

Universidade Católica Dom Bosco

Centro de Ciências Exatas e Tecnológicas Curso de Engenharia de Computação

Segmentação e Reconhecimento Baseado em Textura: Técnicas e Ferramentas

Wagner Belotti Leal

Hemerson Pistori

Relatório Final submetido como um dos requisitos para a obtenção do grau de Engenheiro de Computação.

UCDB - Campo Grande - MS - DEZEMBRO/2006

Agradecimentos

Agradeço em primeiro lugar a DEUS por me conceder tudo o que tenho e pela graça de ser chamado de seu filho. À minha família, em especial aos meus pais, que concederam meus estudos e entenderam meus momentos de dificuldade, sempre me apoiando. Agradeço meu orientador Hemerson Pistori, que sempre me mostrou o melhor caminho a seguir para a realização de um ótimo projeto de graduação, ao corpo docente da UCDB e ao grupo de pesquisa do projeto DTCOURO, em especial à Mariana Aragão, pesquisadora da EMBRAPA-MS, que contribuiu na primeira etapa deste trabalho. Agradeço aos meus amigos de classe, por todos os momentos de descontração, em especial, ao Guilherme Baganha, pelos momentos de discussões que nunca chegavam a uma conclusão porque ninguém dava o braço a torcer, pela companhia nas madrugadas de monografia e trabalhos e pela força, tendo sempre a mesma fé. Ao meu amigo João Humberto, pelas correções ortográficas, e à minha namorada Helenice Stela por sempre acreditar em mim e me dar força. Agradeço ao povo guarani que inventou o tereré, que me manteve acordado em muitas noites de pesquisa e escrita deste projeto. São tantos nomes a agradecer, porém eu agradeco a Jesus por me conceder pessoas que me ajudaram de várias as maneiras para a finalização deste projeto.

Resumo

O método atual de classificação do couro bovino é realizado visualmente. A visão computacional sugere várias técnicas e ferramentas para a realização deste trabalho e estas técnicas mostram várias formas para o reconhecimento e classificação do couro. O objetivo é que o sistema DTCOURO 1 se torne realidade em toda a cadeia do couro, desde o produtor até o curtume. O sistema DTCOURO trata de um projeto em realização entre a UCDB ² e a EMBRAPA-MS gado de corte; este projeto tem a finalidade de criar um sistema objetivo de classificação do couro bovino. O sistema atual de classificação de couro é somente realizado no curtume e essa classificação ocorre da seguinte maneira: os compradores de couro enviam uma pessoa capacitada a classificar o couro no curtume, a qual escolhe as peças de couro de acordo com a classificação que necessita e logo após é negociado o valor com o curtume. Através de técnicas de segmentação e reconhecimento, é possível classificar as peças de couro bovino com maior rapidez. Este projeto de graduação teve o objetivo de mostrar as principais técnicas de segmentação e reconhecimento baseadas em textura e implementar um módulo que realiza a extração das características e separa as classes dos defeitos no couro bovino, que também é parte integrante do sistema DTCOURO.

¹Detecç
cão Automática de Defeitos em Peles e Couros Bovinos

²Universidade Católica Dom Bosco

Abstract

The method of bovine leather's classification is the manual approach, realized visually. The computer vision provides several techniques and tools for the accomplishment of this work, with different methods for the leather's defect recognition. The DTCOURO³ system has the objective to act in all the leather's production chain, since the producer until the tannery. However, nowadays, the leather is classified just in the tannery, and this classification occurs in the following way: the leather's purchasers send a person able to classify the leather in the tannery, and this person chooses the leather parts in accordance with the classification that it needs, and a value is negotiated with the tannery. Through the techniques of segmentation and recognition, will be possible to classify the bovine leather parts quickly. This graduation project has the objective to show to the main techniques of segmentation and recognition based on texture, and to implement one module that it extracts the characteristics and separates the classes of defects on the bovine leather, which is integrant part of the system DTCOURO.

³Automatic Detection of Defects in Skins and Bovine Leathers

Conteúdo

| 1 Introdução | | |
|--------------|--------------|---|
| 2 | Rev | risão de Literatura |
| | 2.1 | Fundamentação Teórica |
| | | 2.1.1 Imagem Digital e Transformação para Tons de Cinza . |
| | | 2.1.2 Textura |
| | | 2.1.3 Técnicas de Segmentação |
| | 2.2 | DTCOURO |
| | 2.3 | Trabalhos Correlatos |
| | | 2.3.1 Identificação de Defeitos no Couro |
| | | 2.3.2 Utilizando Características de Textura para Identi- |
| | | ficação de Tecidos em Imagens Médicas |
| | | 2.3.3 Seleção de Características do Couro para Reconheci- |
| | | mento de Defeitos |
| 3 | Som | mentação e Reconhecimento Baseado em Textura |
| 3 | 3.1 | Matriz de Co-ocorrência |
| | $3.1 \\ 3.2$ | Classificação |
| | 0.2 | Classificação |
| 4 | Imp | olementação |
| | 4.1 | Método de Aquisição das Imagens e Montagem do Banco de |
| | | Imagens |
| | 4.2 | Extração das Características |
| | 4.3 | Classificador |
| 5 | Evr | perimentos, Resultados e Análise dos Resultados |
| J | 5.1 | Material Utilizado e Experimentos |
| | 9.1 | 5.1.1 Material Utilizado |
| | | 5.1.2 Experimentos |
| | 5.2 | Resultados |
| | 5.2 5.3 | Análise dos Resultados |
| | | ATTALISE UUS TESIIITAUUS |

| Conteúdo | CCET - UCI |
|----------|------------|
| Conteúdo | CCET - UCI |

| 6 | Cor | clusão e Trabalhos Futuros 6 | 66 |
|--------------|-------|------------------------------|----|
| | 6.1 | Conclusão | 66 |
| | 6.2 | Trabalhos Futuros | 66 |
| \mathbf{R} | eferê | icias Bibliográficas | 38 |

Lista de Figuras

| 1.1 | Princípio da visão Computacional | 11 |
|------|--------------------------------------|----|
| 1.2 | Fases de Processamento do Couro | 13 |
| 1.3 | Marca Fogo - Original | 15 |
| 1.4 | | 15 |
| 1.5 | | 16 |
| 1.6 | | 17 |
| 2.1 | 8 | 24 |
| 2.2 | Foto Couro - Binarizada - Limiar 54 | 24 |
| 2.3 | Foto Couro - Binarizada - Limiar 120 | 24 |
| 2.4 | | 24 |
| 2.5 | Histograma - Limiar 54 | 24 |
| 2.6 | 0 | 24 |
| 2.7 | Histograma - Limiar 140 | 24 |
| 2.8 | Dinâmica do Crescimento de Regiões | 26 |
| 2.9 | Algoritmo da Análise da Imagem | 33 |
| 2.10 | Exemplo de Histograma | 37 |
| 3.1 | 0 | 40 |
| 3.2 | | 43 |
| 3.3 | Extração de Características | 44 |
| 4.1 | 1 1 | 48 |
| 4.2 | 1 | 49 |
| 4.3 | 3 | 50 |
| 4.4 | 1 | 50 |
| 4.5 | Gerador de Amostras | 51 |
| 4.6 | 1 | 52 |
| 4.7 | ± | 53 |
| 4.8 | Configuração do Weka | 54 |
| 4.9 | Excução dos Algoritmos | 55 |

| T | ista | de | Figur | ลร |
|---|------|----|-------|-------------------|
| L | nsta | uc | rigui | $a_{\mathcal{D}}$ |

CCET - UCDB

| 4.10 | Análise dos Resultados | 55 |
|------|--------------------------------------|----|
| 5.1 | Couro Wet-Blue (1) | 58 |
| 5.2 | Couro Wet-Blue (2) | 58 |
| | Valores dos Pixels (1) | |
| 5.4 | Valores dos Pixel (2) | 58 |
| | Validação Cruzada (Cross-Validation) | |
| 5.6 | Amostra Carrapato | 64 |
| 5.7 | Amostra Furo de Esfola | 64 |
| 5.8 | Amostra Sarna | 65 |
| 5.9 | Amostra Sem Defeito | 65 |

Lista de Tabelas

| 1.1 | Valores Agregados ao Couro | 12 |
|-----|---|----|
| 1.2 | Relação Entre Produção de Couros e Empregos | 12 |
| 2.1 | Opereador de Sobel | 28 |
| 2.2 | 0° - Horizontal | 29 |
| 2.3 | 45° - Diagonal Direita | 29 |
| 2.4 | 90° Vertical | 30 |
| 2.5 | 135° - Diagonal Esquerda | 30 |
| 2.6 | Descritores de textura | 34 |
| 2.7 | Resultados | 36 |
| 3.1 | Imagem em tons de cinza | 41 |
| 5.1 | Legenda dos Classificadores | 60 |
| 5.2 | Tabela de resultados do primeiro conjunto de amostras (3 Cou- | |
| | ros Cru) | 61 |
| 5.3 | Matriz de Confusão - Primeiro Conjunto | 61 |
| 5.4 | Tabela de resultados do segundo conjunto de amostras (7 Cou- | |
| | ros Wet-Blue) | 61 |
| 5.5 | Matriz de Confusão - Segundo Conjunto | 62 |
| 5.6 | Tabela de resultados do terceiro conjunto de amostras (1 | |
| | Couro Wet-Blue) | 62 |
| 5.7 | Matriz de Confusão - Terceiro Conjunto | 62 |
| 5.8 | Melhores Resultados dos Algoritmos | 63 |

Capítulo 1

Introdução

A visão computacional tem um papel cada vez mais relevante para o homem, na medida em que ela passa a colaborar em diversas tarefas essenciais. As aplicações destas técnicas expandiram-se em várias áreas tais como: diagnóstico médico, automatização de fábricas e sistemas de segurança, sensoriamento remoto, movimentação automática de robôs e veículos [43]. Trata-se de uma área de pesquisa multidisciplinar, e onde os conhecimentos de computação além de fundamentais, são aplicados extensivamente. Define-se a visão computacional como a construção de descrições explícitas e significativas de objetos físicos nas imagens [5]. O princípio básico da visão computacional é descrito na Figura 1.1, o processamento e análise de imagens são o núcleo da visão computacional, com vários algoritmos e métodos para alcançar a classificação e medidas estabelecidas [30]. Motivado pela gama de soluções disponíveis na visão computacional, e pela parceria do Centro de Pesquisa de Gado de Corte da Embrapa - Mato Grosso do Sul 1 com o projeto de melhoramento do couro bovino, surgiu o projeto DTCOURO ², que coloca-se como instrumento de ajuda, para promover o desenvolvimento tecnológico do sistema de classificação da cadeia produtiva de couros e derivados. Neste projeto sistema desenvolvido especificamente serviu para analisar imagens de couro e classificá-las de acordo com o sistema determinado.

No mercado Brasileiro de couro bovino, apenas 8% do couro produzido é comercializado como de primeira qualidade, e uma das principais causas da perda da qualidade é a infestação por carrapatos e bernes [33]. A baixa qualidade do couro provoca um crescimento limitado no setor coureiro, reduzindo a agregação de valores ao produto e sua comercialização no exterior. O esforço conjunto dos demais elos (produtor, frigorífico e curtume) representa

 $^{^1{\}rm Empresa}$ Brasileira de Pesquisa Agropecuária - Setor de Gado de Corte. (http://www.cnpgc.embrapa.gov.br)

²Detecção Automática de Defeitos em Couro Bovino

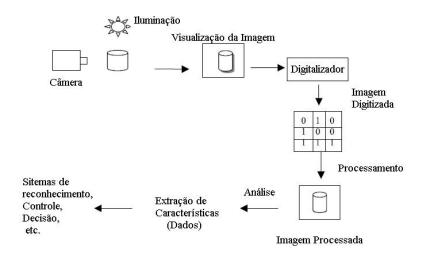


Figura 1.1: Princípio da visão Computacional

uma condição essencial e complementar, cujo objetivo é reestruturar da cadeia produtiva, aumentando o desenvolvimento do setor coureiro, tornando-o mais competitivo e com um grande potencial gerador de divisas e empregos.

O comércio do couro bovino ocorre, em geral, da seguinte maneira: o produtor (fazendeiro) comercializa o bovino pelo método de arrobas, sendo que o couro e outras partes do animal como cabeça, patas, chifre e outros, estão inclusos no preço da arroba do boi, porém, essas partes são retiradas antes da pesagem. O couro, no Brasil, representa 6% do preço do boi em pé ³. Uma arroba bovina equivalente a 14.69Kg era comercializada no Brasil por uma média de R\$50,00 em 10/08/2005 ⁴. Do frigorífico para o curtume (lugar onde o couro é curtido, e onde ocorrem os estágios de tratamento e inicia a agregação de valores ao couro, devido seu processamento), o couro é comercializado, no Brasil, pelo método conhecido como *Bica Corrida* ⁵. Neste método, o couro é repassado sem qualquer análise de defeitos ou classificação, sendo vendido por peso. Devido a falta de um sistema de classificação, o preço do couro brasileiro sofre uma desvalorização de quase 50% na sua comercialização no mercado dos países concorrentes ⁶. A Tabela 1.1 ⁷

³http://www.unifolha.com.br/Materia/?id=2411

⁴http://www.agrolink.com.br

⁵O termo "bica corrida" é utilizado para denominar sistemas de comercialização em que não há sistema de classificação das mercadorias. Uma de suas conseqüências é não proporcionar um prêmio adequado aos produtos de qualidade superior.

⁶http://www.faeal.org.br/princ_notic_27.htm

⁷Fonte: http://www.cnpgc.embrapa.br

mostra a escada de valores agregados em cada estágio do couro.

| Estágio de | Valor Atual | % | % |
|--------------------------------|-------------|---------------------|----------------|
| $\mathbf{Processamento}(Und.)$ | (US\$) | $\mathbf{Agregado}$ | Agregado(M.Q.) |
| CouroFresco | 24,00 | 100% | |
| CouroFresco(M.Q.) | 34,00 | | 100% |
| CouroWetBlue | 48,00 | 200% | |
| CouroWetBlue(M.Q.) | 55,00 | | 162% |
| Couro A cabado | 70,00 | 292% | |
| CouroAcabado(M.Q.) | 85,00 | | 250% |
| Couro Manu fatura do | 240,00 | 1000% | |
| Couro Manu fatura do (M.Q.) | 300,00 | | 882% |

^{*(}M.Q.) - Melhor Qualidade

Tabela 1.1: Valores Agregados ao Couro

Na Tabela 1.1 temos os couros de *Melhor Qualidade*, representando os couros comercializados em países concorrentes mais desenvolvidos; e os outros couros, representando a parte dos couros comercializados no Brasil. Cada valor é referente a uma unidade de couro inteiro. A participação do produtor rural no crescimento do setor é proporcional à qualidade da matéria-prima. Podemos visualizar na Tabela 1.2 ⁸ uma relação da produção com o número de empregos gerados.

| Produção de 1.000 Couros/Dia | Números de Empregos Gerados |
|------------------------------|-----------------------------|
| CouroFresco | 10 |
| CouroWetBlue | 40 |
| Couro A cabado | 100 |
| Couro Manu fatura do | 2.000 |

Tabela 1.2: Relação Entre Produção de Couros e Empregos

O processamento do couro começa no curtume, onde o couro recebe um tratamento inicial, que é o curtimento do couro. Nessa fase o couro passa por processos químicos para retirada dos pêlos, e logo após apresenta um estágio intermediário denominado "tripa", o qual passa por outro processo para retirar algumas aparas desnecessárias do couro. Logo após este estágio, o couro passa por mais alguns processos químicos e então chega no estágio WetBlue. Com o couro em WetBlue conseguimos perceber visivelmente todos os seus defeitos. Logo após, o couro recebe uma classificação (subjetiva)

⁸Fonte: http://www.cnpgc.embrapa.br

para a sua comercialização com empresas que realizam as próximas etapas da cadeia do couro. A classificação é feita, na maioria das vezes, por um especialista em couros da empresa interessada na compra. Na maioria das vezes não é necessário que o couro seja 100% livre de defeitos para que seja comercializável, mas isso é definido pelo classificador, que ajusta um preço junto ao dono do curtume. Isto se repete nessa cadeia agregando valor ao couro à medida que se avança, até que o produto final chegue às lojas. Na Figura 1.2 ⁹ podemos visualizar as fases de processamento do couro desde o abate do bovino até o produto manufaturado.

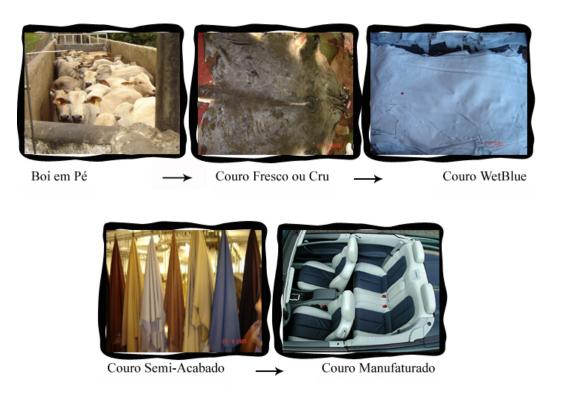


Figura 1.2: Fases de Processamento do Couro

Na cadeia do couro, principalmente na forma wetblue, observamos que o método de classificação é subjetivo, este método se dá porque não há uma regra para classificação de couros wetblue estabelecida nacionalmente. Primeiramente é necessário estabelecer uma regra para uma classificação objetiva, porém, este é o principal objetivo do projeto de melhoramento do couro realizado pela Embrapa. O objetivo do projeto DTCOURO, realizado pelo

⁹Fonte: http://www.serafim.com.gr

GPEC ¹⁰ da UCDB e juntamente com a Empraba Gado de Corte, é a criação de uma sistema automático que analise as imagens do couro, reconheça os defeitos e estabeleça uma classificação para cada peça de couro. A análise das imagens tem como objetivo os três primeiros estágios do couro: boi em pé, frigorífico, e wetblue.

Este projeto de graduação tem como principal objetivo a escolha de uma técnica para a realização da fase de segmentação defeitos e classificação do couro, que será implementada na forma de um módulo (plug-in), o qual será integrado ao sistema DTCOURO. Este módulo é responsável por analisar as imagens, extrair informações através do algoritmo de extração de características, agrupar as informações extraídas de modo a formar classes e em seguida classificá-las.

Cada defeito na imagem determina uma classe, mas primeiramente a imagem passa por um processo de segmentação. O objetivo da segmentação é obter a partir de uma imagem adquirida (digitalizada), um conjunto de primitivas ou segmentos significativos que contém as informações necessárias em relação à imagem original. A segmentação pode ser definida como a divisão da imagem em fragmentos, segmentos ou regiões, cada qual sendo homogênea em algum sentido. A disposição dos pixels ¹¹ para cada região da imagem será homogênea se as regiões analisadas não exibirem nenhuma grande mudança na forma como estão dispostos os atributos da imagem, nas regiões [39]. O problema em questão não se concentra somente em separar o objeto do fundo e nem apenas fazer sua divisão em regiões, mas identificar e separar no couro todos os defeitos presentes. Na segmentação utilizando textura encontramos muitas técnicas, cada uma projetada para uma aplicação particular. Entretanto, nenhum método geral é eficaz em todas as situações [39]. Tendo em vista que não necessitamos de um método geral, e que este projeto é algo muito recente, necessitamos de um método que nos permite extrair o máximo de informações necessárias para a segmentação e classificação dos defeitos.

A segmentação baseada em textura apresenta dificuldades, quando não se conhece, a priori, quais os tipos de textura existem na imagem, ou quantos tipos diferentes de texturas existem, ou ainda quais regiões da imagem possuem uma determinada textura [12]. Existem várias técnicas de segmentação de imagens na literatura, como: segmentação por agrupamento [45], segmentação baseada em pixel [22], segmentação por crescimento de regiões [10], entre outras. Quaisquer umas das técnicas citadas acima podem utilizar a textura como informação para extração de características, porém, isso irá

¹⁰Grupo de Pesquisa em Engenharia e Computação

¹¹Abreviatura de Elemento de Imagem (Picture Element) - É o menor ponto de luz cuja cor e luminosidade podem ser controladas na tela. As imagens são formadas com a combinação de grande número de pixels

depender de como essa informação irá solucionar o problema em questão.

As Figuras 1.3 e 1.4 mostram, respectivamente, as imagens do couro fresco com uma marca a fogo em destaque, e a segmentação dessa imagem, separando cada textura como uma classe contida na imagem, sendo elas: o defeito em vermelho, o couro bom em verde e o que não é couro em azul.





Figura 1.3: Marca Fogo - Original Figura 1.4: Marca Fogo - Segmentado

Visualmente as texturas de uma imagem são facilmente reconhecidas, porém definir textura é uma tarefa difícil. A seguir são citadas algumas definições de textura encontradas na literatura [12]:

- "Muitas vezes a textura é considerada como sendo constituída de uma região. A estrutura da textura é simplesmente formada da repetição de padrões no quais os elementos ou primitivas são arranjadas de acordo com uma regra local."
- "Uma região em uma imagem tem uma textura constante se um conjunto local de estatísticas ou se outras propriedades da figura são constantes, variam muito pouco, ou periodicamente."

A textura tem uma propriedade importante na percepção de regiões e superfícies contendo informações sobre a distribuição espacial das variações de tonalidade dos objetos [42]. Abordamos neste projeto a textura como principal característica, pois, as imagens dos couros apresentam texturas complexas e sua superfície apresenta características exclusivas em cada tipo de defeito, facilitando desta maneira o processo de segmentação das imagens.

O sistema de classificação é baseado nas características extraídas dos defeitos das imagens analisadas. As características são extraídas com base na textura, pois como podemos visualizar na Figura 1.5, a forma que a textura toma na região dos defeitos é diferente (visualmente falando), das demais

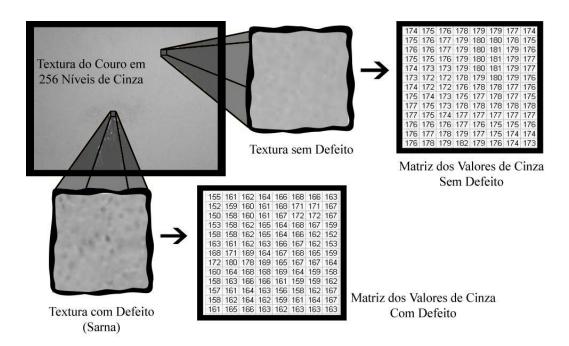


Figura 1.5: Textura no Couro - Tons de Cinza

regiões do couro. Esta é uma propriedade exclusiva dos sistemas que utilizam a textura como base para segmentação e reconhecimento.

Cada defeito é caracterizado por um tipo de textura, na Figura 1.6 podemos visualizar uma ampliação de uma marca na peça de couro.

Nesta pesquisa foram aplicadas algumas métricas básicas para seleção das técnicas de reconhecimento e classificação dos defeitos no couro, baseando-se principalmente: no estudo de técnicas de visão computacional para detecção de defeitos no couro utilizada por outros grupos de pesquisa no mundo, técnicas de segmentação e classificação de imagens baseada em textura, escolha e implementação de uma técnica e por ultimo, análise de resultados do sistema. Além das métricas acima, também foi utilizada a ferramenta ImageJ¹². Esta é uma ferramenta de código-livre, escrita na linguagem Java e disponível para várias plataformas, porém, sua principal característica é a sua grande utilização no meio científico e acadêmico, em processamento de imagens, e com isso o constante desenvolvimento e melhoramento de plugins e novidades para esta ferramenta.

Foi construído também um banco de imagens através de visitas a alguns curtumes no estado do Mato Grosso do Sul, proporcionado pela parceria com a EMBRAPA-MS. Nessas visitas, primeiramente o couro foi analisado e suas

¹²http://rsb.info.nih.gov/ij/



Figura 1.6: Couro Fresco com Defeito

características anotadas. Logo após foram fotografadas as regiões afetadas e também toda a área do couro. Foi utilizada uma câmera fotográfica digital com a resolução de 4.1 MegaPixels.

Após a fase da construção do banco de imagens, foram separadas e classificadas manualmente, pela equipe especializada da Embrapa, as imagens e seus respectivos defeitos, para serem utilizadas no teste do sistema proposto. Após a implementação do sistema, foram realizados os testes, com base no banco de imagens previamente classificado.

A organização do texto ocorre como segue a seqüência: o Capítulo 2 trata da revisão de literatura, sendo sua primeira seção, a fundamentação teórica, logo após, uma seção sobre o DTCOURO e por último os trabalhos correlatos. O Capítulo 3 trata da segmentação e reconhecimento baseados em textura, tendo em sua primeira seção a matriz de co-ocorrência, e na segunda seção a classificação. O Capítulo 4 mostra os detalhes sobre os métodos e ferramentas utilizados para implementação do módulo, sua primeira seção trata do método de geração de amostras, a segunda seção trata do método de extração das características, e a terceira dos classificadores utilizados. O

Capítulo 5 apresenta os experimentos, os resultados e a análise dos resultados, cada um respectivamente em sua seção. Finalmente, o Capítulo 6 descreve as conclusões obtidas com este trabalho e os trabalhos sugeridos para futuras pesquisas em cima deste projeto.

Capítulo 2

Revisão de Literatura

Neste capítulo é apresentada primeiramente uma introdução sobre imagem digital, a transformação de imagens coloridas para tons de cinza, algumas características da textura e um relato inicial das técnicas de segmentação. Na seção 2.1 são ligeiramente descritos a visão computacional e o processamento de imagens, duas áreas de extrema importância para esta pesquisa. Na subseção 2.1.1 apresentamos uma breve introdução sobre imagem digital e a transformação do sistema de cor RGB para tons de cinza, sendo essa a parte inicial do processamento de imagens. Na subseção 2.1.2 destacamos a textura e a grande quantidade de parâmetros que podem ser extraídos utilizando as técnicas de processamento de imagens. Na subseção 2.1.3 é tratada a segmentação de uma forma geral, também é definida sua importância no processamento de imagens e são apresentadas algumas de suas técnicas. Na seção 2.2 tratamos do DTCOURO, serão esclarecidos mais profundamente a problemática do couro bovino, quais os benefícios da classificação do couro, e o que o couro representa na realização deste projeto. Na seção 2.3 são apresentados alguns trabalhos que contém relação com a principal técnica que é abordada neste projeto.

2.1 Fundamentação Teórica

O processamento de imagens é responsável pela representação ou descrição de um objeto, pessoa ou cena, trazendo informações computacionalmente mensuráveis através de distribuições da intensidade (valor) dos pixels. Esta técnica caminha juntamente com a visão computacional, e elas podem ser definidas, juntamente, como o conjunto de métodos e técnicas através dos quais sistemas computacionais podem ser capazes de interpretar imagens. A interpretação de uma imagem, em termos computacionais, é a transformação

do conjunto de dados digitais em uma imagem, em uma estrutura de dados. Tanto as imagens quanto os conjuntos de dados são avaliados por seres humanos [46].

2.1.1 Imagem Digital e Transformação para Tons de Cinza

A imagem capturada pelo olho humano ou por qualquer aparelho, tem natureza contínua [46]. Para que a imagem possa ser armazenada e manipulada pelo computador é necessário que ela esteja em formato digital, ou seja, transformada em uma seqüência de bits, que têm natureza discreta, podendo assumir valor 0 ou 1.

As imagens digitais são compostas por pixels, e a quantidade de bits utilizada por pixel depende basicamente da profundidade de cores da imagem. Quando a imagem utiliza o espaço de cor RGB ¹ a representação utilizada é a de 8 bits para cada banda, fazendo um total de 24 bits por pixel. Com isso é possível gerar mais de 16 milhões de cores diferentes. Para imagens em tons de cinza é comum utilizar 8 bits para cada pixel, totalizando 256 níveis possíveis de cinza. Já as imagens binárias necessitam apenas de um bit por pixel, totalizando duas cores. Para realizar a conversão de uma imagem em RGB para tons de cinza (8-bit ou 256 níveis de cinza) normalmente é feita a média dos valores de cada banda:

$$c(x,y) = \frac{I_R(x,y) + I_G(x,y) + I_B(x,y)}{3}$$
 (2.1)

onde c(x, y) é o nível de cinza da imagem de destino, $I_R(x, y)$, $I_G(x, y)$, $I_B(x, y)$ são os níveis da bandas R, G e B, respectivamente. Os três canais de cores do RGB são transformados em apenas um canal, ou em uma image com 256 níveis de cinza(8-bit).

2.1.2 Textura

A textura é uma característica qualitativa dos materiais que constituem objetos dos mais diferentes tipos, sejam eles naturais ou sintetizados por algum processo industrial. Apesar de conhecida e intuitiva, a definição desta

¹(Red, Green, Blue ou Vermelho, Verde, Azul) Trata-se de um modelo de visualização de cores, baseado em luz, largamente usado em sistemas de vídeo, câmeras de vídeo e monitores de computador. O sistema representa todas as cores como uma combinação dessas três. O RGB é o modo mais comum de manipulação de imagens nos monitores de computador.

característica não possui, de fato, uma versão formal e bem estabelecida. Alguns autores a descrevem de acordo com suas percepções pessoais ou mesmo conforme encontram para ela utilidade em suas aplicações. A seguir são apresentados alguns exemplos:

- "Textura é um atributo que representa o arranjo espacial dos tons de cinza dos pixels em uma região [27]".
- "Textura se refere à repetição de elementos básicos da imagem chamados textels². A distribuição dos textels pode ser periódica ou aleatória. As texturas naturais geralmente possuem um comportamento aleatório, sendo que as artificiais possuem um comportamento periódico e determinístico." [28]
- "Padrões que caracterizam objetos em uma cena são chamados texturas." [28]

O estudo das texturas, de acordo com processamento de imagens, é divido em três grandes categorias: a segmentação por textura, a classificação de texturas e a síntese de texturas. A classificação dos métodos de segmentação por textura pode ocorrer da seguinte maneria:

- Métodos estruturais
- Métodos estatísticos
- Métodos baseados em modelos

A abordagem estrutural é aplicada na classificação e segmentação de imagens que possuem texturas com uma certa homogeneidade. Neste caso elas se compõem por um arranjo repetitivo de elementos estruturais denominados textels.

Os métodos estatísticos ou métodos baseados em características, seguem uma abordagem em etapas, que são geralmente três:

- 1. Extração de características das texturas;
- 2. Seleção ou redução do número de características caso haja um número muito grande delas;
- 3. Utilização de um algoritmo de classificação.

²Uma única unidade gráfica que dá a origem, repetida, a uma textura

A grande desvantagem destes métodos está relacionada com a extração de características. Normalmente esta etapa demanda grande quantidade de processamento e grande quantidade de memória para armazenar as estruturas utilizadas [44].

Os métodos baseados na utilização de modelos constituem uma categoria cuja utilização se estende a praticamente qualquer tipo de textura. Existem basicamente dois tipos de modelos utilizados nesta abordagem: os modelos fractais e os modelos estocásticos [38]. Estes dois modelos são apenas citados para nível de conhecimento de sua existência, é encontrado mais sobre estas técnicas em [38].

2.1.3 Técnicas de Segmentação

A segmentação de imagens é um processo que permite subdividir uma imagem em diversas partes ou regiões significativas [21]. O processo gera regiões descritas pelas suas características espaciais e espectrais, e à medida que cada região é adquirida, ela é rotulada e seus atributos estatísticos são extraídos [7]. Uma região R_i na imagem é um conjunto de pontos circundados por um limite fechado de comprimento finito [34]. Uma segmentação do domínio R_i de uma imagem é um conjunto finito de regiões, tal que: R é a união de R_i e a interseção entre R_i e R_j é igual a zero para todo i diferente de i [5].

Em geral, a segmentação é baseada em duas características dos tons de cinza de uma imagem: a descontinuidade e a similaridade. O método da descontinuidade baseia-se na mudança abrupta dos valores de cinza e o método da similaridade fundamenta-se pela agregação de pixels em função da sua semelhança com os pixels vizinhos [21]. Ainda no caso de a imagem não estar em tons de cinza, mas em algum formato de cor ex.: RGB, HSV ³ e outros, seus componentes como: brilho, contraste ou até mesmo uma ou mais componentes do formato de cor, também poderão ser utilizados. As técnicas que utilizam o reconhecimento de bordas (contornos) ou extrai parâmetros da textura, também podem utilizar imagens coloridas ou não [10].

Serão apresentadas algumas técnicas de segmentação e elas serão divididas em dois grupos: as técnicas baseadas em similaridades e as técnicas baseadas em descontinuidades.

³(Hue, Saturation, Value ou Matiz, Saturação e Valor) são usados para descrever a cor de um pixel. A matiz é a cor básica determinada pela sua freqüência ou comprimento de onda da luz. A saturação é controlada pela quantidade da cor branca adicionada à cor básica. O valor é o valor da escala de cinza ou a nível de cor preta adicionada a um pixel.

Técnicas Baseadas em Similaridades

1. Limiarização (Thresholding) - O processo de limiarização consiste em separar as regiões de uma imagem quando esta apresenta duas classes (o fundo e o objeto). As técnicas para isso são as mais simples, pois não levam em conta o contexto, ou seja, a vizinhança dos pixels não é analisada. Basicamente, o algoritmo de limiarização deve primeiramente definir um ou mais limiares de separação, a partir do(s) qual(is) as regiões serão segmentadas. Uma aplicação básica onde esta técnica pode ser utilizada é binarização de imagens, que transforma uma imagem com diversos tons de cor em uma imagem com apenas dois tons, processo normalmente utilizado para converter uma imagem em tons de cinza para preto e branco. O processo de binarização é a forma mais simples e geral de limiarização e consiste na bipartição do histograma, convertendo os pixels cujo tom de cinza é maior ou igual a um determinado valor de limiar (T) em brancos e os demais em pretos. Matematicamente, esta operação pode ser descrita dessa forma: a entrada de uma imagem f(x,y) de N níveis de cinza é transformada a fim de se obter uma imagem de saída g(x,y), chamada limiarizada, cujo número de níveis de cinzas é menor que N. No caso de conversão para preto e branco, q(x,y) apresenta 2 níveis de cinza:

$$g(x,y) = \begin{cases} 255 & \text{se} \quad f(x,y) \ge T \\ 0 & \text{se} \quad f(x,y) < T \end{cases}$$

onde: o pixel = 255 corresponde ao(s) objeto(s), o pixel = 0 corresponde ao fundo e T é um valor de nível de cinza predefinido (limiar ou threshold). Sabe-se que a escolha de um limiar que melhor segmente a imagem é um desafio. Em casos práticos, não se adota um limiar para a imagem toda, pois os níveis de cinza podem sofrer variações bruscas, causando perda de informação [20]. Podemos visualizar este processo nas Figuras 2.2, 2.3 e 2.4 tratadas com valores diferentes de limiar de binarização. Os limiares foram estabelecidos utilizando a ferramenta ImageJ, definidos aleatoriamente de modo que as três figuras resultantes pudessem demonstrar a diferença entre os limiares estabelecidos, são eles: 54, 120, 140, respectivamente apresentados nas Figuras 2.2, 2.3 e 2.4. Logo após estão representados nas Figuras 2.5, 2.6, 2.7, respectivamente, os histogramas relativos às binarizações.

2. Crescimento de Regiões - Os algoritmos de crescimento de regiões, em geral, realizam uma busca por grupos de pixels com alguma propriedade similar, caracterizando os pixels com essas propriedades similares



Figura 2.1: Foto do couro original



Figura 2.2: Foto Couro - Figura 2.3: Foto Couro - Figura 2.4: Foto Couro - Binarizada - Limiar 54 - Binarizada - Limiar 120 - Binarizada - Limiar 140

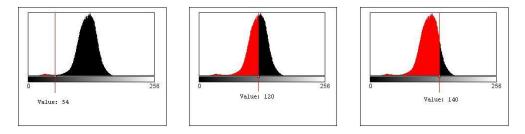


Figura 2.5: Histograma Figura 2.6: Histograma Figura 2.7: Histograma - Limiar 54 - Limiar 120 - Limiar 140

como pertencentes a uma mesma região. Este método escolhe um pixel inicial, conhecido como semente, e a partir dele examina seus vizinhos numa sequência para decidir se eles possuem alguma semelhança, baseado no critério de similaridade escolhido. Se os pixels vizinhos analisados forem aceitos como similares, então serão agrupados ao pixel inicial para formar uma região. Desta maneira, formam-se as regiões a

partir de pixels sementes. O processo termina quando não houver mais pontos que satisfaçam o critério de similaridade.

O crescimento das regiões pode ser feito a partir dos pontos vizinhos da borda das regiões utilizando um critério de semelhança cuja forma mais simples é a diferença total entre os níveis de cinza dos pontos da borda das regiões e seus vizinhos [23]. Os operadores simples, baseados apenas num critério de vizinhança, podem dar resultados ruins com maior freqüência, pois uma região M pode ligar-se a uma outra região N devido apenas à diferença existente entre um ponto da borda da região M e seu vizinho na região N.

Uma forma de agrupamento que evita esse problema foi introduzida por Brice [9]. A técnica pode ser resumida da seguinte forma:

- Na primeira etapa do processo, pares de pontos vizinhos são ligados para formar um conjunto, que são chamados regiões atômicas, se eles têm o mesmo valor de cinza. Em outras palavras, se eles têm a mesma intensidade e são vizinhos, então eles formarão regiões conexas.
- A segunda etapa, é conhecida pelos autores como heurística da fagocitose, regiões maiores devem absorver as regiões menores segundo o seguinte critério:

Sendo $|P_1|$ e $|P_2|$ os comprimentos das bordas das regiões $R_1 \subset E$ e $R_2 \subset E$, respectivamente. Seja |I| o comprimento da fronteira I entre R_1 e R_2 . Seja |W| o comprimento das partes "fracas" da fronteira, o comprimento de $W \subset I$ onde a diferença absoluta entre os níveis de cinza de R_1 e R_2 através da fronteira é menor do que um certo \in_1 . Desta forma, duas regiões, R_1 e R_2 , são ligadas se:

$$\frac{|W|}{min\{|P_1|\},\{|P_2|\}} > \in_2 \quad onde \in_2 = \frac{1}{2}, usual mente.$$

Se \in_2 é pequeno, duas regiões podem juntar-se com facilidade. Se, ao contrário, ele é grande, só quando uma região praticamente envolver a outra é que elas serão agrupadas.

• Na terceira etapa, regiões adjacentes cuja fronteira é fraca, ou seja, têm vários pontos cuja diferença absoluta entre os níveis de cinza através da fronteira é menor do que E_1 , são ligadas desta maneira:

Esta técnica produz resultados satisfatórios, desde que as imagens e

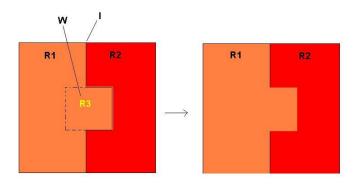


Figura 2.8: Dinâmica do Crescimento de Regiões

regiões não sejam muito complexas, não tenham muitos objetos a serem segmentados e possuam pouca textura [9].

3. Aglomeração (Clustering) - A segmentação por aglomeração refere-se ao agrupamento de um dado conjunto de objetos em subconjuntos de acordo com as características de cada objeto, porém é computacionalmente "pesado". Essa técnica atua sobre um espaço chamado espaço de atributos [25], que representa um espaço de dimensão elevada no qual cada ponto da imagem é representado por um vetor de atributos. Atributo é o nome dado a uma medida feita sobre a imagem, tais como: tamanho de objetos na imagem, desvio padrão, componentes de um sistema de cores (RGB, HSB, etc) entre outros.

O vetor de atributos é dado por $x = [x_1, x_2, ..., x_n]^T$, onde n representa a dimensão do espaço de atributos e x_i é o valor do i-ésimo atributo de uma determinada localização do pixel. Um espaço de atributos é um plano cartesiano em que cada eixo representa um atributo diferente.

A técnica abordada é dividida em dois estágios onde primeiramente são calculados os vetores de atributos e segundo é determinado o número ótimo de aglomerados, segundo um critério de proximidade dos centros de aglomeração [15]. O algoritmo utilizado propõe, primeiramente, aglomerar todos os M vetores em torno de dois centros (que podem ser escolhidos aleatoriamente dentre os M vetores), segundo a distância do vetor ao centro mais próximo dele. Após isso, o número de centros aumentará de uma posição, e um fator de qualidade β será computado a cada iteração até que ele alcance um valor máximo igual a um (que fornecerá o número K ótimo de aglomerados). A cada etapa seguinte, o centro do novo aglomerado a ser criado será o ponto que possui a maior distância ao centro do aglomerado, dentre os aglomerados atuais.

O cálculo do fator de qualidade β é feito da seguinte maneira. Sejam:

M o número de pontos a serem aglomerados;

K o número de aglomerados atual;

 M_k o número de pontos do aglomerado;

 A_k (k-ésimo aglomerado);

 X_i um vetor de características, $1 \le i \le N$;

 μ_0 o vetor médio de todos os vetores, dado por
: $\mu_0 = \frac{1}{M} \sum_{i=1}^M X_i$

 μ_k a média dos vetores de A_k

 S_k o conjunto dos elementos de A_k

 S_W e S_B , duas matrizes de espalhamento (Within e Between, respectivamente) dadas por:

$$S_W = \frac{1}{K} \sum_{k=1}^{K} \frac{1}{M_k} \sum_{X_i \in S_k} [X_i - \mu_k] [X_i - \mu_k]^T$$

$$S_B = \frac{1}{K} \sum_{k=1}^{K} \left[\mu_k - \mu_0 \right] \left[\mu_k - \mu_0 \right]^T$$

onde \mathbf{u}^T é o vetor transposto de \mathbf{u} . Finalmente,

$$\beta = tr \left[S_W \right] tr \left[S_B \right]$$

onde tr é o traço da matriz ou a soma dos elementos da diagonal da matriz. Depois de aglomerados, um conjunto de aglomerados formam os segmentos da imagem.

Técnicas Baseadas em Descontinuidades

Nas técnicas baseadas em descontinuidades os objetos que podem ser localizados são de três tipos: pontos, linhas e bordas. Essas técnicas são definidas por uma operação orientada à vizinhança. Operações lógicas e aritméticas orientadas à vizinhança utilizam o conceito de convolução com máscaras (janelas, templates, kernel, masks) [11], [16]. A cada posição relativa da máscara sobre a imagem, o pixel central da subimagem em questão será substituído, em uma matriz denominada imagem destino, pela soma dos produtos dos coeficientes com os níveis de cinza contidos na sub-região envolvida pela máscara.

1. Detecção de Arestas ou Bordas - Dá-se o nome de aresta ou borda aos pontos de uma imagem pertencentes à fronteira entre regiões que

tenham níveis de cinza diferenciados entre si. Do cálculo diferencial sabemos que os operadores diferenciais, por exemplo o gradiente, são adequados para detectar mudanças na inclinação de curvas ou superfícies [3].

Na função $f: \Re^2 \longrightarrow \Re^2$, o gradiente de f é dado pelo vetor:

$$\nabla f(x,y) = (\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y})$$

Geometricamente, ele é um vetor que aponta na direção de maior crescimento de f no ponto (x, y) e seu módulo (que é a informação importante na detecção de arestas) é proporcional à intensidade do crescimento de f.

Para uma imagem digital $f \in K^E$, o módulo do gradiente pode ser aproximado pelo operador [20],

$$|\nabla f| \cong \left| \frac{\partial f}{\partial x} \right| + \left| \frac{\partial f}{\partial x} \right| \cong \left[(w_7 + 2w_8 + w_9 - (w_1 + 2w_2 + w_3)) \right] + \left[(w_3 + 2w_6 + w_9) - (w_1 + 2w_4 + w_7) \right]$$

Os termos entre colchetes são denominados *operadores de sobel*. Eles podem ser vistos na Tabela 2.1.

| -1 | -2 | -1 | |
|----|----|----|--|
| 0 | 0 | 0 | |
| 1 | 2 | 1 | |

| -1 | 0 | 1 |
|----|---|---|
| -2 | 0 | 2 |
| -1 | 0 | 1 |

Tabela 2.1: Opereador de Sobel

2. Detecção de Pontos Isolados - O conceito de ponto isolado em uma imagem binária é simples e a sua segmentação também. Definimos ponto isolado um ponto $p \in E$ tal que f(p) = 1 e $f(q) = 0, \forall q \in N_G(p)$

$$\Psi(f)(x) = \sum_{i=1}^{9} w - if(x_i)$$
(2.2)

Na segmentação de um ponto isolado, primeiramente usa-se um operador local que o destaque em relação aos outros. O operador definido pela equação (2.2) com os pesos w_i dados por $w_5 = 8$ e

 $w_1 = -1, 1 \le i \le 9, i \ne 5$, aplicado à imagem binária $f(x) \in [0,1]^2$ resulta em uma imagem em níveis de cinza onde todo ponto isolado vale oito (ex.: $\Psi(f)(x) = 8$, caso x seja um ponto isolado) e $\Psi(f)(x) < 8$, caso contrário.

Para completar a segmentação destes pontos, basta aplicar uma limiarização que segmente os pontos cujo valor seja igual a oito.

Pontos isolados em imagens de níveis de cinza têm um conceito um pouco diferente, dizemos que um ponto é isolado quando seu valor difere consideravelmente de seus vizinhos e não, simplesmente, quando todos os seus vizinhos são nulos. O operador que será aplicado à imagem pode ser o mesmo que é aplicado para imagens binárias, mas o limiar dependerá da diferença de níveis de cinza entre o ponto e seus vizinhos que considerarmos suficiente para tratá-lo como isolado.

Exemplo de uma máscara para detecção de diferentes pontos isolados.

| -1 | -1 | -1 |
|----|----|----|
| -1 | 8 | -1 |
| -1 | -1 | -1 |

3. $Detecção\ de\ Retas$ - Da mesma forma que um ponto isolado pode ser segmentado por um operador do tipo dado pela equação (2.2), também pode ser um segmento de reta, desde que o vetor de pesos usado seja adequado para destacar as partes de uma reta. Para cada direção possível das retas que se deseja destacar na imagem deve-se considerar um vetor de pesos para destacá-la. Por exemplo, utilizando a representação de matrizes para os pesos w_i , se quisermos destacar uma reta deveremos utilizar as respectivas máscaras nos seus respectivos ângulos.

| -1 | -1 | -1 |
|----|----|----|
| 2 | 2 | 2 |
| -1 | -1 | -1 |

Tabela 2.2: 0° - Horizontal

| -1 | -1 | 2 |
|----|----|----|
| -1 | 2 | -1 |
| 2 | -1 | -1 |

Tabela 2.3: 45° - Diagonal Direita

2.2. DTCOURO CCET - UCDB

| -1 | 2 | -1 |
|----|---|----|
| -1 | 2 | -1 |
| -1 | 2 | -1 |

Tabela 2.4: 90° Vertical

| 2 | -1 | -1 |
|----|----|----|
| -1 | 2 | -1 |
| -1 | -1 | 2 |

Tabela 2.5: 135° - Diagonal Esquerda

Pelo que podemos ver, existe uma grande quantidade de técnicas a se utilizar na segmentação de imagens, porém agora será apresentada a segmentação utilizando a textura como principal parâmetro. De modo geral ela é definida por não evidenciar a geometria nem o conteúdo, mas as características da imagem, como: sua propriedades de regularidade e repetição [32].

As técnicas estatísticas permitem caracterizar uma textura do tipo suave, irregular, granulado, etc. As técnicas estruturais tratam da disposição das primitivas numa imagem, por exemplo, textura baseada sobre linhas paralelas dispostas regularmente. A segmentação em geral faz parte de um processo, o qual não se restringe em simplesmente dividir a imagem em regiões mas em obter uma descrição da imagem [20]. Essa descrição será utilizada na fase de análise, a qual irá determinar as regiões que foram segmentadas e buscar as características necessárias. Neste projeto a segmentação tem uma maior ênfase, pois a textura possui uma gama muito grande de informações que podem ser extraídas e com isso obter uma melhor análise da superfície da imagem em questão. Nesse caso a imagem em questão é a do couro bovino no estágio de couro cru e também WetBlue.

2.2 DTCOURO

O DTCOURO é um projeto no qual serão aplicadas técnicas de visão computacional para detecção de defeitos no couro bovino. O Projeto DT-COURO tem como objetivo o desenvolvimento de um sistema automático de extração de parâmetros numéricos, com base em imagens digitais, tornando mais eficiente e preciso o processo de classificação em peles e couros bovinos, determinando um conjunto genérico de parâmetros e métricas que poderão ser utilizados por diferentes sistemas de classificação de qualidade do couro bovino. Os índices básicos da classificação dos defeitos do couro podem ser: a forma, tamanho, área, profundidade, cor, origem do defeito, etc.

2.2. DTCOURO CCET - UCDB

A metodologia básica para o desenvolvimento do sistema de detecção automática de defeitos no couro é a de projeto e programação orientada a objetos. O reaproveitamento de códigos livres também é uma outra característica central da metodologia. O pacote livre, com fontes em linguagem Java, será intensivamente utilizado: o ImageJ, para o processamento digital de sinais. A linguagem Java foi escolhida por ser altamente portável e por possuir boas ferramentas automáticas, livres e gratuitas, que facilitam a geração de documentação e alteração de programas-fonte.

As metas para o desenvolvimento do projeto são:

- Construir um banco de imagens digitais, manualmente classificadas, abrangente e representativo, para treinamento e teste de sistemas automáticos de detecção de defeitos em couro bovino.
- Desenvolver um módulo de pré-processamento digital de imagens para melhorar o desempenho de sistemas automáticos de detecção de defeitos
- Implementar um módulo de extração de atributos para alimentação de sistemas de aprendizagem automática.
- Adaptar ambientes de aprendizagem automática e visão computacional existentes para realização de experimentos com imagens do couro bovino.
- Implementar um sistema para extrair de um conjunto de imagens de uma peça de couro bovino os parâmetros requisitados pelo classificador.
- Desenvolver sistema para aplicação e especificação, por parte de um usuário especializado, de um conjunto de regras para classificação do couro bovino.
- Analisar o desempenho e a viabilidade do sistema proposto em três diferentes situações: no produtor, no frigorífico e no cortume.
- Integrar o sistema DTCOURO ao Programa Embrapa de Carne, Couro e Pele de Qualidade (PECCPQ).
- Capacitar recursos humanos na área em estudo.

O programa de qualidade do couro, o qual é realizado pela EMBRAPA-MS, tem como objetivo gerar um modelo eficaz de classificação do couro e programas para incentivo para maior qualidade, tendo em vista que o Brasil é um dos maiores produtores de couro bovino do mundo, e ainda o estado do Mato Grosso do Sul como um dos principais fornecedores de bovinos abatidos

do Brasil, porém, a má qualidade e preservação do couro nos fazem perder muita renda com exportação destas peles e couros para outros países.

O trabalho que hoje em dia é realizado visualmente para reconhecer os tipos de defeitos (no curtume), será realizado através de um sistema que é moldado com as características vistas acima e pretende auxiliar e tornar automático o trabalho do classificador humano.

Posteriormente este sistema poderá ser integrado ao (SISBOV) ⁴, o que há de trazer mais informações com relação ao gado, desde a sua criação até o abate.

2.3 Trabalhos Correlatos

Os trabalhos citados a seguir representam algumas pesquisas realizadas no meio científico, algumas para detecção dos defeitos no couro bovino utilizando técnicas de segmentação em textura e outra somente tendo como principal tema a segmentação baseada em textura. Em meio a um tema de pesquisa recente e ainda em busca de resultados, foram escolhidas estas pesquisas para melhor compreensão deste projeto.

2.3.1 Identificação de Defeitos no Couro

Esta pesquisa foi realizada por um grupo búlgaro especializado em tecnologia do couro, que basicamente seleciona um critério para análise da imagem baseado no histograma, realizando assim a detecção de defeitos no couro. Este grupo afirma que os defeitos no couro afetam a aparência de couro e o tamanho de uso da área aproveitável. A presença dos defeitos é fator crítico para o ajuste do couro para o fabricante, porque a existência das áreas com defeitos de couro pode ser considerada sem utilidade ou útil somente para finalidades particulares. Há alguns métodos diferentes para a análise dos defeitos de superfície e das classificações dos couros [19].

Neste trabalho é discutido a aplicação do critério $\chi^2(chi\text{-}quadrado)$ para a análise de imagem de couros e para obter seus histogramas este é um dos critérios mais aplicáveis para imagens grandes.

$$\chi^2 = \sum_{i} \frac{(R_i - S_i)^2}{R_i + S_i} \tag{2.3}$$

Na fórmula acima, o R_i e o S_i são respectivamente a contagem dos pixels para o nível cinza dos histogramas padrão e de outra área da imagem, o i é

⁴Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina

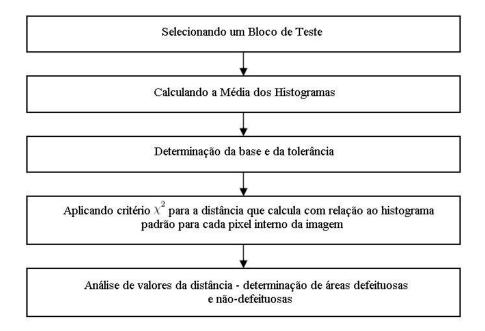


Figura 2.9: Algoritmo da Análise da Imagem.

número de pixels referente a área da imagem em análise. O método proposto é baseado em calcular a diferença entre o histograma do nível cinza da imagem padrão e as áreas procuradas da imagem. O problema básico desta técnica é determinar o histograma padrão, porém o autor propõe o valor do histograma padrão, com o cálculo da média dos histogramas do conjunto de teste. A escolha deste conjunto consiste nas áreas que não possuem defeitos com o mesmo tamanho ⁵ que são selecionadas do processamento de imagem [19].

A Figura 2.9 ilustra o funcionamento do algoritmo da técnica apresentada. Inicialmente é feita a escolha do bloco de teste, o qual possui padrões independentes de sua localização, aspectos dos elementos da textura na superfície de padrões e uma redução da influência do brilho irregular do objeto. Em seguida, utiliza-se o cálculo da média dos histogramas para a determinação do histograma padrão, da base e da tolerância padrão para a avaliação das superfícies. É realizada uma busca para a determinação dos limites relativos às áreas com e sem defeito, sendo que, o intervalo do limite da distância é influenciado pela textura de couro, como: sua cor, forma, tamanho, área, etc.

No geral, a técnica apresentada detecta as áreas defeituosas no couro, porém não há uma localização exata do defeito quando eles ocorrem em

⁵Ex.: 64x64 pixels

cima de uma borda, esta tarefa deve ser discutida em trabalhos futuros.

2.3.2 Utilizando Características de Textura para Identificação de Tecidos em Imagens Médicas

Este trabalho desenvolvido por pesquisadores do ICMC ⁶ da Universidade de São Paulo e apresenta uma ferramenta de suporte à recuperação e indexação em bases de dados de imagens médicas, utilizando atributos da textura. A implementação executa a extração dos atributos baseando-se em alguns descritores, obtidos através dos métodos estatísticos, e realiza a recuperação e classificação das imagens, a partir da similaridade dos valores extraídos das consultas [17].

O problema consiste em analisar um conjunto de matrizes de coocorrência para se caracterizar a textura à qual elas se referem, utilizando-se um ou mais descritores [24]. A Tabela 2.6 mostra os descritores mais utilizados.

| Descritor (significado) | Equação | Descritor (significado) | Equação |
|------------------------------------|--|---|--|
| Variância (contraste da imagem) | $\sum_{i}\sum_{j}(i-j)^{2}P(i,j)$ | Homogeneidade (distribuição de pixels) | $\sum_{i} \sum_{j} P(i,j) / (1 + i - j)$ |
| Entropia (suavidade) | $\sum_{i} \sum_{j} P(i, j) \log P(i, j)$ | Momento 3ª ordem (distorção da imagem) | $\sum_{i}\sum_{j}(i-j)^{3}P(i,j)$ |
| Energia (uniformidade) | $\sum_{i}\sum_{j}P^{2}\left(i,j\right)$ | Variância Inversa (inverso de contraste) | $\sum_{i}\sum_{j}P(i,j)/(i-j)^{2}$ |

Tabela 2.6: Descritores de textura

Usualmente, a escolha dos descritores a serem adotados baseia-se em testes empíricos sobre um domínio específico, verificando-se quais deles produzem resultados mais satisfatórios. Diversos trabalhos têm utilizado a estatística e conseguiram obter resultados satisfatórios. A análise é realizada utilizando a matriz de co-ocorrência da imagem, a qual será explicada no Capítulo 3, seção 3.1.

Foi utilizada uma ferramenta chamada extrator de textura, que para cada amostra da imagem, gera matrizes de co-ocorrência (com 16 níveis de cinza) para quatro ângulos (0, 45, 90 e 135 graus) e distâncias 1, 2, 3, 4 e 5, resultando em 20 matrizes de dimensões de 16x16 pixels, para cada imagem.

⁶Instituto de Ciências Matemáticas e de Computação

Para verificar a capacidade do método quando aplicado à tarefa de distinguir diferentes tecidos do corpo humano, foi criada uma base de imagens que consiste em seções de imagens de tomografia computadorizada, ressonância magnética, contendo segmentos típicos de diferentes órgãos: pulmão, coluna vertebral, cérebro, coração, fígado, osso e músculo. A base contém uma média de sete imagens de cada grupo, totalizando cinqüenta imagens. Foram realizadas extrações tomando-se como referência uma imagem de cada grupo e computando-se a classificação obtida pelas outras imagens da base em relação à mesma, para os seguintes descritores:

- Gradiente:
- Variância;
- Entropia;
- Energia;
- Homogeneidade;
- Momento de terceira ordem;
- Momento inverso;
- Combinação de gradiente, entropia e homogeneidade.

Para apresentar os resultados, foi utilizado os conceitos de precision e recall, que são medidas baseadas na noção de dados importantes de acordo com uma determinada necessidade de informação. O precision é a proporção das ações importantes para aquele estado que foram realizadas, o recall é a proporção de dados importantes de um conjunto que foi recuperado. Em um conjunto TO de dados formado pelos elementos obtidos de uma busca e TR um conjunto de dados de elementos relevantes também de uma busca, o conjunto de dados denominado TRO é formado pela união dos conjuntos A e B $(A \cap B)$, desta maneira o precision e o recall podem ser melhor compreendidos através da fórmula abaixo:

$$Precision = \frac{TRO}{TO}$$

$$Recall = \frac{TRO}{TR}$$

Sendo TR o total de relevantes disponíveis, TRO o total de relevantes obtidas e TO o total de obtidas.

Em cada experimento, TO foi variado de 1 até o total de imagens da base. Para cada valor de TO, foi tomado o valor obtido de TRO e calculado

precision e recall. A área sob a curva precision x recall indica a eficácia dos resultados: se para todos os valores de TO os valores de TRO foram sempre os máximos, o valor da área será igual a 1, enquanto no pior caso o valor da área será igual a 0. Podemos visualizar na Tabela 2.7 o resumo dos resultados obtidos utilizando a técnica citada acima neste trabalho.

| Extrator | Melhor Valor | Pior Valor | Média (Dsv-Padrão) |
|-------------------|--------------|------------|--------------------|
| Combinação | 1,00 | 0,67 | 0,84(0,13) |
| Gradiente | 0,97 | 0,51 | 0,80(0,18) |
| Variância | 1,00 | 0,45 | 0,80(0,19) |
| Homogeneidade | 0,95 | 0,45 | 0,77(0,18) |
| Mom. Terc. Ordem | 1,00 | 0,54 | 0,76(0,16) |
| Entropia | 0,85 | 0,58 | 0,73(0,11) |
| Variância Inversa | 0,95 | 0,52 | 0,72(0,13) |
| Energia | 0,81 | 0,52 | 0,66(0,10) |

Tabela 2.7: Resultados

Com os resultados, pode-se constatar que a combinação de extratores conseguiu os melhores resultados, seguida dos extratores gradiente, variância e homogeneidade. O extrator que apresentou pior desempenho foi o de energia, que além de ter a pior média, teve também o desvio-padrão baixo, indicando que seu desempenho foi ruim para todos os tipos de tecidos.

Essa ferramenta foi implementada especificamente para auxiliar no estudo e análise de imagens médicas. Os resultados bastante satisfatórios que foram obtidos qualificam os métodos e procedimentos utilizados, tanto para processos que envolvam contextos mais abrangentes das imagens médicas (integrado a métodos de segmentação, por exemplo) quanto para contextos mais específicos de análise detalhada de imagens típicas de tecidos.

2.3.3 Seleção de Características do Couro para Reconhecimento de Defeitos

Esta pesquisa foi realizada por um grupo do DSCT ⁷ da Universidade de Rússia, em um estudo com 12 histogramas e suas características estatísticas para a análise das imagens do couro bovino. Foi feita uma pesquisa dos tipos de características da superfície do couro para a detecção dos defeitos. Na análise da imagem foi usado o método de "quadtree" para decomposição da imagem, por esta técnica dividir a imagem em blocos homogêneos. Este método possibilitou a percepção de mudanças dos valores das características

⁷Departamento de Sistemas de Computação e Tecnologia

dependendo do tamanho da área analisada. Para a identificação dos defeitos nas regiões é utilizada a lógica fuzzy.

Tendo em vista a complexidade da textura na superfície de couro, a presença dos defeitos muda as características de algumas texturas e por essa razão, uma solução para o reconhecimento dos defeitos no couro, é utilizar os métodos estatísticos. São alguns métodos de análise estatística de imagens: análise estatística do histograma e dos seus níveis de cinza, análise das características locais na textura, entre outros.

A variação das diferenças das características em regiões sem defeitos e defeituosas, depende de onde está disposta a área dos defeitos. Quanto maior a variação de pixels pertencentes aos defeitos, há maior diferença nas características. Por esta razão, neste trabalho em específico, são examinadas áreas de diferentes tamanhos, de maneira que se alcance uma proporção maior de pixels com defeitos e sem defeitos.

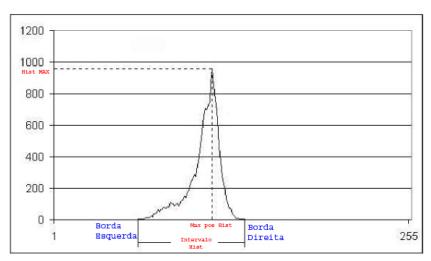


Figura 2.10: Exemplo de Histograma

No método de decomposição quadtree um bloco é homogêneo se nenhuma característica exceder o valor do limiar (threshold) definido. O método de decomposição do quadtree é utilizado: na análise de imagem [14], na segmentação de movimento [40] e nas aplicações de compressão [4]. O principal problema da quadtree é determinar do valor do seu limiar, o qual é geralmente encontrado por um treinamento com imagens previamente classificadas, e ainda assim, um pequeno erro pode causar uma diferença sobre o limiar. Para determinar um limiar mais confiável, é utilizada a lógica fuzzy. A lógica fuzzy é muito utilizada na segmentação de imagens [47], o realce da imagem [13] e aplicações morfológicas de processamento de imagens [31]. O principal objetivo deste trabalho é observar o conjunto de características

para a análise das imagens do couro e determinação e dos valores de limiar utilizando a lógica fuzzy.

O histograma é a maneira gráfica utilizada na análise de imagem que mostra a distribuição das intensidades dos pixels em uma imagem. Neste trabalho são feitos alguns cálculos com base nas características do histograma da imagem em nível de cinza.

A Figura 2.10 ilustra as características do histograma. A Borda Esquerda apresenta o menor valor do pixel; a Borda Direita o maior valor do pixel; o Intervalo Hist mostra o valor dos pixels compreendidos entre as bordas direitas e esquerdas; Hist Max aponta a maior quantidade de pixels com o mesmo valor de intensidade na escala de cinza; o Max Pos Hist mostra a posição máxima do histograma, o valor do pixel onde está situada posição máxima do histograma.

As características das estatísticas de primeira ordem do histograma que são calculadas, são definidas como segue: A média representada na Equação 2.4 e o desvio-padrão na Equação 2.5 .

$$\mu = \frac{1}{N} \sum_{i} \sum_{j} p(i, j);$$
 (2.4)

$$\sigma^{2} = \frac{1}{N} \sum_{i} \sum_{j} [p(i, j) - \mu^{2}]$$
 (2.5)

Sendo que p(i, j) é o nível de cinza, (i, j), é a posição do pixel na imagem e por fim o N que é o número total dos pixels da imagem. O último grupo das características que foi usado inclui as medidas estatísticas de segunda ordem baseadas na matriz da co-ocorrência do nível cinza da imagem. A matriz da co-ocorrência e seus descritores estão definidas no Capítulo 3, seção 3.1.

O conjunto de todas as características vistas anteriormente foi agrupado com o intuito de que com esse grande número de informações, fosse possível criar uma ferramenta de precisão para reconhecer de defeitos em couro.

Capítulo 3

Segmentação e Reconhecimento Baseado em Textura

O método descrito nesse capítulo utiliza técnicas de segmentação combinadas. Na fase do pré-processamento e extração de características, será utilizada a matriz de co-ocorrência, a qual tem com objetivo descrever textura através de um conjunto de características para as ocorrências de cada nível de cinza nos pixels da imagem, considerando múltiplas direções e distâncias. A partir da matriz de co-ocorrência são realizados cálculos estatísticos para extração dos valores que irão determinar as características de cada bloco analisado. No método de classificação, serão utilizados métodos de aprendizagem supervisionados.

3.1 Matriz de Co-ocorrência

As matrizes de co-ocorrência são uma das mais populares fontes de características para texturas [38]. Numa relação espacial entre os pixels de uma textura, os elementos da matriz de co-ocorrência descrevem a freqüência com que ocorrem as transições de nível de cinza entre pares de pixels. Dessa maneira, ocorrendo variações na relação espacial, por meio de alterações na orientação e distância entre as coordenadas dos pixels, podem ser obtidas diversas matrizes de co-ocorrência, a partir das quais os descritores, ditos de segunda ordem, calculam os valores utilizadas para análise das características.

Na estatística de segunda ordem calculamos a probabilidade de um determinado par de níveis de cinza (i, j), numa determinada distância δ e uma direção θ ocorrer, ou seja, a matriz de co-ocorrência $P(i, j, \delta, \theta)$ pode ser denominada como sendo um histograma bidimensional que apresenta a freqüência

de ocorrência [23]. O número de matrizes computadas e a escolha correta dos parâmetros δ e θ das mesmas, determina o modo com que as características serão extraídas. Para imagens com texturas mais complexas é necessário que sejam criadas matrizes com parâmetros δ de pequenos valores, ou seja, com menores distâncias, geralmente 1 ou 2. Porém, para texturas menos complexas costuma-se utilizar valores maiores, ou seja, as distâncias são escolhidas de acordo com a granularidade das imagens manipuladas. O parâmetro θ , neste trabalho, varia apenas em 4 direções (0, 45, 90 e 135 graus), realizando o cálculo a partir do pixel central em relação aos seus oito vizinhos, de modo a não se trabalhar em uma única direção [24]. Na Figura 3.1 podemos visualizar os ângulos utilizados para θ . No módulo implementado, as distâncias e os ângulos poderão ser escolhidos pelo usuário, de modo que se defina o valor que melhor determina as características dos defeitos em cada imagem.

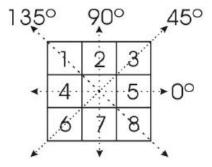


Figura 3.1: Ângulos utilizados para o cálculo da Matriz de Co-ocorrência

A matriz é formada por um número C de linhas e colunas, onde C é o número de níveis de cinza da imagem. A matriz é ordenada do menor nível de cinza até o maior tanto na linha como na coluna, ou seja, a posição (0,0) da matriz corresponde à ocorrência do nível de cinza 0 com ele mesmo. Com isso, cada posição da matriz armazena o número de ocorrência $P(i,j,\delta,\theta)$ em relação ao valor do pixel inicial com o do seu vizinho, o qual varia de acordo com ângulo e distância.

Este método pode ser visualizado observando a Tabela 3.1, na qual temos os valores dos pixels de uma imagem de tamanho 4x4, com 4 níveis de cinza (C=4), logo as matrizes de co-ocorrência serão de tamanho 4x4. Considerando $\theta=0^\circ$ e $\delta=1$, então, por exemplo, para a posição (0,0) da matriz teremos que contar quantas vezes ocorre o relacionamento do nível 0 de cinza com o nível 0 de cinza, à distância 1 e ângulo 0. Vemos claramente na Tabela 3.1 que esse relacionamento ocorre 4 vezes na imagem, sendo computado da esquerda para direita e vice-versa, o resultado é visualizado na

matriz (0°), as outras matrizes mostram os resultados em ângulos diferentes, porém com $\delta = 1$.

| 0 | 0 | 1 | 1 |
|---|---|---|---|
| 0 | 0 | 1 | 1 |
| 0 | 2 | 2 | 2 |
| 2 | 2 | 3 | 3 |

Tabela 3.1: Imagem em tons de cinza

$$Matriz(0^{\circ}) = \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix}, \quad Matriz(45^{\circ}) = \begin{bmatrix} 4 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 0 & 2 & 4 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

$$Matriz(90^{\circ}) = \begin{bmatrix} 6 & 0 & 2 & 0 \\ 0 & 4 & 2 & 0 \\ 2 & 2 & 2 & 2 \\ 0 & 0 & 2 & 0 \end{bmatrix}, \quad Matriz(135^{\circ}) \begin{bmatrix} 2 & 1 & 3 & 0 \\ 1 & 2 & 1 & 0 \\ 3 & 1 & 0 & 2 \\ 0 & 0 & 2 & 0 \end{bmatrix}$$

Realizado o cálculo das matrizes, no próximo passo são utilizados alguns dos descritores apresentados por Haralick em [24] para extração de características. Ele definiu 14 diferentes descritores de textura [24], porém serão utilizados apenas sete desses descritores, os que mais se adaptaram a este tipo de pesquisa. Os descritores utilizados na aplicação foram: energia, entropia, contraste, dissimilaridade, correlação, diferença inversa e segundo momento angular. A seguir são apresentadas as características de alguns dos descritores citados e suas respectivas fórmulas:

• Energia: também conhecida como segundo momento angular, é a medida da dispersão das entradas da matriz, ou seja, avalia a uniformidade textural da imagem.

$$Energia = \sum_{i}^{n-1} \sum_{j}^{n-1} [P(i,j)]^{2}$$
 (3.1)

P(i,j) representa o total de co-ocorrências entre os tons de cinza i e j e n o número total de tons de cinza da imagem.

• Entropia: mede a desordem em uma imagem, ou seja, o nível de dispersão de níveis de cinza, no sentido de que a maior entropia corresponde a menor ordem de organização das estruturas e vice-versa.

$$Entropia = -\sum_{i}^{n-1} \sum_{j}^{n-1} p(i,j) \log_2[p(i,j)]$$
 (3.2)

• Contraste: também conhecido como variância, mede a presença de mudança abrupta de níveis de cinza (bordas) na imagem.

$$Contraste = \sum_{i}^{n-1} \sum_{j}^{n-1} (i,j)^2 P(i,j)$$
 (3.3)

• Correlação: mede a dependência linear de um nível de cinza em relação aos vizinhos, em uma imagem que apresenta certa ordenação local de níveis de cinza, o valor da correlação será alto [24].

$$CORR = \frac{\sum_{i}^{n-1} \sum_{j}^{n-1} ijP(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$$
 (3.4)

Onde:

$$\mu_x = \sum_{i}^{n-1} \sum_{j}^{n-1} iP(i,j), \quad \mu_y = \sum_{i}^{n-1} \sum_{j}^{n-1} jP(i,j)$$

$$\sigma_x = \sqrt{\sum_{i}^{n-1} \sum_{j}^{n-1} i^2 P(i,j) - \mu_i^2}$$

$$\sigma_y = \sqrt{\sum_{i}^{n-1} \sum_{j}^{n-1} j^2 P(i,j) - \mu_j^2}$$

• Homogeneidade: é a medida da uniformidade da textura, ou como o próprio nome sugere mede homogeneidade da imagem. .

$$Homogeneidade = \sum_{i}^{n-1} \sum_{j}^{n-1} \frac{P(i,j)}{1 + (i-j)^2}$$
 (3.5)

Os cálculos realizados pelos descritores em cima da matriz de coocorrência, se agrupam no vetor de características de modo a determinar

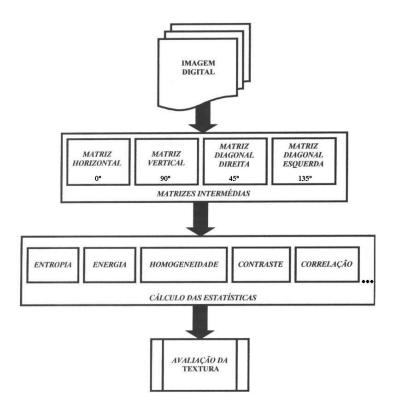


Figura 3.2: Processamento da Análise da Textura

a classificação das imagens analisadas, tais fases do cálculo da matriz de coocorrência e dos descritores, é ilustrado na Figura 3.2. Na primeira fase é inserida a imagem, logo após são realizados os cálculos da matriz de co-ocorrência
nos quatro ângulos determinados, depois são feitos os cálculos estatísticos e
por fim determinado a classificação da textura. A análise estatística de cada
característica é combinada de maneira que é gerado um parâmetro para a
definição da classe a qual o bloco analisado pertence. Esses parâmetros são
definidos no treinamento. A posterior combinação de alguma técnica que
contribua na precisão deste sistema não irá alterar o objetivo principal que é
a segmentação e o reconhecimento baseado nas características da textura. A
matriz de co-ocorrência não é um método computacionalmente rápido, principalmente quando se aumenta o número de ângulos e distâncias a calcular.

3.2 Classificação

A classificação depende do processo de extração de informações nas imagens para reconhecer os padrões e objetos homogêneos. A classificação define

em que conjunto o defeito a ser reconhecido encontra-se na textura. Para a realização deste processo de classificação o sistema necessita ter um conhecimento anterior das classes a serem reconhecidas, ou seja, um treinamento. Uma vez que este conhecimento esteja disponível e as características da textura já tenham sido extraídas, usa-se então uma técnica de classificação do teste padrão a fim de separar cada bloco analisado em sua respectiva classe. Em outras palavras, um defeito (ex.: berne) reconhecido numa peça de couro, está contido em uma classe, com isso o couro receberá a classificação que ele contém aquela classe (berne) e também sua localização espacial na peça de couro. Na Figura 3.3 temos o exemplo de uma imagem de couro com um defeito de marca a fogo.

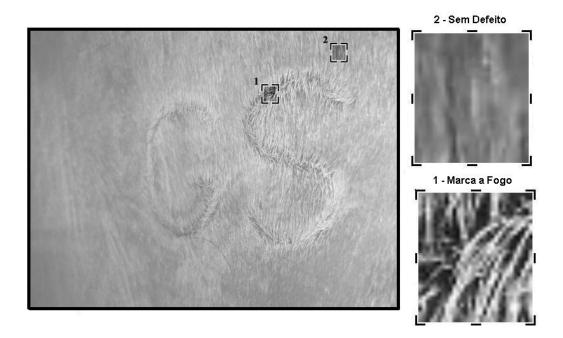


Figura 3.3: Extração de Características

Na Figura 3.3 temos a marcação de 2 amostras, uma sem defeito e outra com defeito, com o objetivo de mostrar a diferença visual no tipo das duas texturas. O objetivo da classificação é que, a partir das informações extraídas da matriz de co-ocorrência e seus descritores, ela seja capaz de distinguir as amostras de classes diferentes.

No processo de definição das classes dos defeitos do couro bovino, houve primeiramente um trabalho manual, para classificação de cada defeito em cada imagem. Um grande problema encontrado na aquisição das imagens foi a ocorrência de alterações da intensidade de luz, por utilização de flash da

câmera fotográfica e luz ambiente, entre outros. Estas alterações permitem que duas fotos de um mesmo defeito em uma peça de couro possam ter uma classificação diferente, pois há uma variação na luminosidade dos pixels.

Capítulo 4

Implementação

Neste capítulo são apresentadas as técnicas e ferramentas utilizadas para implementação do módulo proposto. Na seção 4.1 é descrita como foi feita a escolha do método utilizado para aquisição das imagens do couro, como foi aplicado, de que maneira foram adquiridas as imagens e a importância da técnica selecionada para a fase de extração de características. A seção 4.2 trata da extração de características em três segmentos. São eles:

- O gerador de amostras, que gera as amostras baseando-se nas áreas dos defeitos selecionadas:
- A extração de características, que realiza a transformação das amostras dos defeitos das imagens do couro, em valores (atributos);
- O classificador, que define as classes, na qual, cada defeito está contido, baseando-se nos resultados extraídos dos atributos das amostras.

Os métodos e ferramentas utilizados na extração são fundamentais, pois implicam diretamente no resultado gerado pelo cálculo do vetor de características e na classificação. A seção 4.3 apresenta o método e a ferramenta para classificação, nessa parte os arquivos do tipo ARFF ¹ gerados pelo extrator, como descrito na seção 4.2, são processados e seus resultados são analisados.

Algumas ferramentas foram de fundamental importância neste projeto. São elas: o ImageJ [2] que foi a base para integração do extrator de características, o Weka ² [26] que forneceu todos os pacotes necessários para a

 $^{^1\}mathrm{Attribute}\text{-Relation}$ File Format - Arquivo no formato de atributo e relações

²Waikato Environment for Knowledge Analysis - é formado por um conjunto de implementações de algoritmos de diversas técnicas de Mineração de Dados (www.cs.waikato.ac.nz/ml/weka)

análise e os experimentos, por fim o pacote SIGUS [35]o qual foi utilizado na montagem do arquivo ARFF, entre outros. Também foi utilizada a ferramenta: Eclipse; esta serviu de uso para a escrita e depuração do código-fonte, escrito na linguagem Java.

4.1 Método de Aquisição das Imagens e Montagem do Banco de Imagens

A escolha de um método para a aquisição das imagens do couro foi baseada em pesquisas e discussões entre os integrantes do projeto DTCOURO. Problemas similares ocorrem em outras áreas de pesquisas, alguns deles aparecem nas áreas das indústrias têxtil [36], indústrias de madeiras e derivados [1], entre outras. De modo que fosse escolhida uma técnica que contribuísse para o bom funcionamento do sistema proposto, o método estabelecido é descrito a seguir.

O método para fotografar os couros e seus defeitos foi estabelecido da seguinte forma: três distâncias (10~cm, 50~cm e 1,75~cm), dois ângulos (45~e 90~graus) e por último o uso do flash ($sim~ou~n\~ao$). Esta técnica é utilizada para que cada peça de couro analisada seja fotografada, primeiro na distância de 1,75~metros, em 90~ou~45~graus, de modo que a foto alcance a peça de couro inteira. No próximo passo a peça de couro deve ser fotografada em uma proximidade maior, com o foco principal nos defeitos do couro, nas distâncias 10~cm~e~50~cm, cada uma com os dois tipos de angulação e as duas opções do flash, citados anteriormente.

Para que cada imagem tivesse suas informações preservadas, enquanto as peças de couro eram fotografadas e analisadas eram anotadas de forma manual em uma tabela, que continha todas as características citadas acima, e mais o tipo do defeito e o número da foto. Após o término da fase do ensaio fotográfico e análise, as imagens eram descarregadas no computador e suas informações eram gravadas no nome do arquivo de cada imagem. Dessa forma: cada foto foi nomeada com a seguinte seqüência de caracteres: 000-[AA.DD.X]-Defeito.jpg, em que 000 a numeração da foto, AA o ângulo, DD a distância, X é S se o flash da câmera estiver ligado e S0 se não estiver ligado e por fim, em S0 se foi utilizada com a finalidade de não se perder as informações básicas de cada imagem, pois o módulo de inserção e marcação das imagens do projeto S1 DTCOURO é responsável por armazenar a imagem e as coordenadas das marcações dos defeitos, que é feita pelo usuário. O sistema S1 DTCOURO visa armazenar todas essas informações através de um

sistema de banco de dados e estruturas para interligação com os demais módulos desenvolvidos. Este banco de imagens também poderá ser utilizado por acadêmicos ou pessoas do meio científico que se interessarem pelo conteúdo desta pesquisa.

As imagens foram adquiridas através de visitas a alguns curtumes e frigoríficos no estado de Mato Grosso do Sul. Foram responsáveis pela préclassificação visual dos defeitos nos couros: a pesquisadora Mariana Aragão, do setor de Gado de Corte da EMBRAPA-MS e também integrante do projeto DTCOURO, juntamente com técnicos treinados em classificação de couros dos próprios curtumes e frigoríficos visitados.

Para a inclusão das imagens no banco de dados do sistema DTCOURO, foi utilizado o ambiente de aquisição e marcação, desenvolvido pelo acadêmico da UCDB Willian Paraguassu, do curso de Engenharia da Computação e integrante do projeto. Este ambiente está diretamente ligado a uma base de dados, e quando é inserida uma nova imagem, o sistema faz o cadastro mediante a escolha do estágio da imagem do couro (cru ou wet-blue), pelo usuário. Após o cadastro das imagens no banco, é iniciado o processo de marcação, para que o sistema saiba onde está localizado o defeito, e qual a sua classificação. Os métodos de marcação e classificação são manuais, logo após a seleção da área defeituosa do couro o sistema pergunta se o usuário deseja que esta área seja cadastrada no bando de dados. Confirmado o cadastramento, o sistema pede para que o usuário defina qual o tipo do defeito selecionado, aí então todas as informações da área selecionada, juntamente com suas características, são salvas no banco de dados. Toda a descrição do módulo de inclusão de imagens no banco de dados pode ser visualizada nas Figuras 4.1, 4.2, 4.3 e 4.4.



Figura 4.1: Janela principal do sistema DTCOURO

A Figura 4.1 mostra a tela inicial do sistema DTCOURO, que agrupa todos os outros módulos desenvolvidos pelo grupo de pesquisa do projeto. Na Figura 4.2 temos a tela do ambiente de aquisição e marcação das imagens, que é responsável pelo cadastramento das imagens e seus defeitos. A

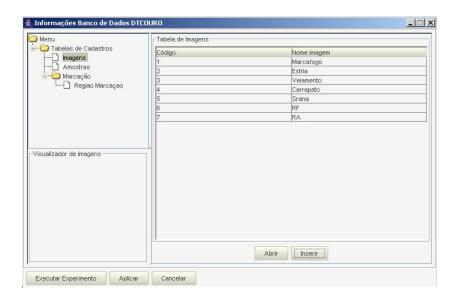


Figura 4.2: Ambiente de Aquisição e Marcação

seleção de defeitos no couro e cadastramento das marcações são visualizados na Figura 4.3. Por fim, é representado na Figura 4.4 como as informações dos defeitos são selecionadas e gravadas, juntamente com as marcações, no banco de dados.

4.2 Extração das Características

O método definido para extração de características tem o seu início na geração de amostras, depois passa por um processamento no qual são extraídos da textura das imagens os valores dos atributos definidos no cálculo da matriz de co-ocorrência, logo após os atributos e vetores de características são armazenados no arquivo ARFF ³, por último é utilizada ferramenta a WEKA, para que através dos algoritmos de classificação, previamente estabelecidos, sejam determinadas as classes e também a eficiência do algoritmo.

Geração de Amostras

A geração de amostras utiliza as marcações realizadas nas imagens com defeito, pois é da área demarcada que o gerador de amostras irá extraílas. Este método é utilizado dessa forma: dentro do projeto DTCOURO foi desenvolvido um módulo chamado geração de amostras. Nesta ferramenta basta apenas selecionar o defeito, o tamanho da cada amostra (dimensão), o

³Arquivo do WEKA



Figura 4.3: Marcação de defeitos



Figura 4.4: Cadastro do tipo de defeito para inclusão no Banco

número de amostras a ser geradas e o espaçamento entre uma e outra. Este processo é apresentado na Figura 4.5.

Esta Figura mostra o gerador de amostras e suas opções, os defeitos para escolha são os mesmos cadastrados no banco de dados do projeto. As escalas foram definidas nas dimensões 10x10, 20x20, 30x30 e 40x40 pixels, o número de amostras a ser gerado e o espaçamento entre as amostras depende da necessidade do usuário.

Extraindo Características das Amostras

O extrator de características tem seu foco principal na matriz de coocorrência e seus descritores. Para a execução dos cálculos da matriz de co-ocorrência é fundamental que antes se faça a seleção dos ângulos, das



Figura 4.5: Gerador de Amostras

distâncias, dos descritores e de quais amostras irão utilizar. O sistema DTCOURO possui uma interface de comunicação com o usuário, chamada análise de experimentos, para que o mesmo possa definir suas preferências. Esta interface é visualizada na Figura 4.6.

No ambiente de análise de experimentos, Figura 4.6, temos as seguintes opções: seleção de características, que permite escolher quais descritores serão utilizados. Entre eles estão:

- Entropia;
- Momento de diferença inversa;
- Dissimilaridade;
- Correlação;
- Contraste;
- Segundo momento angular;
- Diferença inversa.

O intervalo de ângulos pode ser escolhido entre 0 até 360 graus; o intervalo de distâncias, o qual é selecionado pelo usuário (Ex.:1 a 4); por fim a seleção do conjunto de amostras baseado nos defeitos, estágio do couro e dimensões da amostra.

Após a execução da matriz de co-ocorrência todos os resultados e atributos são armazenados em um arquivo do tipo ARFF. A Figura 4.7 mostra de que maneira são dispostos os dados no arquivo.

O exemplo apresentado na Figura 4.7, mostra um arquivo ARFF gerado por algumas amostras de tipos diferentes (carrapato, estria, marca a fogo,

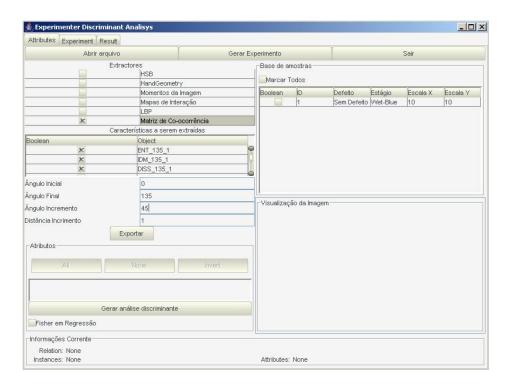


Figura 4.6: Ambiente de análise de Experimentos

risco aberto, risco fechado, sarna e veiamento), com o ângulo em 90 graus, distância igual a 1 e os sete descritores. Após o objeto "@data", cada linha representa o valor extraído dos descritores de uma matriz de co-ocorrência em um ângulo e uma direção, e ao final da linha a descrição do defeito. A ferramenta que gera o arquivo ARFF foi adaptada para utilizar a técnica implementada pertencente a plataforma SIGUS.

4.3 Classificador

O método de classificação é dependende dos métodos anteriores, pois ele utiliza o arquivo ARFF, para poder fazer o treinamento dos algoritmos de classificação e realizar os testes para saber as classes em que foram estalecidas cada amostra analisada.

O ambiente de classificação do projeto DTCOURO é uma ferramenta de grande importância, pois é através dela que podemos realizar os experimentos e selecionar e combinar algoritmos capazes de nos proporcionar bons resultados na classificação dos defeitos. Esta ferramenta foi desenvolvida baseada na ferramenta WEKA, que proporcionou a estrutura para que o projeto fosse integrado.

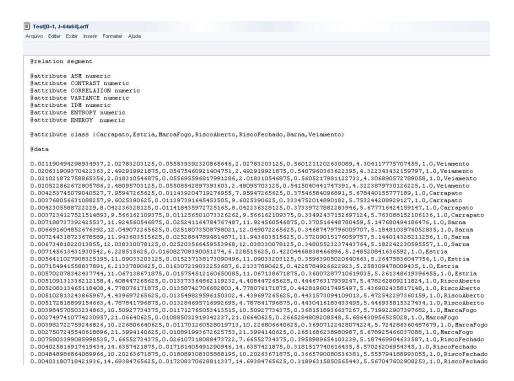


Figura 4.7: Formato do Arquivo ARFF

O WEKA funciona em 3 etapas:

- Etapa de seleção: o arquivo ARFF é selecionado, escolhe-se o método de validação, em seguida os algoritmos de classificação juntamente com o número de iterações;
- 2. Etapa de execução: ocorre a execução do algoritmos;
- 3. Etapa de análise: são visualizados os resultados e analisados da forma que o usuário escolher.

As Figuras 4.8, 4.9 e 4.10 ilustram o funcionamento da ferramenta WEKA.

Na Figura 4.8 temos a tela de opções que é explicada a seguir: em "Datasets" é selecionado o arquivo ARFF a ser analisado, em "Algorithms" é feita a escolha dos algoritmos de classificação e por último, no "Iteration Control" seleciona-se o número de iterações de cada algoritmo; a Figura 4.9 ilustrada a tela em que toda execução dos algoritmos é realizada; a Figura 4.10 representa a tela de análise dos resultados, na qual são mostrados os percentuais de erros e acertos obtidos pelos algoritmos, em "Comparasion Filed" é escolhido o tipo de resultado, entre eles estão: tempo de treinamento, tempo de teste, numero de amostras, número de falsos acertos, entre outros.

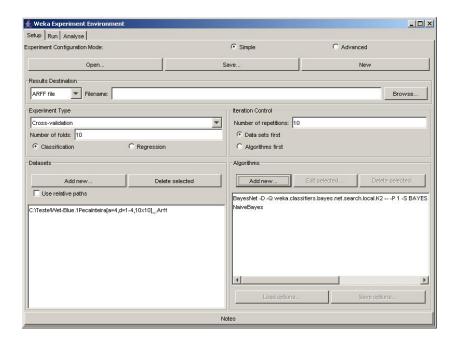


Figura 4.8: Configuração do Weka

Este trabalho não tem com objetivo criar um classificador das amostras analisadas, porém é necessário testar as informações extraídas da matriz de co-ocorrência e medir a eficiência do algoritmo de extração.

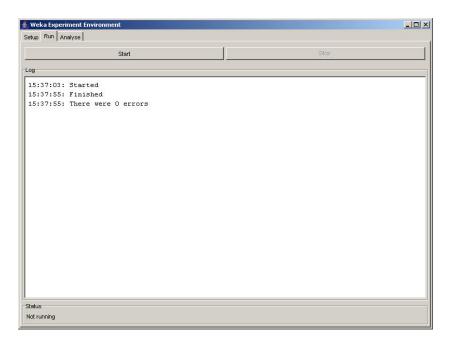


Figura 4.9: Excução dos Algoritmos

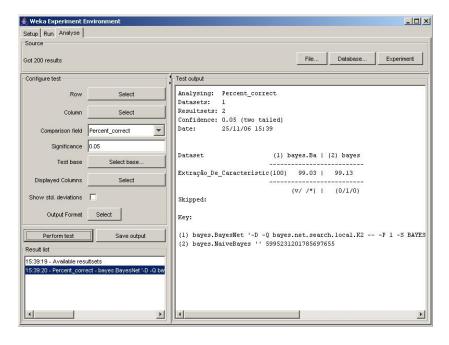


Figura 4.10: Análise dos Resultados

Capítulo 5

Experimentos, Resultados e Análise dos Resultados

5.1 Material Utilizado e Experimentos

5.1.1 Material Utilizado

Os equipamentos e aplicativos utilizados para a realização deste projeto estão disponíveis no Grupo de Pesquisa em Engenharia e Computação - GPEC da Universidade Católica Dom Bosco - UCDB, e também na Embrapa Gado de Corte de Mato Grasso do Sul que é parceira no projeto DTCOURO, serão apresentados a seguir.

- Notebook Centrino Duo, CPU bi-processado 1.66Ghz, Memória DDR 400Mhz de 1GB, Disco Rígido de 80GB, Monitor de Plasma 14.5".
- Computador Pentium 4-HT, com CPU 3.6, Memória DDR 400Mhz de 1GB, Disco Rígido SATA-2 de 160GB, Monitor de vídeo colorido de 17".
- Maquina fotográfica digital de 4.1 *Megapixels*, da marca Sony, modelo CyberShot.
- Sistema Operacional Linux Kurumim 2.0.
- Eclipse.
- ImageJ.

5.1.2 Experimentos

Entre os computadores utilizados, o notebook recebeu as imagens da pesquisa de campo e contribuiu em parte da implementação do módulo de extração de características. No computador de mesa foi realizada a escrita deste trabalho e a implementação do módulo.

As imagens do banco foram obtidas através de visitas aos curtumes: Couro Azul em Campo Grande - MS, e Independência em Nova Andradina - MS, e ao frigorífico Independência em Campo Grande - MS e em Nova Andradina - MS. Através destas visitas, apesar da falta de uma estrutura especial e luz adequada para a aquisição das imagens, foram estabelecidas algumas regras para o modo de aquisição ¹. Todas as imagens foram fotografadas na resolução máxima que a câmera permitiu, 2304x1728 e no formato de cor RGB.

O método utilizado na organização das imagens dos couros no banco de dados foi descrito no capítulo 4.1. Do banco de dados, três conjuntos de imagens foram previamente selecionados e realizados testes com as amostras extraídas de cada um, individualmente. O primeiro conjunto envolve 3 peças de couro no estado cru, com distância de 1,75metros, ângulo de 45graus e com flash ligado. Os defeitos presentes nas imagens eram: carrapato, fotossensibilidade, furo de esfola, marca a fogo, risco aberto e risco fechado. Foram extraídas 50 amostras das áreas demarcadas de cada defeito e 200 amostras das áreas sem defeito. Do segundo conjunto de imagens fazem parte: 7 peças diferentes de couros no estado wet-blue, que foram fotografadas nas distâncias 10 e 50cm, ângulo de 90graus e flash desligado. Essas imagens possuem 7 tipo de defeitos, sendo um em cada imagem. São eles: carrapato, sarna, estria, marca a fogo, risco aberto, risco fechado e veiamento. As amostras geradas foram de 50 para cada região com defeito e 200 para as sem defeito. O terceiro conjunto na verdade se resume a uma única imagem de couro na forma wet-blue, que foi fotografado em uma distância de 10cm, ângulo de 90graus, e flash desligado. Os defeitos dessa imagem são apenas de 2 tipos: carrapato e sarna. Foram geradas 200 amostras para as regiões de cada defeito e 200 para as sem defeito. O número total de amostras extraídas foi de 1.650. A escolha da marcação de alguns defeitos em uma única peça de couro e a sua análise individualmente, tiveram a função de testar o módulo de extração de características, pois o fato de fotografar os couros, de modo manual, altera algumas características da textura, entre cada foto. O fato de alguns conjuntos de imagens terem a função do flash ligado e em outros desligado foi de apenas testar a eficiência do sistema de detecção em meio a fontes de luz diferentes. A seguir nas Figuras 5.1, 5.2, 5.3 e 5.4, é

¹Descritas anteriormente no Capitulo 4 seção 1

demonstrada essa diferença nas características da textura.





Figura 5.1: Couro Wet-Blue (1) Figura 5.2: Couro Wet-Blue (2)

| ì | 130.667 | 128.667 | 129.333 | 130.333 |
|---|---------|---------|---------|---------|
| | 133.667 | 132.333 | 128.333 | 123.667 |
| | 129.333 | 134.667 | 138.667 | 136.667 |
| | 129.333 | 127.667 | 127.333 | 129.000 |
| | 129.667 | 130.667 | 130.000 | 124.000 |
| | 131.000 | 131.667 | 135.667 | 141.667 |
| | 130.667 | 126.667 | 128.667 | 129.667 |
| | | 131.333 | | 126.000 |
| | | 126.000 | | 134.333 |
| | 130.000 | 119.667 | 117.667 | 135.667 |
| | | | | |

| 157.000 | 156.000 | 156.000 | 159.667 |
|---------|---------|---------|---------|
| 151.333 | 157.333 | 159.333 | 160.000 |
| 149.000 | 164.333 | 170.667 | 164.000 |
| 156.333 | 157.333 | 155.333 | 156.000 |
| 153.000 | 156.333 | 159.000 | 158.000 |
| 143.667 | 162.000 | 167.667 | 160.000 |
| 161.000 | | | |
| 151.667 | | | |
| 147.333 | | | |
| 158.000 | 156.000 | 157.000 | 158.333 |

Figura 5.3: Valores dos Pixels (1) Figura 5.4: Valores dos Pixel (2)

Nas Figuras 5.1 e 5.2, é visível a olho humano a diferença na iluminação das duas imagens, sendo a Figura 5.1 com uma cor mais clara e a Figura 5.2 mais escura. Para confirmar a difença nas texturas nas Figuras 5.3 e 5.4, são mostrados os valores de alguns *pixels* referentes as imagens das Figuras 5.1 e 5.2. Estas imagens foram fotografadas em um mesmo ângulo e distância, porém com uma incidência de luz diferente.

As amostras foram todas processadas pelo extrator de características e os atributos selecionados na extração foram: os descritores entropia, momento de diferença inversa, dissimilaridade, correlação, contraste, segundo momento angular e diferença inversa, para cada um deles os ângulos 0, 45, 90 e 135 graus, e para cada ângulo as distâncias 1 e 4 pixels, totalizando 56 atributos para cada amostra. Para cada conjunto de imagens foi gerado um arquivo ARFF contendo os valores extraídos da textura das amostras, pela matriz de co-ocorrência .

Utilizando o ambiente de análise de experimentos do projeto DTCOURO, foram executados os 3 arquivos de relações e atributos (ARFF), cada um de

uma vez. O método de validação utilizado foi o de validação cruzada (*Cross-Validation*) [41], esta técnica é ilustrada na Figura 5.5.

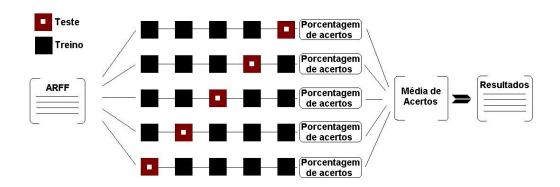


Figura 5.5: Validação Cruzada (Cross-Validation)

A validação cruzada representada na Figura 5.5 mostra como são trabalhadas as características extraídas das amostras. Neste caso cada linha representa 100% do Arquivo ARRF, sendo 80% do arquivo para treino e 20% para teste. Em cada repetição da linha, neste caso 5 vezes, todas têm as mesmas porcentagens, todavia, o teste adquire partes diferentes do arquivo em cada repetição. Para cada uma das 5 repetições é calculada a porcentagem dos acertos de cada linha e ao final, feita a média de todos os acertos. O resultados obtidos tornam mais eficaz a análise dos dados [41].

Foram também determinados alguns algoritmos para classificação, disponíveis no WEKA. Os algoritmos tiveram sua seleção baseada na sua utilização em processos de classificação encontrados na literatura e sua eficiência em outros sistemas de classificação baseados em textura. São eles:

- Naive Bayes Classifier Classificador Naive Bayes [18]
- J48 Implementação do Algoritmo C4.5 [37]
- MultilayerPerceptron Perceptron Multicamadas [6]
- Bayes Network Classifier Classificador de Redes Bayesianas [29]

Alguns critérios para avaliação do módulo, também foram estabelecidos. São eles:

- Porcentagem de Acerto (%)
- Taxa de Falso Positivo (%)

5.2. Resultados CCET - UCDB

- Tempo Treinamento (ms)
- Tempo de Teste (ms)
- Matriz de Confusão

Os critérios de porcentual de acerto, taxa de falso positivo, tempo de treinamento, tempo de teste e matriz de confusão, foram escolhidos para obter uma medida de eficiência do sistema mediante os algoritmos de classificação selecionados. A matriz de confusão escolhida para todos foi a com os resultados utilizando o algoritmo MultilayerPerceptron.

| Legenda | Classificador |
|--------------------|--------------------------|
| (NBC) | Naive Bayes Classifier |
| $\overline{(J48)}$ | J48 |
| $\overline{(MlP)}$ | Multilayer Perceptron |
| $\overline{(BNC)}$ | Bayes Network Classifier |

Tabela 5.1: Legenda dos Classificadores

5.2 Resultados

A seguir são apresentados os resultados em forma de tabela e em seguida a matriz de confusão do algoritmo que obteve o melhor resultado em cada conjunto de imagens. O fato de ter escolhido 3 conjuntos de imagens mostrará a eficiência de cada algoritmo nos diferentes conjuntos de teste. O primeiro conjunto de imagens analisado é o de couro cru com 3 peças de couro inteiras. Faz parte do segundo conjunto as 7 imagens de couro no estágio wet-blue, que possuem um único defeito em cada peça. O terceiro e último conjunto é o de uma única peça de couro wet-blue com 2 tipos de defeitos. A matriz de confusão tem uma importância fundamental neste trabalho, pois relata quais defeitos os algoritmos enxergam como "iguais".

5.2. Resultados CCET - UCDB

Tabela 5.2: Tabela de resultados do primeiro conjunto de amostras (3 Couros Cru)

| Algoritmos | (BNC) | (NBC) | (J48) | (MLP) |
|-----------------------------|----------|-----------|------------|------------|
| Porcentagem de Acertos (%) | 99.16000 | 99.16000 | 97.80000 • | 99.76000 |
| Taxa de Falso Positivo (%) | 0.00533 | 0.00244 | 0.00711 | 0.00133 |
| Tempo de Treino (ms) | 0.32801 | 0.03469 • | 0.21204 • | 54.76343 0 |
| Tempo de Classificação (ms) | 0.00859 | 0.05764 0 | 0.00016 • | 0.00770 |

o, • estatisticamente significante melhora ou degradação

| \overline{a} | b | c | d | e | f | g | |
|----------------|----|----|----|----|----|-----|-------------------------|
| 49 | 0 | 0 | 0 | 0 | 1 | 0 | a = carrapato |
| 0 | 50 | 0 | 0 | 0 | 0 | 0 | b = marca a fogo |
| 0 | 0 | 50 | 0 | 0 | 0 | 0 | c = riscoaberto |
| 0 | 0 | 0 | 50 | 0 | 0 | 0 | d = riscofechado |
| 1 | 0 | 0 | 0 | 49 | 0 | 0 | e = furodees fola |
| 0 | 0 | 0 | 0 | 0 | 50 | 0 | f = fotossensibilizacao |
| 0 | 0 | 0 | 0 | 0 | 0 | 200 | g = semdefeito |

Tabela 5.3: Matriz de Confusão - Primeiro Conjunto

Tabela 5.4: Tabela de resultados do segundo conjunto de amostras(7 Couros Wet-Blue)

| Algoritmos | (BNC) | (NBC) | (J48) | (MLP) | |
|-----------------------------|----------|----------|----------|-------------|---|
| Porcentagem de Acertos (%) | 98.46000 | 99.54545 | 97.25455 | • 100.00000 | |
| Taxa de Falso Positivo (%) | 0.00010 | 0.00000 | 0.00100 | 0.00000 | |
| Tempo de Treino (ms) | 0.04801 | 0.05123 | 0.42045 | o 71.86951 | 0 |
| Tempo de Classificação (ms) | 0.09259 | 0.09627 | 0.00079 | • 0.00644 | • |

 $[\]circ, \, \bullet \,$ estatisticamente significante melhora ou degradação

5.2. Resultados CCET - UCDB

| \overline{a} | b | c | d | e | f | g | |
|----------------|----|----|----|----|----|-----|-------------------------|
| 50 | 0 | 0 | 0 | 0 | 0 | 0 | a = carrapato |
| 0 | 50 | 0 | 0 | 0 | 0 | 0 | b = marca a fogo |
| 0 | 0 | 50 | 0 | 0 | 0 | 0 | c = riscoaberto |
| 0 | 0 | 0 | 50 | 0 | 0 | 0 | d = riscofechado |
| 0 | 0 | 0 | 0 | 50 | 0 | 0 | e = furodees fola |
| 0 | 0 | 0 | 0 | 0 | 50 | 0 | f = fotossensibilizacao |
| 0 | 0 | 0 | 0 | 0 | 0 | 200 | g = semdefeito |

Tabela 5.5: Matriz de Confusão - Segundo Conjunto

Tabela 5.6: Tabela de resultados do terceiro conjunto de amostras (1 Couro Wet-Blue)

| Algoritmos | (BNC) | (NBC) | (J48) | (MLP) |
|-----------------------------|----------|-----------|-----------|------------|
| Porcentagem de Acertos (%) | 99.03333 | 99.13333 | 98.91667 | 99.18333 |
| Taxa de Falso Positivo (%) | 0.00000 | 0.00000 | 0.00050 | 0.00000 |
| Tempo de Treino (ms) | 0.29204 | 0.05422 • | 0.19488 • | 58.98796 ∘ |
| Tempo de Classificação (ms) | 0.00514 | 0.04766 • | 0.00046 | 0.00799 |

o, • estatisticamente significante melhora ou degradação

| \overline{a} | b | c | |
|----------------|-----|-----|----------------|
| 200 | 0 | 0 | a = carrapato |
| 0 | 197 | 3 | b = sarna |
| 0 | 2 | 198 | c = semdefeito |

Tabela 5.7: Matriz de Confusão - Terceiro Conjunto

5.3 Análise dos Resultados

Os resultados avaliados pelo ambiente de análise de experimentos do projeto DTCOURO, mostram a classificação dos valores dos atributos extraídos através do extrator de características. De um modo geral os resultados foram satisfatórios, e quase todos os algoritmos encontraram um limiar bem alto de porcentagem de acerto. Algumas diferenças entre os algoritmos aparecem, por exemplo na Tabela 5.4, em que as amostras do segundo conjunto, juntamente com o algoritmo *MultilayerPerceptron*, resultou na maior porcentagem de acerto e também uma das menores taxas de falso positivo.

O algoritmo NBC teve o melhor desempenho no tempo de treinamento na maioria dos conjuntos e o pior tempo de classificação.

No algoritmo J48 apesar de apresentar a pior porcentagem de acerto e pior taxa de falso acerto em todos os testes, ele foi o mais rápido no quesito tempo classificação entre todos os algoritmos.

No geral estes algoritmos tiveram resultados muito bons e acima do esperado. O maior problema encontrado foi o tempo de treinamento do algoritmo MLP, o mesmo foi muito elevado, mais ou menos uma hora para o treinamento de cada conjunto de dados. Visualizando os resultados de classificação, podemos perceber que outros algoritmos têm seus tempos de treinamento muito velozes, todos com menos de 50 segundos, com isso podem facilmente substituir o MLP, pois eles tiveram uma porcentagem de acertos elevada. Mais detalhes sobre o algoritmo MLP podem ser encontrados em [8]. A Tabela 5.8 mostra em um quadro simples os melhores resultados dos algoritmos em todos os testes.

| | BNC | NBC | J48 | MLP |
|-----------------------------|------------------|------------------|---------|---------|
| Procentagem de Acertos (%) | 99, 16 | 99,54 | 98, 91 | 100,00• |
| Taxa de Falso Positivo (%) | $0,0000 \bullet$ | $0,0000 \bullet$ | 0,0005 | 0,0000• |
| Tempo de Treino (ms) | 0,048 | $0,034 \bullet$ | 0, 194 | 54,763 |
| Tempo de Classificação (ms) | 0,0051 | 0,0476 | 0,0001• | 0,0064 |

• melhor em todos os resultados)

Tabela 5.8: Melhores Resultados dos Algoritmos

Na primeira matriz de confusão podemos visualizar na sua classificação: apenas uma amostra do tipo furo de esfola foi confundida com uma amostra de carrapato. A confusão entre as amostras desses dois tipos de defeitos analisados neste experimento, pode ter ocorrido pelo fato de que os defeitos de carrapato e furo de esfola no couro cru, têm sua forma um pouco parecida em algumas amostras, e também no centro dos dois defeitos prevalece uma

cor mais escura. Nas Figuras 5.6 e 5.7 são ilustradas imagens de amostras de carrapato e furo de esfola em couro cru, de tamanho 10x10 pixels, que mostra texturas visivelmente parecidas. Os valores extraídos no arquivo ARFF, também tiveram uma relação muito próxima, diferente das outras amostras.

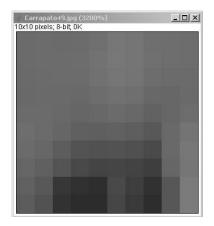




Figura 5.6: Amostra Carrapato

Figura 5.7: Amostra Furo de Esfola

A segunda matriz teve sua classificação perfeita, sem nenhum erro. Na última matriz percebemos a confusão entre amostras do tipo sem defeito e sarna. A causa das amostras de couro sem defeito e sarna terem se confundido, pode ser porque o defeito de sarna analisado na peça de couro possui sua parte interna totalmente cicatrizada e semelhante com a superfície sem defeito. Como o couro analisado está na forma wet-blue, o defeito de sarna apresenta a diferença de ser um pouco mais alto em relação a superfície do couro, o que em uma foto tirada no ângulo de 90 graus não consegue representar muito bem na textura da imagem. Nas Figuras 5.8 e 5.9 é visível a olho-nu a pouca diferença na textura das imagens. Estas figuras representam amostras sem defeito e de sarna no couro wet-blue, de tamanho 10x10 pixels. Possivelmente se esta mesma imagem do couro fosse na forma cru, estes defeitos não teriam sido confundidos, pois quando ocorre um problema de sarna no couro, após a cura, não crescem mais pêlos no local. Os resultados de todos os conjuntos de dados analisados forams satisfatórios em vista de um boa porcentagem de acerto.





Figura 5.8: Amostra Sarna

Figura 5.9: Amostra Sem Defeito

Capítulo 6

Conclusão e Trabalhos Futuros

6.1 Conclusão

Este trabalho foi baseado nas técnicas mais utilizadas no reconhecimento de padrões em imagens de diversas naturezas. Foi realizado um estudo a partir das técnicas mais utilizadas para segmentação baseada em textura, e técnicas utilizadas nos sistemas de detecção de defeitos em couro.

Foi montado um banco de imagens com os defeitos mais comuns no couro bovino, tanto no estágio cru como no wet-blue. Esta montagem do banco foi de grande utilidade para a realização dos testes do sistema, pois as imagens passaram por uma pré-classificação visual realizada pela equipe do DT-COURO, no momento em que eram fotografadas.

O módulo de geração de amostras permitiu que fossem geradas amostras de diversos tamanhos dos defeitos nas imagens, de modo que o processo de classificação fosse realizado de forma mais abrangente e simples.

A implementação do módulo de detecção de defeitos no couro bovino obteve resultados satisfatórios na classificação das imagens propostas. Os resultados obtidos através deste trabalho podem servir de contribuição à comunidade científica e acadêmica. Todo o material, bem como o código-fonte foi disponibilizado de forma livre e gratuita a todos que se interessarem pelo assunto.

6.2 Trabalhos Futuros

Ao sistema DTCOURO foi acrescentado, através deste projeto, um módulo para detecção de defeitos no couro bovino. Porém, esta área possui uma grande quantidade de técnicas diferentes com o mesmo objetivo: o reconhecimento de padrões em imagens de qualquer natureza. No decorrer

da aquisição de imagens para montagem do banco de dados referentes aos defeitos do couro bovino, foi observado em uma das visitas feitas ao curtume do frigorífico Independência no município de Nova Andradina em MS, uma forma mais fácil de identificar, visualmente, os defeitos no couro. Esse estágio é conhecido como "tripa", e se dá após o abate do bovino e antes da forma wet-blue, porém, este é um estágio em que o couro está sem pêlos. O couro na forma de tripa dura pouco tempo, pois ele tem que continuar na sua linha de processamento até chegar a forma wet-blue e por este motivo, não houve facilidade em analisar a peça de couro como foi feito na forma wetblue. Com o couro no estágio de tripa, a facilidade em detectar os defeitos no couro visualmente aumenta consideravelmente.

Uma possível continuação deste projeto poderia basear-se na montagem de um banco de imagens de couro bovino na forma tripa, devidamente préclassificado por um profissional da área. Não é uma afirmação que a segmentação e classificação baseadas em textura sejam a melhor forma de reconhecer os padrões nas imagens do couro na forma de tripa, contudo, é possível utilizar o módulo implementado com uma maior variedade de tamanhos de janelas, distâncias, ajustando o sistema para este tipo de necessidade.

Referências Bibliográficas

- [1] C.P. Abrahao, C.A.A. Varella, e F.A.C. PINTO. Quantificação da falha na madeira em juntas coladas utilizando técnicas de visão artificial. Revista Árvore, 27:71–78, 2003.
- [2] M.D. Abramoff, P.J. Magelhaes, e S.J. Ram. Image processing with imagej. In *Biophotonics International*, volume 11 de 7, páginas 36–42. 2004.
- [3] T.M. Apostol. *Mathematical Analysis*. aw, Reading, MA, segunda edição, 1974.
- [4] V.P. Baligar, L.M. Patnaik, e G.R. Nagabhushana. High compression and low order linear predictor for lossless coding of grayscale images. *Image and Vision Computing*, 21(6):543–550, June 2003.
- [5] D.H. Ballard e C.M. Brown. *Computer vision*. Prentice-Hall, Englewood Cliffs, NJ, 1992.
- [6] J. Basak. Online adaptive decision trees. *Neural Computation*, 16(9):1959–1981, 2004. ISSN 0899-7667.
- [7] L.S. Bins, G.J. Erthal, e L.M.G. Fonseca. Um método de classificação não supervisionada por regiões. In *In Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens*. 1992.
- [8] Genevieve B.O. e K. Müller, editores. Neural Networks: Tricks of the Trade, this book is an outgrowth of a 1996 NIPS workshop, volume 1524 de Lecture Notes in Computer Science. Springer, 1998. ISBN 3-540-65311-2.
- [9] C.R. Brice e C.L. Fenema. Scene analysis using regions. AI, 1:205–226, 1970.

- [10] S.F. Brito e J.M. Carvalho. Sistemas de processamento digital de imagens para fins didático/científico: estudo seleção e implementação de algoritmos de segmentação, Agosto 1998.
- [11] K.R. Castleman. *Digital Image Processing*. Prentice Hall, Englewoods Cliffs, New Jersey, 1979.
- [12] C.H. Chen, L.F. Pau, e P.S.P. Wang. *The handbook of pattern recong*nition and computer vision. World Scientific Publishing Co, segunda edição, 1998.
- [13] H. D. Cheng, Yen-Hung Cheng, e Ying Sun. A novel fuzzy entropy approach to image enhancement and thresholding. *Signal Process.*, 75(3):277–301, 1999. ISSN 0165-1684.
- [14] W. Chin-Hsiung, H. Shi-Jinn, L. Pei-Zong, L. Shung-Shing, e L. Shih-Ying. A new computation of shape moments via quadtree decomposition. j-LECT-NOTES-COMP-SCI, 1800:123—??, 2000. ISSN 0302-9743.
- [15] G.B. Coleman e H.C. Andrews. Image segmentation by clustering. *IEEE*, 16:773–785, 1979.
- [16] B.M. Dawson. Introduction to image processing algorithms. Byte, MAR 1987.
- [17] J.C. Felipe e A.J.M. Traina. Utilizando características de textura para identificação de tecidos em imagens médicas, 2002.
- [18] H.J. George e P. Langley. Estimating continuous distributions in bayesian classifiers. In *Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence*, páginas 338–345. Morgan Kaufmann, 1995.
- [19] L. Georgieva, K. Krastev, e N. Angelov. Leather features selection for defects recognition using fuzzy logic. *International Conference on Com*puter Systems and Technologies, 2004.
- [20] R.C. Gonzales e R.E. Woods. *Processamento de imagens digitais.*. In Edgar Blucher ltda, 1992.
- [21] R.C. Gonzalez e P. Wintz. *Digital image processing*. Addison-Wesley, segunda edição, 1987.
- [22] T. Hanning e G. Pisinger. A pixel-based segmentation algorithm of color images by n-level-fitting. *Computer Graphics and Imaging*, 2002.

- [23] R. Haralick. *Encyclopedia of Art Intelligence*, volume vol. 2. hecidas John Wiley and Sons, Inc., 1992.
- [24] R.M. Haralick, K. Shanmugam, e I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems*, 3(6):610–621, November 1973.
- [25] R. Hirata. Segmentação de imagens por morfologia matemática. Tese de Mestrado, Instituto de Matemática e Estatística, IME - USP, São Paulo, Brasil, 1997.
- [26] H.W. Ian e E. Frank. Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations. Morgan Kaufmann, 1999.
- [27] Ieee standard 610.4-1990 IEEE. standard glossary of image processing and pattern recognition terminology. New York: IEEE Press, 1990.
- [28] A.K. Jain. Fundamentals of Digital Image Processing. Prentice Hall, Englewood Cliffs, NJ, USA, 1989.
- [29] P. Judea e R. Stuart. Bayesian networks. In M. A. Arbib, editor, Handbook of Brain Theory and Neural Networks, páginas 157–160. MIT Press, Cambridge, MA, USA, 2003.
- [30] G.W. Krutz, H.G. Gibson, D.L. Cassens, e Zhang M. Machine vision: Colour vision in forest and wood engineering. *Landwards*, 55:pp. 2–9., 2000.
- [31] G. Louverdis, I. Andreadis, e Ph. Tsalides. A new fuzzy model for morphological colour image processing. *IEEE Proc. Vision, Image & Signal Processing*, 149(3):129–139, 2002.
- [32] I.H. Mannsour. Visualização colaborativa de dados científicos com ênfase na área médica, Outubro 1998. Exame de Qualificação.
- [33] M.L. Martinez e M. A. Machado. Programa genoma brasileiro de bovinos e suas perspectivas de aplicações práticas. In *Anais do IV Simpósio Nacional de Melhoramento Animal*. 2002.
- [34] J.G. Moik. Digital processing of remotely sensed images. NASA SP, Washington DC, 1980.
- [35] H. P. PISTORI, P. S. MARTINS, M. C. PEREIRA, CASTRO JR. A. A., e J.J. NETO. Sigus - plataforma de apoio ao desenvolvimento de sistemas para inclusão digital de pessoas com necessidades especiais. IV

- Congresso Iberdiscap: Tecnologias de Apoio a Portadores de Deficiência, 2006.
- [36] C. B. Proença, A. Conci, e Segenreich S. A. Investigação para detecção automática de falhas têxteis. *Journal of the Brazilian Society of Mechanical Sciences*, 21:493–507, 1999.
- [37] J.R. Quinlan. C4.5: Programs for Machine Learning. Morgan Kaufmann, 1993.
- [38] T.R. Reed e J.M. Hans Du Buf. A review of recent texture segmentation and feature extraction techniques. *Computer Vision, Graphics and Image Processing: Image Understanding*, 57(3):359–372, may 1993.
- [39] C. Ruberto, S. Vitulano, e G. Rodriguez. Image segmentation by texture analysis. In 10th International Conference on Image Analysis and Processing. 1999.
- [40] E. Salari e W. Li. A fast quadtree motion segmentation for image sequence coding. *Signal Processing: Image Communication*,, 14:811–816, Agosto 1999.
- [41] C. Schaffer. Selecting a classification method by cross-validation. In Fourth Intl. Workshop on Artificial Intelligence & Statistics, páginas 15–25. January 1993.
- [42] W.R. Schwartz e H. Pedrini. Segmentação de imagens de terrenos baseada na associação de características de texturas com dependência espacial modelada por campo aleatório de markov. In *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*. Abril 2005.
- [43] M. Sonka, V. Hlavac, e R. Boyle. *Image Processing: Analysis and Machine Vision*. O'Reilly, 1999. SON m 99:1 1.Ex.
- [44] M. Sonka, V. Hlavac, e R. Boyle. *Image processing, analysis, and machine vision.*, volume 1. Brooks/Cole Publishing Company, segunda edição, 1999.
- [45] F.P.C. Souza e A.A. Susin. Localização e leitura automática de caracteres alfanuméricos uma aplicação na identificação de veículos, April 2000.
- [46] S.E. Umbaugh. Computer Vision And Image Processing: A Practical Approach Using Cviptools, Prentice-Hall, Upper Saddle River. 1997.

[47] D. Xiaoyan e J. Maeda. Fuzzy based unsupervised segmentation of textured color images. In ICIP (3), páginas 293–296. 2002.