

Desenvolvimento de um Software de Processamento e Geração de Imagens para Classificação de Couro Bovino

Willian P. Amorim, Roberto Viana,
Ricardo Rodrigues, Hemerson Pistori (orientador)
Grupo de Pesquisa em Engenharia de Computação (GPEC)
Universidade Católica Dom Bosco (UCDB)
Av. Tamandaré, 6000, Jardim Seminário, 79117-900, Campo Grande - MS - Brasil
{paraguassuec, hbdbobs, rikardocezar}@gmail.com, pistori@ucdb.br

Resumo

Este artigo apresenta um software para processamento e geração de amostras de couro para treinamento de detectores de defeitos baseados em aprendizagem automática. O software também oferece recursos para pré-processamento das amostras, marcação e rotulação de regiões defeituosas, além da extração de atributos baseados em textura e cor. Serão apresentados também alguns experimentos e resultados na detecção automática de defeitos em couro wet-blue, utilizando matrizes de co-ocorrência para extração de atributos e indução de árvores de decisão para aprendizagem automática.

1. Introdução

Apesar de possuir o maior rebanho bovino do planeta, o Brasil ainda não consegue assumir um papel de destaque na indústria do couro bovino. A maior parte do couro produzido no país é de baixa qualidade, sendo que a maioria desse couro é comercializada nos estágios iniciais de processamento, com baixo valor agregado. A baixa qualidade do couro bovino brasileiro tem limitado o desenvolvimento do setor coureiro, afetando também a capacidade do país agregar valor ao produto internamente e de usufruir das oportunidades oferecidas pela comercialização do couro acabado, de melhor cotação no mercado [3].

O grande fator limitante para a melhoria da qualidade do couro bovino é a inexistência de sistemas de remuneração diferencial pela qualidade da matéria prima produzida [1]. Atualmente, o couro é remunerado através do sistema “bica corrida”, isto é, em média, o pecuarista recebe pelo couro cerca de 7 a 8% do valor da arroba do boi gordo, independente de sua qualidade [2]. A partir das dificuldades encontradas para o problema da qualidade do couro bo-

vino, foi proposto um sistema de classificação de couro verde e harmonizado. Esse sistema foi estabelecido pelo Ministério da Agricultura, Pecuária e Abastecimento por meio da Instrução Normativa Nº 12, em 18 de dezembro de 2002 [5]. Com essa norma foi estabelecido o critério de classificação do couro bovino, através dos defeitos encontrados na pele do animal.

Para a automatização desse processo foi proposta a criação do projeto DT-COURO. O objetivo do projeto DT-COURO é o desenvolvimento de um sistema automático de extração de parâmetros, treinamento e classificação das peles ou couro bovinos através de imagens pré-processadas e selecionadas. Diferentes problemas foram encontrados, para o desenvolvimento inicial desse projeto, como: baixa quantidade de imagens de couros bovinos, baixa quantidade de imagens de diferente tipos de defeitos (carapato, berne, risco, sarna, entre outros) em seus diversos processos, complexidade de identificação visual dos defeitos, entre outros.

Para solucionar esses problemas, foi desenvolvido esse trabalho, que teve como objetivo principal, a criação de um módulo computacional capaz de controlar a construção de um banco de imagens de couros bovinos. O módulo também fornece operação de marcação sobre os defeitos encontrados, marcações sobre regiões de interesse, e armazenamento dessas informações em um banco de dados. Problemas como baixa quantidade de imagens de diferentes tipos de defeitos, foram resolvidos com o desenvolvimento de uma técnica de varredura sobre o banco e geração de amostras sobre os defeitos em diversas escalas. Todas essas operações desenvolvidas farão com que algoritmos de aprendizagem, técnicas de extração de atributos e algoritmos de classificação, tenham uma base consistente para a realização de testes para identificação de defeitos e classificação de couros bovinos.

Na realização dos experimentos, foram utilizados algumas imagens com dois tipos de iluminação (com *flash* e

sem *flash*) de couro bovino no processo de curtimento *wet-blue*¹. Alguns defeitos como: (carrapato, marca ferro, risco e sarna) e imagens sem defeitos, foram selecionados para testes de identificação. Os métodos utilizados na extração de atributos para classificação foram a matriz de co-ocorrência e o espaço de cores HSB. Para realização dos experimentos, foram criados três grupos de testes que foram: grupo de amostras com defeitos sem *flash*, grupo de amostras com defeitos com *flash* e um grupo de amostras com defeitos misto (com *flash* e sem *flash*). Os resultados obtidos mostraram que o módulo de geração de amostras auxiliou o classificador do DTCOURO melhorando seu desempenho.

Nesse artigo apresentaremos métodos e tecnologias que foram utilizados para a implementação do módulo. Na seção 2, apresentaremos três ferramentas tecnológicas, que foram integradas, sendo uma para processamento de imagens, outra para aprendizagem de máquina e a terceira para armazenamento dos dados. Apresentaremos também uma seção mostrando o banco de dados utilizado e uma seção descrevendo o desenvolvimento do módulo. Na seção 5 e 6 apresentaremos os métodos de extração de atributos que foram utilizados para a medição do desempenho do módulo implementado. Na seção 7 e 8 são demonstrados os experimentos e resultados realizados sobre couros bovinos e na seção 9 apresentaremos as conclusões.

2. Ferramentas Auxiliares

Para a utilização de recursos de processamento digital de imagens e visão computacional, foi proposta a utilização do pacote *ImageJ*, que é uma ferramenta multi-plataforma, do software *NIH Image*, para *Macintosh*. Entre os recursos oferecidos pelo pacote, destacamos a disponibilidade de programas-fonte abertos de diversos algoritmos como: manipulação dos mais variados formatos de arquivo de imagens, detecção de bordas, melhoria de imagens, cálculos diversos (áreas, médias, centróides) e operações morfológicas.

O segundo pacote proposto para a utilização no desenvolvimento desse módulo foi o *WEKA (Waikato Environment for Knowledge Analysis)*[11], também escrito em Java e com programas-fonte abertos. O *WEKA* é um ambiente bastante utilizado em pesquisas na área de aprendizagem de máquina, pois oferece diversos componentes que facilitam a implementação de classificadores. Além disto, esse ambiente permite que novos algoritmos sejam comparados a outros algoritmos já consolidados na área de aprendizagem, como o *C4.5*, o *Backpropagation*, o *KNN* e o *naiveBayes*, entre outros [7].

¹ Wet-blue é um couro já obtido na fase de curtimento, mais especificamente na operação chamada rebaixe

Para a criação do banco de imagens de couros bovinos, foi utilizado o banco de dados *PostgreSQL*. O *postgreSQL* é um banco de dados relacional. Uma de suas grandes características é a de possuir recursos comuns a banco de dados de grande porte, sendo também um banco de dados versátil, seguro e gratuito.

3. Banco de Dados

Devido à grande quantidade de informações e imagens que devem ser armazenadas para garantir uma classificação confiável, o projeto DTCOURO foi integrado com um banco de dados Postgres. O banco de dados proposto para o módulo permite que dados como estágio, região, tipo de marcação e tipo de defeitos de uma determinada imagem do couro, sejam cadastrados durante o processo de treinamento para o reconhecimento de defeitos. Entre as entidades do modelo relacional as principais são:

- Imagem - responsável pelo armazenamento e controle de todas as imagens de peças do couro bovino em seu formato original e suas informações;
- Marcação - sua principal função é armazenar todas as marcações realizadas em uma imagem, ou seja, regiões da imagem que apresentem características importantes para o treinamento. Cada marcação será representada através de um tipo especial de dados *polygon* do postgres.
- Amostra - conterá todas as amostras geradas pelo módulo. Essa entidade será a base principal para a manipulação, extração e teste de classificação.

O banco do sistema DTCOURO possui algumas características como armazenamento do código binário das imagens no próprio banco e a utilização de técnicas de georeferenciamento. Tais características facilitaram a implementação do módulo, tornaram o acesso as imagens mais simples, permitindo cálculos geométricos sobre imagens de maneira eficiente.

4. Módulo de aquisição, marcação e geração de amostras

O módulo implementado auxilia nas seguintes fases de processamento: (1) aquisição de imagens, (2) pré-processamento, (3) marcação e rotulação das principais áreas que concentram os defeitos, (4) geração de imagens para testes e (5) aprendizagem e testes de classificação das amostras geradas.

Para a fase de aquisição de imagens, foi criada uma janela de seleção, em que o usuário poderá pré-visualizar imagens que servirão como base de trabalho. Uma janela

também foi criada, que servirá para o cadastro e consultas de todas as informações referente às imagens. Essas informações serão cadastradas e visualizadas à medida que imagens são requisitadas. A Figura 1 ilustra a fase de aquisição de imagens.

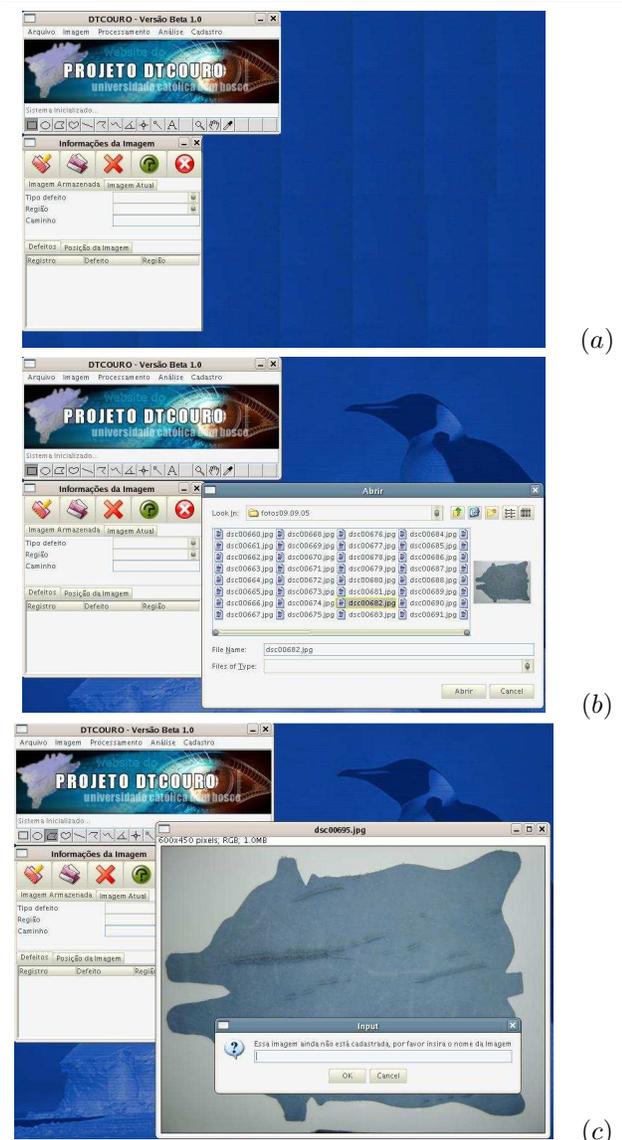


Figura 1. Imagens do módulo de pré-processamento e geração de imagens para o treinamento e testes de classificação de peles e couros bovinos: (a) Tela inicial do módulo, (b) Tela de seleção de imagens, (c) Tela de cadastro de imagens

Na fase de pré-processamento o módulo disponibiliza

ao usuário a opção de realizar processamentos nas imagens como: filtros (convolução, filtros de Fourier), limiarização, detector de bordas, conversão de formato de cores(RGB, HSB), entre outros. Na fase de marcação e rotulação o usuário poderá realizar marcações sobre regiões de interesse. A cada marcação, o módulo cria um registro no banco de imagens, contendo informações capturadas do usuário como: nome do defeito marcado, tipo de defeito selecionado, região da marcação e a imagem marcada. A Figura 2 mostra um exemplo de pré-processamento.

A marcação é feita utilizando o conceito de máscara. Em qualquer marcação realizada sobre a imagem, o módulo captura a informação do polígono desenhado, armazenando no banco de dados. A Figura 3 mostra o processo de marcação. O módulo também oferece a opção de calibragem da marcação, podendo dessa forma capturar a região em centímetros ou milímetros. Essa função é chamada a partir que a imagem é requisitada, pedindo ao usuário a medida referente a cada pixel.

Todas essas informações são armazenadas automaticamente a cada marcação, fazendo com que a imagem original não seja modificada, apenas que seja criada uma máscara sobre a imagem. Dessa forma o módulo realiza a marcação visual à medida que a imagem é solicitada, caso isso ocorra, o módulo buscará no banco de dados todas as informações referentes às marcações. Caso exista alguma marcação referente à imagem, o módulo recupera com base nas informações armazenadas.

Na fase de geração de imagens de testes, o módulo utiliza a base de imagens marcadas e armazenadas no banco de dados. Para a geração dessas amostras é utilizado o modo de varredura. Esse modo de geração tem como objetivo principal varrer a imagem requisitada, e através das informações capturadas do usuário como: marcação selecionada, quantidade de amostras a serem geradas, largura e comprimento em pixel de cada amostra, percorrer a imagem e criar as amostras. Dessa forma o módulo cria um banco de amostras específicas para cada tipo de defeito selecionado. Esta fase ajudará a aumentar o banco de informações, com amostras mais específicas, referente a cada tipo de defeito para cada fase de processamento do couro bovino. A Figura 4 ilustra a fase de geração de amostras.

Na fase de aprendizagem e testes de classificação o módulo toma como base o banco de amostras gerado para cada tipo de defeito. Essas amostras farão com que os algoritmos de extração de atributos realizem suas análises e gerem um arquivo no formato de reconhecimento do WEKA. Podemos assim então obter facilmente, através do WEKA, resultados estatísticos comparativos que ajudarão na escolha dos melhores métodos de aprendizagem.

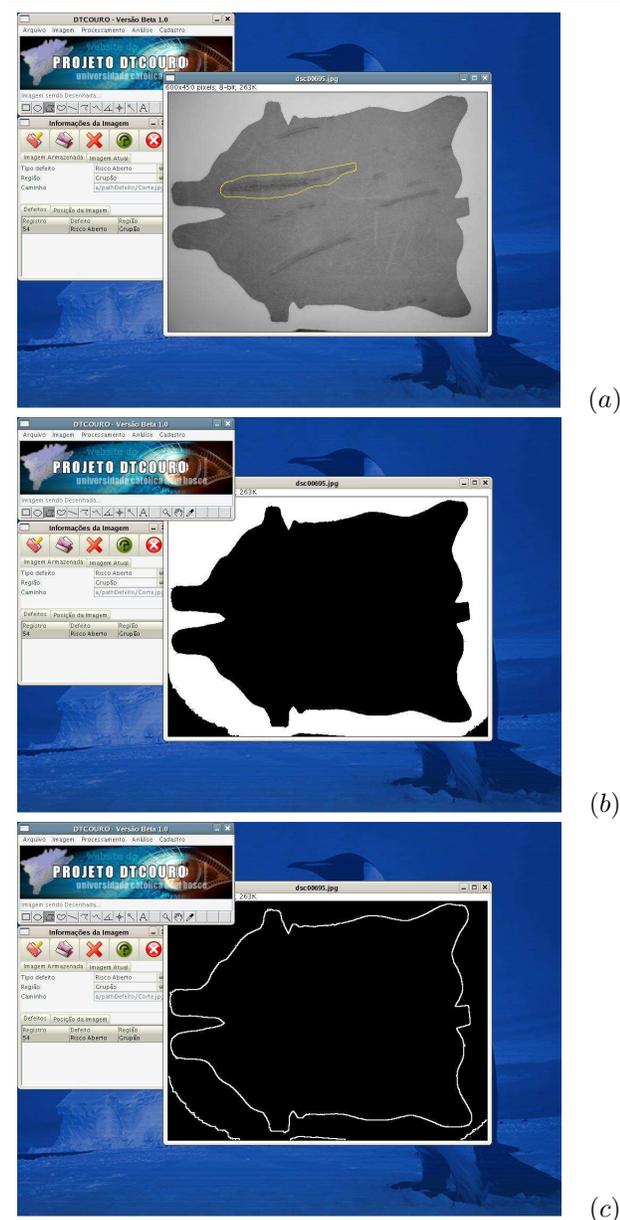


Figura 2. Imagens do módulo de pré-processamento e geração de imagens para o treinamento e testes de classificação de peles e couros bovinos: (a) Imagem sendo transformada para 8-bit (b), Imagem sendo binarizada, (c) Imagem sendo passada pelo processo de convolução para detecção de bordas

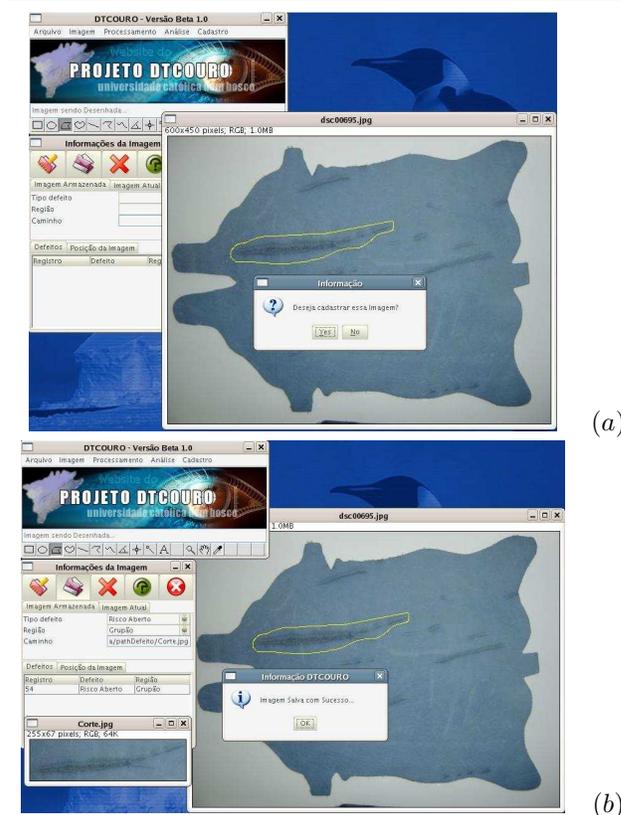


Figura 3. Imagens do módulo de pré-processamento e geração de imagens para o treinamento e testes de classificação de peles e couros bovinos: (a) Exemplo de marcação (b) Cadastro no banco da marcação realizada

5. Matriz de co-ocorrência

Matriz de co-ocorrência é uma forma de calcular a partir do nível de cinza de uma imagem digital, a frequência da ocorrência de dois em dois pixels, em uma certa direção e a uma certa distância [6]. A matriz de co-ocorrência de níveis de cinza fornece relações espaciais de uma imagem, possibilitando a extração de atributos representando suas características de textura[10].

Os atributos que foram escolhidos para a extração sobre a matriz de co-ocorrência foram: entropia, momento da diferença inversa, dissimilaridade, correlação, contraste, segundo momento angular e a diferença inversa. Entropia em uma imagem é o nível de variação na intensidade entre os pixels da mesma. Imagens com pouca variação (ex.: céu azul) apresentam um valor de entropia baixo e imagens com muita variação (ex.: couro) tem um valor maior de en-

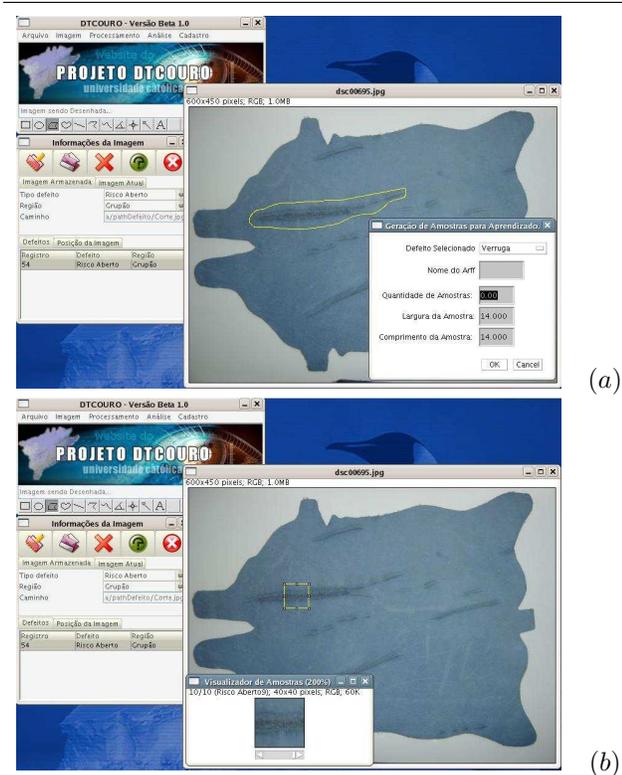


Figura 4. Imagens do módulo de pré-processamento e geração de imagens para o treinamento e testes de classificação de peles e couros bovinos: (a) Tela de opções para a geração de amostras (b) Visualização das amostras geradas

tropia. Momento da Diferença Inversa (MDI) é a medida da quantidade de homogeneidade local. Valores maiores de MDI apresentam maior similaridade entre os pixels do local. A dissimilaridade mede o grau de diferença nos níveis de cinza de pares de pixels. Quanto maior a diferença entre os pixels maior a dissimilaridade. Correlação é a medida das dependências lineares dos tons de cinza. Quanto maior a dependência maior a correlação. Contraste é a medida de variação local presente em uma imagem, geralmente utilizado para encontrar bordas na área de interesse. Segundo Momento angular é a medida de uniformidade de uma região da imagem. Essa uniformidade é calculada sobre a textura da imagem. O segundo momento angular tende a 1 quando a área é mais uniforme e tende a zero caso a área não seja uniforme [8].

6. Espaço de Cores HSB

O modelo de cor HSB se baseia na percepção humana das cores e não nos valores de RGB². Isso por que a mente humana não separa tão facilmente as cores em modelos de vermelho/verde/azul ou ciano/magenta/amarelo/preto. O olho humano vê cores como componentes de matiz, saturação e brilho [4]. Em termos gerais, o matiz se baseia no comprimento da onda de luz refletida de um objeto ou transmitida por ele, que concentra a maior parte da energia, no espectro do sinal visível. A Saturação é a quantidade de cinza de uma cor, quanto mais alta a saturação, mais intensa é a cor, e brilho é a medida de intensidade da luz em uma cor. Essas informações H (matiz, *hue*), S (saturação, *saturation*) e B (brilho, *brightness*) serão capturadas das amostras e calculado seu valor médio de presença. Esses valores serão utilizados como atributos de cores para a realização dos testes.

7. Experimentos

Para a realização dos testes foi criado um banco de imagens, com diferentes tipos de defeitos de couros bovinos no estágio de processamento wet-blue. Todas essas imagens foram pré-cadastradas no módulo de geração de amostras, e em seguida para cada uma dessas imagens foram realizadas as marcações referentes aos seus específicos defeitos. Com essas informações armazenadas no banco de dados, foi possível realizar então a fase de geração de amostras. Nessa fase, o módulo utilizou todos os dados das rotulações para realizar uma varredura sobre os tipos de defeitos pré-cadastrados, criando dessa forma um maior conjunto de amostras de diferentes tipos de defeitos.

Para cada imagem, foram realizadas duas marcações, uma referente ao defeito específico, e outra marcação referente à região sem defeito. Um dos principais motivos para esse tipo de regra de marcação, foi a necessidade de se obter uma maior variação de regiões sem defeitos próximas a regiões com defeitos. Para a realização desses testes iniciais foram utilizadas 8 imagens, com a seguinte organização: 4 imagens com *flash* e 4 imagens sem *flash*, sendo duas imagem para cada tipo de defeito (carrapato, marca fogo, risco e sarna). Esse tipo de alteração na iluminação, faz parte de um conjunto de testes, para verificação da influência das variáveis de ambiente (iluminação, distância do objeto, superfície da localização do objeto, entre outros) sobre o classificador. Inicialmente, pela falta de imagens, foi testada somente a característica de iluminação. As imagens com regiões sem defeito serão retiradas das próprias imagens selecionadas, próximas aos defeitos, sendo identificadas como

2 RGB é um modelo de cor com três cores primárias: vermelho, verde e azul. A sigla RGB deriva da junção das primeiras letras dos nomes destas cores primárias em língua inglesa: Red, Green e Blue

sem defeito. A figura 5 ilustra os tipos de defeitos utilizados no estado wet-blue.

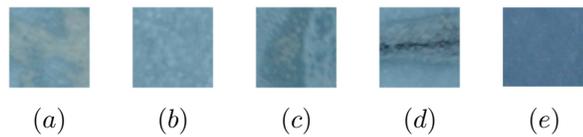


Figura 5. Imagens de defeitos do couro bovino no processo wet-blue. (a) defeito sarna, (b) defeito carrapato, (c) defeito marca ferro, (d) defeito risco, (e) sem defeito.

Em seguida, para cada marcação cadastrada no banco de dados, foram geradas 400 amostras na escala de 40X40 pixel, e divididas em três grupos, que são amostras com *flash*, amostras sem *flash* e amostras mistas (*flash* e sem *flash*). A escolha da escala 40X40 pixel, foi baseada em resultados de experimentos anteriores. Esses experimentos mostraram que em imagens com escalas maiores que 40X40 pixel não houve um ganho significativo em sua porcentagem de acerto. No caso de imagens com escalas menores, houve uma perda de informação, prejudicando sua classificação. A partir de cada amostra gerada, o módulo extraiu 63 tipos de atributos de textura utilizando matriz de co-ocorrência e 3 tipos de atributos de cor utilizando HSB, como mostra a Tabela 1.

Textura	Cor
Entropia	Média de H(Matiz)
Momento da Diferença Inversa	Média de S(Saturação)
Dissimilaridade	Média de B(Brilho)
Correlação	
Contraste	
Segundo Momento Angular	
Diferença Inversa	

Tabela 1. Atributos extraídos para o processo de treinamento

Para a realização dos primeiros experimentos foram utilizadas para cada escala, variações nas propriedades na análise da matriz de co-ocorrência, como variações nos ângulos e nas distâncias. Para cada atributo de textura foram obtidas variações nos ângulos com valores 0°, 45°, 90° e variações nas distâncias com valores 1,5, 10 pixel. Totalizando 66 tipos de atributos e 1200 amostras para cada tipo de defeito.

Com base nas amostras geradas e na extração dos atributos referente a cada amostra, o módulo gerou automaticamente o arquivo de interpretação do WEKA “*.arff”. Desse modo utilizamos a sessão de experimentos e as propriedades do WEKA, para a medição do desempenho do classificador. Inicialmente escolhemos como algoritmo de aprendizagem e classificação o C4.5 ou J48. O algoritmo C4.5 constrói uma árvore de decisão a partir de um conjunto de treinamento previamente fornecido. Este conjunto é composto por várias instâncias do problema, onde para cada uma são fornecidos valores para atributos e para uma classe. Os atributos podem conter valores discretos, contínuos e também o valor “nulo” que representa valores não especificados. As classes são representadas por valores discretos e não admitem valores nulos.

A árvore de decisão do C4.5 é construída a partir da raiz. Os nós folha representam as classes e os nós intermediários representam um teste sobre uma variável. São gerados sub-nós de um nó intermediário quando se define mais de uma classe para seu conjunto de instâncias. Quando ocorre uma subdivisão o atributo mais relevante é selecionado de acordo com algum critério. Caso o atributo seja discreto será criado um sub-nó para cada valor possível do atributo. No caso de atributos contínuos é definido um nível de corte e são gerados dois sub-nós, uma para valores maiores que e outro para valores menores que o nível de corte. Nós folha definem uma classe [9].

Para a realização dos experimentos, o WEKA escolhe como padrão, o modo de validação cruzada em 10 dobras. Esse modo de validação pega o total de amostras, mantém 90% para a aprendizagem e os 10% restante para a realização dos testes. Isso ocorre 10 vezes, sendo uma para cada 10% seguintes. Com esses 10 resultados é calculada sua média indicando sua porcentagem de acerto.

8. Resultados

A partir desses experimentos foram gerados a matriz de confusão dos testes de classificação, a árvore decisão do algoritmo C4.5 e a porcentagem de acerto, que serão utilizados para a análise do desempenho das técnicas implementadas.

Analisando a matriz de confusão das amostras com *flash*, sem *flash* e amostras mistas, como mostram as Tabelas 2, 3 e 4, pode-se perceber que houve grande discriminação entre as amostras com defeito e até mesmo regiões sem defeito. O fato de algumas amostras terem sido classificadas incorretamente, mostra que alguns tipos de defeitos apresentam valores semelhantes nos atributos selecionados para a discriminação. Espera-se uma elevação no grau de confusão com o aumento da quantidade de diferentes defeitos em diferentes situações. Também se pode constatar que alguns defeitos apresentam semelhanças, isso devido a apre-

sentar um textura de cicatriz muito semelhante. A Tabela 5 apresenta as principais semelhanças entre os tipos de defeitos.

a	b	c	d	e	
400	0	0	0	0	a-Carrapato
0	395	5	0	0	b-Marca Fogo
0	0	399	1	0	c-Risco Aberto
0	3	0	397	0	d-Sarna
0	0	0	0	400	e-Sem Defeito

Tabela 2. Matriz de confusão das amostras com *flash*

a	b	c	d	e	
398	0	2	0	0	a-Carrapato
1	398	0	1	0	b-Marca Fogo
0	0	398	0	2	c-Risco Aberto
0	2	0	398	0	d-Sarna
0	0	0	0	400	e-Sem Defeito

Tabela 3. Matriz de confusão das amostras sem *flash*

a	b	c	d	e	
397	2	0	1	0	a-Carrapato
2	397	0	1	0	b-Marca Fogo
2	3	394	0	1	c-Risco Aberto
2	3	0	395	0	d-Sarna
0	0	1	0	399	e-Sem Defeito

Tabela 4. Matriz de confusão das amostras mistas (com *flash* e sem *flash*)

Analisando a árvore de decisão gerada pelos três grupos avaliados (com *flash*, sem *flash*, misto), foi verificado que os atributos mais relevantes são: dissimilaridade com ângulo da matriz de co-ocorrência (90° - distância 1 e 90° - distância 5), diferença inversa com ângulo da matriz de co-ocorrência (0° - distância 1, 90° - distância 1, 0° - distância 10, 0° - distância 5), segundo momento angular com ângulo da matriz de co-ocorrência (90° - distância 5, 0° - distância 10, 90° - distância 1), valor médio de H (matiz, *hue*), S (saturação, *saturation*) e B (brilho, *brightness*).

Foi conseguido com esses primeiros experimentos uma taxa de 99.1% de acerto para amostras mistas, 99.55% de acerto para amostras com *flash* e 99.6% de acerto para amostras sem *flash*. Em um total de 6000 amostras avali-

Defeito	Defeitos semelhantes
Carrapato	Marca Ferro e Risco
Marca Ferro	Carrapato e Risco
Risco	Carrapato, Sarna e Sem Defeito
Sarna	Carrapato e Marca Ferro
Sem Defeito	Risco

Tabela 5. Defeitos semelhantes analisados

adas, foram classificadas corretamente 5965 e 45 amostras incorretas.

9. Conclusão

A detecção de defeitos e a classificação do couro bovino, com base em inspeção visual, é uma importante etapa da cadeia produtiva do boi. A automatização desse processo, através de sistemas computacionais, pode torná-lo mais preciso, menos subjetivo, menos sujeito a falhas e mais uniforme.

Com base nos resultados gerados, foi verificado que apesar das variações do ambiente, o classificador apresentou um bom resultado, reforçando as expectativas de que será possível a implantação de um classificador automático de couros bovinos. A baixa quantidade de imagens, favoreceu o alto nível de acerto, pelo fato de existir pouca variação entre as imagens, como: iluminação, cor, brilho, entre outros, porém para o desenvolvimento de um classificador ideal, seria necessário um conjunto maior de imagens, em diferentes ambientes.

Apesar da grande quantidade de atributos extraídos sobre as amostras, notou-se que somente uma pequena quantidade de atributos foram utilizados na geração da árvore de decisão. Isso ocorreu porque o classificador C4.5, seleciona os atributos mais discriminantes no decorrer de sua execução. Dependendo da quantidade de atributos utilizados, a escolha dos melhores através do C4.5, pode ser custosa. Uma das maneiras para otimização desse processo, seria a utilização de técnicas de seleção de atributos. As técnicas de seleção de atributos melhoram o desempenho do classificador, pois a partir de um conjunto de atributos inicial, é gerado um sub-conjunto de atributos mais relevantes.

Durante o período de experimentos, foi verificado que o módulo apresentou um bom desempenho em todas as fases. Sem ajuda desse módulo, a realização desses experimentos seria inviável, pois a geração manual de 6000 amostras, com a precisão necessária, levaria um tempo indispensável do projeto. O módulo também fornece um ambiente para desenvolvimento de novos experimentos, como: testes com novos métodos de extração de atributos e novas técnicas de classificação.

Agradecimentos

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco, UCDB. Os acadêmicos Willian Paraguassu Amorim e Ricardo Rodrigues, co-autores deste artigo, são bolsistas do programa PIBIC/CNPQ. O projeto DTCOURO está sendo desenvolvido em parceria com a EMBRAPA Gado de Corte (Campo Grande/MS).

Referências

- [1] L. Georgieva, K. Krastev, and N. Angelov. Identification of surface leather defects. In *CompSysTech '03: Proceedings of the 4th international conference conference on Computer systems and technologies*, pages 303–307, New York, NY, USA, 2003. ACM Press.
- [2] A. Gomes. Aspectos da cadeia produtiva do couro no brasil e em mato grosso do sul. *Embrapa Gado de Corte*, pages 61–72, 2002.
- [3] A. Gomes. Avaliação técnica e operacional do sistema de classificação do couro bovino. *Embrapa Gado de Corte, Relatório Final do Projeto (CNPQ)*, 2005.
- [4] Gonzalez, Woods, and Eddins. *Digital Image Processing*. Prentice Hall, 2004.
- [5] MAPA. Ministério da agricultura, pecuária e abastecimento. instrução normativa nº 12, de 18 de dezembro de 2002. estabelece critérios de classificação para qualificação do couro bovino visando a sua valorização comercial e das outras províncias. diário oficial da república federativa do brasil. 2002.
- [6] S. Martins, M. Azevedo-Marques, F. Oliveira, R. P. Jr., and M. Trad. Caracterização de lesões intersticiais de pulmão em radiograma de tórax utilizando análise local de textura. *Radio Bras*, 2005.
- [7] H. Pistori and M. C. Pereira. Integração dos ambientes livres weka e imagej na construção de interfaces guiadas por sinais visuais. In *Anais do V Workshop de Software Livre - WSL*, Porto Alegre, RS, 2-5 de Junho 2004.
- [8] R. Rocha and J. Leite. Classificação de texturas a partir de vetores de atributos e função de distribuição de probabilidades. *UNICAMP, Universidade Estadual de Campinas - Instituto de Computação*, 2002.
- [9] S. Ruggieri. Efficient C4.5. (TR-00-01), 2, 2000.
- [10] W. R. Schwartz and H. Pedrini. Métodos para classificação de imagens baseada em matrizes de co-ocorrência utilizando características de textura. *Anais do III Colóquio Brasileiro de Ciências Geodésicas*, 2002.
- [11] I. H. Witten and E. Frank. Data mining: Practical machine learning tools and techniques with java implementations. *Morgan Kaufmann*, 2000.