_4_Callback(hObject, eventdata, handles)
% hObject    handle to Untitled_4 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% -----
function Untitled_5_Callback(hObject, eventdata, handles)
% hObject    handle to Untitled_5 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% --- Executes on button press in direcao.

```

```

function direcao_Callback(hObject, eventdata, handles)

% hObject      handle to direcao (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

% handles      structure with handles and user data (see GUIDATA)


B=str2num(get(handles.bloco,'String'));

B2=str2num(get(handles.limiar,'String'));

axes(handles.grafico1);colormap(gray);

MM=get(handles.Abrir,'UserData'); %pega a imagem do callback abrir

status = get(handles.equa,'Value');%pega o status

segmta = get(handles.seg,'Value');%segmenta??

tipo_s = get(handles.sobel,'Value');

if (status == 1)

MM=histeq(uint8(MM));

end

if ( segmta== 1)

    if(tipo_s==1)

        MM = edge(MM,'sobel',B2,'nothinning');

    else

        MM = edge(MM,'log',B2,'nothinning');

    end

end

end

imagesc(MM);

axes(handles.grafico2);%manipula o grafico da direita

set(handles.Tgrafico2,'String','Mapa Direcional');

colormap(gray);

@wait_noninterruptible;

[olBound,olArea,centro]=mapadirecional(MM,B);

```

```

set(hObject,'UserData',MM);

set(handles.Salvar,'UserData',centro);

%trata angulo

% --- Executes on button press in direcao.

function pushbutton4_Callback(hObject, eventdata, handles)

% hObject    handle to direcao (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     structure with handles and user data (see GUIDATA)


% --- Executes on button press in equa.

function equa_Callback(hObject, eventdata, handles)

% hObject    handle to equa (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     structure with handles and user data (see GUIDATA)


% Hint: get(hObject,'Value') returns toggle state of equa


% --- Executes on button press in Transforma.

function Transforma_Callback(hObject, eventdata, handles)

% hObject    handle to Transforma (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     structure with handles and user data (see GUIDATA)

MM=get(handles.Abrir,'UserData');


% --- Executes on button press in Som.

function Som_Callback(hObject, eventdata, handles)

% hObject    handle to Som (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     structure with handles and user data (see GUIDATA)

```



```

% --- Executes on button press in MlpTr.

function MlpTr_Callback(hObject, eventdata, handles)

% hObject    handle to MlpTr (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     structure with handles and user data (see GUIDATA)


% --- Executes on button press in seg.

function seg_Callback(hObject, eventdata, handles)

% hObject    handle to seg (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     structure with handles and user data (see GUIDATA)


% Hint: get(hObject,'Value') returns toggle state of seg


function limiar_Callback(hObject, eventdata, handles)

% hObject    handle to limiar (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     structure with handles and user data (see GUIDATA)


% Hints: get(hObject,'String') returns contents of limiar as text

%          str2double(get(hObject,'String')) returns contents of limiar as a
double


% --- Executes during object creation, after setting all properties.

function limiar_CreateFcn(hObject, eventdata, handles)

% hObject    handle to limiar (see GCBO)

% eventdata  reserved - to be defined in a future version of MATLAB

% handles     empty - handles not created until after all CreateFcns called

```

```

% Hint: edit controls usually have a white background on Windows.

%         See ISPC and COMPUTER.

if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))

    set(hObject,'BackgroundColor','white');

end

% --- Executes on button press in Salvar.

function Salvar_Callback(hObject, eventdata, handles)

% hObject      handle to Salvar (see GCBO)

% eventdata    reserved - to be defined in a future version of MATLAB

% handles      structure with handles and user data (see GUIDATA)


i = get(handles.cont,'String');
MM=get(handles.direcao,'UserData'); %pega a imagem do callback direcao
C= get(handles.Salvar,'UserData');

segmta = get(handles.seg,'Value');% verifica se a imagem foi segmentada
nomearq = get(handles.edit5,'String');% pegou??
arq = get(handles.edit5,'String');

if segmta==1

    nomearq = strcat(nomearq,'_seg', num2str(i),'.jpg')
    arq =  strcat('M',arq,'_seg', num2str(i),'.dat')
else

    nomearq = strcat(nomearq,'_co',num2str(i) ,'.jpg')
    arq =  strcat('M',arq,'_seg', num2str(i),'.dat')

    MM = uint8(MM);

end

set(handles.cont,'String',str2num(i)+1);

imwrite(MM, nomearq, 'jpg');

fid = fopen(arq,'wt');
```

```
fprintf(fid,'%4.3f\n', C(:,3));
```

```
fclose(fid)
```

```
function edit4_Callback(hObject, eventdata, handles)
```

```
% hObject    handle to edit4 (see GCBO)
```

```
% eventdata  reserved - to be defined in a future version of MATLAB
```

```
% handles    structure with handles and user data (see GUIDATA)
```

```
% Hints: get(hObject,'String') returns contents of edit4 as text
```

```
%          str2double(get(hObject,'String')) returns contents of edit4 as a  
double
```

```
% --- Executes during object creation, after setting all properties.
```

```
function edit4_CreateFcn(hObject, eventdata, handles)
```

```
% hObject    handle to edit4 (see GCBO)
```

```
% eventdata  reserved - to be defined in a future version of MATLAB
```

```
% handles    empty - handles not created until after all CreateFcns called
```

```
% Hint: edit controls usually have a white background on Windows.
```

```
%          See ISPC and COMPUTER.
```

```
if ispc && isequal(get(hObject,'BackgroundColor'),  
get(0,'defaultUicontrolBackgroundColor'))
```

```
    set(hObject,'BackgroundColor','white');
```

```
end
```

```
function edit5_Callback(hObject, eventdata, handles)
```

```
% hObject    handle to edit5 (see GCBO)
```

```
% eventdata  reserved - to be defined in a future version of MATLAB
```

```
% handles    structure with handles and user data (see GUIDATA)
```

```
% Hints: get(hObject,'String') returns contents of edit5 as text
```

```

%          str2double(get(hObject,'String')) returns contents of edit5 as a
double

% --- Executes during object creation, after setting all properties.
function edit5_CreateFcn(hObject, eventdata, handles)
% hObject    handle to edit5 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% Hint: edit controls usually have a white background on Windows.
%          See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

% --- Executes on button press in pushbutton11.
function pushbutton11_Callback(hObject, eventdata, handles)
% hObject    handle to pushbutton11 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
set(handles.cont,'String',1);

```

8.2 Anexo 2- Algoritmo do Segundo Programa de Processamento de Imagem

```

function gera_angulos(nomearq, ini,fim)

% calcula as 10 primeiros angulos do mapa direcional

% versao 0.1 data 15/agosto/2007

%versao 0.2 23/Agosto/2007

% Uso: se o arqwuivo cahma teste15081 ate teste150823

% entao ter-se-a : SndSpcAn('teste',15081,150823) coreespondendo

% a 23 arquivos do tipo teste

c=1;

for i =0:(fim-ini) % le os arquivos *.wav e salva na matriz

    a=num2str(i+ini);

    x=load(strcat(nomearq,a,'.dat'));

    %calcular o espctrum para cada arquivo e armazenar em uma matriz

    X=angulos(x);

    Matr(:,c)= X;

    %figure;plot(Mat(:,c));

    c = c+1;

end;

Matr=Matr';

tt=size(Mat);

str=strcat(nomearq,num2str(ini),'_f.dat');

fid = fopen(str, 'wt');

for (i = 1:tt(1))

    for(j = 1:tt(2))

        fprintf(fid, '%2.4f ', Matr(i,j));

    end

    fprintf(fid, '\n');
```

```

        end

fclose(fid);

end

function vetangulo = angulos(x)

vet=0;

i=0;

e = size(x);

numpontos = e(1);

for i = 1:12

    soma(i)=0;

    cont(i)=0;

end

for j = 1:numpontos

    if x(j)< pi/12;

        soma(1)=soma(1)+x(j);

        cont(1)=cont(1)+1;

    else

        if ((x(j)>=pi/12)&&(x(j)<2*pi/12))

            soma(2)=soma(2)+x(j);

            cont(2)=cont(2)+1;

        else

            if ((x(j)>=2*pi/12)&&(x(j)<3*pi/12))

                soma(3)=soma(3)+x(j);

                cont(3)=cont(3)+1;

            else

                if ((x(j)>=3*pi/12)&&(x(j)<4*pi/12))

                    soma(4)=soma(4)+x(j);

                    cont(4)=cont(4)+1;

                else

                    if ((x(j)>=4*pi/12)&&(x(j)<5*pi/12))

```

```

soma(5)=soma(5)+x(j);

cont(5)=cont(5)+1;

else

if((x(j)>=5*pi/12)&&(x(j)<6*pi/12))

    soma(6)=soma(6)+x(j);

    cont(6)=cont(6)+1;

else

    if((x(j)>=6*pi/12)&&(x(j)<7*pi/12))

        soma(7)=soma(7)+x(j);

        cont(7)=cont(7)+1;

    else

        if((x(j)>=7*pi/12)&&(x(j)<9*pi/12))

            soma(8)=soma(8)+x(j);

            cont(8)=cont(8)+1;

        else

            if((x(j)>=9*pi/12)&&(x(j)<10*pi/12))

                soma(9)=soma(9)+x(j);

                cont(9)=cont(9)+1;

            else

                if((x(j)>=10*pi/12)&&(x(j)<11*pi/12))

                    soma(10)=soma(10)+x(j);

                    cont(10)=cont(10)+1;

                else

                    if((x(j)>=11*pi/12)&&(x(j)<pi))

                        soma(11)=soma(11)+x(j);

                        cont(11)=cont(11)+1;

                    else

                        soma(12)=soma(12)+x(j);

```


8.3 Anexo 3- Algoritmo do Classificador K-nn

```
%script para o classificador k-nn
load boil_6_40k;

bt4=boil_6_40k(4,:);
ebt4=dist(X,bt4');%gera matriz de distâncias
for i = 1 : 21
    bt(:,i)=boil_6_40k(i,:);
end
for i = 1 : 21
    p1(i)=0;
    p2(i)=0;
    p2(i)=0;
end
size(X)

ebt=dist(X,bt)

m=min(ebt)
size(m)
limiar =0;
%procura por k vizinhos
for i=1:21
    pp = (1.4*m(i)+m(i))/0.4;
    limiar =pp;
    p1(i)=0;
    p2(i)=0;
    p3(i)=0;

    for j=1:9
        if ebt(j,i)<= limiar

            p1(i)=p1(i)+1;

        end
    end

    for j=10:18
        if ebt(j,i)<=limiar
            p2(i)=p2(1)+1;

        end
    end

    for j=19:27
        if ebt(j,i)<=limiar
            p3(i)=p3(i)+1;
        end
    end
end
end
```