

Máquinas de Vetores de Suporte Aplicadas à Classificação de Defeitos em Couro Bovino

Ricardo B. Rodrigues, Roberto Viana, André Pasquali e Hemerson Pistori

GPEC - Universidade Católica Dom Bosco

Av. Tamandare, 6000 Campo Grande, Brasil

{ricardo, roberto, andre}@acad.ucdb.br

pistori@ucdb.br

Marco A. Alvarez

Department of Computer Science

Utah State University

Logan, UT 84322-4205, USA

malvarez@cc.usu.edu

Abstract

Currently the bovine leather classification in Brazil is done visually by specialists. Just like other industrial processes the automatization of the leather classification would bring many benefits to the leather production chain. This work proposes the usage of Support Vector Machines (SVM) for the leather defects classification, in addition it presents empirical results that encourage the usage of SVMs for the process automatization. The paper also presents a comparison between SVM and other classification algorithms like C4.5, K-NN, Naive Bayes and Multi-layer Perceptron

Resumo

Atualmente a classificação do couro bovino no Brasil é realizada manualmente por especialistas. Assim como em outros segmentos da indústria a automatização deste processo traria grandes benefícios para a cadeia produtiva do couro. Este trabalho propõe o uso de Máquina de Vetores de Suporte (SVM) na classificação de defeitos em couro bovino e apresenta resultados empíricos que encorajam a utilização de SVMs na automatização do processo. O trabalho também apresenta uma comparação entre a SVM e os algoritmos de classificação, C4.5, K-NN, Naive Bayes e Multi-layer Perceptron.

1. Introdução

A cadeia produtiva de gado é de grande importância para a economia brasileira e o Brasil é considerado um dos maiores produtores de gado do mundo [14]. Porém, de acordo com [6], apenas 8.5% do couro brasileiro é considerado de alta qualidade, o que é prejudicial para a cadeia produtiva. Recentemente, a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) sugeriu uma busca por um método de padronização do sistema de classificação de couro cru¹.

Hoje, em diversos processos industriais, defeitos em madeiras, metais, couros, tecidos entre outros são classificados por seres humanos [22]. Em geral, esta tarefa consiste em analisar visualmente a textura da superfície do produto à procura de falhas. Por ser um trabalho minucioso e cansativo, a ocorrência de erros durante a análise torna-se comum.

O processo de inspeção visual de peles de couro para análise de defeitos pode ser modelado utilizando técnicas de visão computacional, como relatado em [1, 7, 12, 13, 16, 19, 22]. No entanto, o couro bovino é considerado uma superfície complexa, pois pode apresentar muitas variações na aparência como: cor, brilho, espessura dentre outros [7].

Para classificação automática de defeitos em couro são utilizadas neste trabalho técnicas de visão computacional e aprendizagem de máquina. Este trabalho faz parte do sistema DTCOURO² que propõe o desenvolvimento de um

¹ Instrução normativa número 12, 18 de Dezembro de 2002 Ministério Brasileiro de Agricultura, Pecuária e Abastecimento

² Projeto para a Detecção Automática de Defeitos em Peles e Couros Bovinos

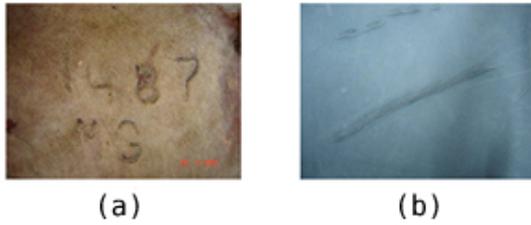


Figura 1. Imagens do couro bovino nos estágios crú e wet blue

processo automatizado de classificação do couro bovino em diferentes estágios da cadeia produtiva. A Figura 1a mostra uma imagem do defeito “marca ferro” sobre uma peça de couro bovino no estágio crú (antes de ser curtido) e a Figura 1b uma imagem do defeito “risco aberto” sobre uma peça de couro bovino no estágio *wet blue* (primeiro processo após o curtimento). Neste sistema, a análise será realizada a partir de imagens digitais coletadas do produto alvo, utilizando técnicas de visão computacional, inteligência artificial e reconhecimento de padrões.

Dentre as várias técnicas de aprendizado supervisionado existentes, as Máquinas de Vetores de Suporte (SVM) tem sido amplamente utilizadas na área de classificação de padrões por demonstrarem um grande poder de generalização e capacidade de manipular grandes volumes de dados. Este estudo apresenta o uso de técnicas de extração de atributos combinadas com SVMs para o problema de classificação de defeitos do couro bovino. Em experimentos preliminares foram realizadas análises comparativas com outros algoritmos de classificação mostrando resultados promissores.

No capítulo 2 são apresentados alguns trabalhos correlatos, em seguida, no capítulo 3 é fundamentado o método SVM e a implementação do mesmo utilizada neste trabalho. A seção 4 descreve a construção do *dataset*, os experimentos de comparação entre métodos. Na seção 5 encontram-se conclusões e projeções futuras e na seção 6 os agradecimentos.

2. Trabalhos Correlatos

A discussão dos trabalhos correlatos será dividida em duas partes principais. Inicialmente, são analisados trabalhos na área de classificação de couro bovino, em seguida, é apresentada uma revisão na utilização de SVMs na área de reconhecimento de padrões e classificação.

2.1. Classificação do couro

Em [22] Yeh and Perng é proposto um método semi-automático para extração e detecção de defeitos em couro bovino nos estágios *wet-blue* e couro cru. Os resultados de seus trabalhos se apresentaram confiáveis quando comparados com os de especialistas na área, mas os autores também apontam a desvantagem da necessidade de um especialista na fase de contagem total de defeitos. Um método de inspeção de couro baseado em *Haar's wavelets* é apresentado por Sobral em [19]. Segundo Sobral, o método apresenta resultados equivalentes ao de humanos experientes e em tempo real [19], além de superar métodos propostos anteriormente, como o descrito por Kumar e Pang em [13]. Apesar de não esclarecido claramente por Sobral, aparentemente seu sistema foi testado apenas em couro no estágio final de produção, um problema bem mais simples comparado com outros estágios de produção como *wet-blue* ou couro cru. Uma medida de similaridade baseada em χ^2 é usada para comparar histogramas em tons de cinza extraídos de amostras (“janelas” de 65×65 pixels) de imagens em estágio *wet-blue* com um histograma médio de imagens sem defeito em [7]. Os resultados do χ^2 e o limiar encontrado experimentalmente são utilizados para segmentar regiões defeituosas. O método não foi usado na identificação dos tipos de defeito. Uma outra abordagem utilizando histograma e atributos extraídos por co-ocorrência é investigada em [12].

2.2. Máquinas de Vetores de Suporte

Osuna utiliza SVM para detecção de faces em imagens em [15], ele demonstra a aplicabilidade das SVMs na detecção de faces em imagens que apresentaram resultados equivalentes ou superiores a outros métodos baseados em exemplos [15]. O sistema de Osuna percorre imagens em tons de cinza e é capaz de encontrar faces em diferentes escalas e grau de iluminação. Nos testes realizados por Osuna a SVM é configurada com parâmetro $C = 200$ e um *kernel* polinomial de grau 2. A forma de obtenção desta configuração não é especificada no artigo. Em [10] Joachims apresenta evidências teóricas e práticas do bom desempenho de classificação das SVM em problemas de categorização de textos. O desempenho das SVM é calculado com base em dois conjuntos de dados cada um contendo mais de 20000 casos de teste com cerca de 10000 atributos. Entre outros algoritmos testados no artigo o *K-NN* foi o que apresentou melhor performance e foi superado pela SVM em 63 das 90 categorias do primeiro conjunto de testes e em todas as 23 categorias do segundo conjunto. Apesar do tempo de treinamento das SVM ser superior ao do *K-NN* o ganho na classificação é compensador para este problema. Uma outra aplicação das SVM na área de Visão Computacional é apresentada

em [18] onde Pontil e Verri realizam experimentos na classificação de objetos aplicando vários tipos de modificações como: adição de ruído, remoção de partes do objeto, alteração da localização espacial e combinações entre os mesmos. Os resultados foram comparados com *Perceptrons* e se mostraram superiores. Os autores atribuem estes resultados ao maior poder de generalização das SVMs [18].

3. Máquinas de Vetores de Suporte - SVM

A SVM é uma técnica usada para o treinamento de classificadores baseada no conceito da minimização do risco estrutural [3]. A técnica foi desenvolvida por Vladimir Vapnik em 1979 e está sendo amplamente utilizada desde a década de 90 em vários problemas de classificação e reconhecimento de padrões como: detecção de face em imagens [15], categorização de textos [10] e reconhecimento de Objetos [18].

Uma das grandes vantagens da SVM é seu alto poder de generalização. Isto ocorre pois a complexidade da hipótese não depende do número de atributos, mas sim da margem com que eles separam os dados [10]. Este fator é muito interessante quando lidamos com problemas de classificação baseados em imagens, pois a dimensão dos seus vetores de atributos é geralmente grande.

Em sua forma básica SVMs são classificadores lineares que separam os dados em duas classes através de um hiperplano de separação.

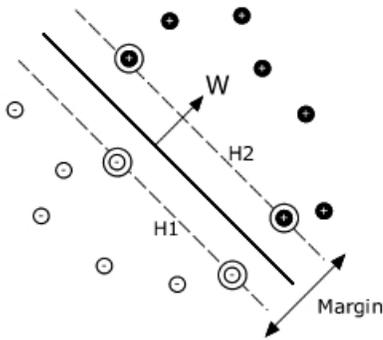


Figura 2. Classificação de um conjunto de dados usando uma SVM linear.

Um hiperplano ótimo separa os dados com a máxima margem possível, que é definida pela soma das distâncias entre os pontos positivos e os pontos negativos mais próximos do hiperplano. Estes pontos são chamados de vetores de suporte e estão circulados na Figura 2. O hiperplano

é construído com base em treinamento prévio em um conjunto finito de dados [20].

Assumindo o conjunto de treinamento $\{x_i, y_i\}$, $y_i \in \{\pm\}$, $x_i \in R^d$ onde x_i é o i -ésimo elemento de entrada e y_i é o seu respectivo valor de classe para $x_i, i = 1, \dots, l$. O cálculo do hiperplano com margem ótima é dado pela minimização de $\|w\|^2$ obedecendo as seguintes restrições:

$$y_i (x_i \cdot w + b) - 1 \geq 0, \forall_i \quad (1)$$

Onde w é a normal ao hiperplano. Este é um problema quadrático de otimização, e pode ser transformado para forma *dual*, onde depende apenas dos Multiplicadores de Lagrange a_i :

$$u \equiv \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j (x_i \cdot x_j) \quad (2)$$

respeitando as restrições da equação linear:

$$\sum_i a_i y_i = 0, \quad (3)$$

e as restrições da inequação:

$$a_i \geq 0, \forall_i \quad (4)$$

Com a solução dada por:

$$w = a_i y_i x_i \quad (5)$$

Onde N é o número de exemplos de treinamento. Os elementos mais próximos ao hiperplano são chamados de vetores de suporte e estão localizados nos planos H_1 e H_2 Figura 2. Estes são os pontos mais importantes, pois são eles que definem a margem de classificação da SVM [3].

Infelizmente para a maioria dos problemas reais o conjunto de dados não é separável através de um hiperplano linear, e o cálculo dos vetores de suporte utilizando as formulações descritas acima não se aplicaria [17]. Este problema pode ser resolvido através da introdução de variáveis de alargamento de margem ξ_i que "relaxam" as restrições da SVM linear permitindo algumas falhas na margem, mas também penaliza as falhas através da variável de controle C . Estas modificações alteram o problema de otimização (1) para:

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i, \quad (6)$$

respeitando,

$$y_i (x_i \cdot w + b) - 1 + \xi_i \geq 0, \forall_i \quad (7)$$

A transformação deste problema de otimização para sua forma *dual* apenas altera a restrição (4) para:

$$0 \leq a_i \leq C, \forall_i \quad (8)$$

As SVMs ainda podem ser vistas por um ponto de vista mais geral como um classificador multiclasse. Estas modificações podem ser aplicadas mapeando o conjunto de dados em espaço Euclidiano de alta dimensão (possivelmente infinita), estes mapeamentos são feitos utilizando funções de *kernel* (núcleo) na fase de treinamento[3]. O cálculo da SVM multiclasse é definido por:

$$u \equiv \sum_{i=1}^N a_i y_i K(x_i, x) - b, \quad (9)$$

Onde a minimização dos Multiplicadores de Lagrange ainda é um problema quadrático,

$$\min_a \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N K(x_i, x_j) a_i a_j y_i y_j, \quad (10)$$

3.1. Implementação de C-SVC em LIBSVM

O LIBSVM é uma biblioteca de implementações de SVM desenvolvida por Chin-Chung Chang [4] com várias finalidades: classificação, regressão e estimativa de distribuição. O algoritmo de classificação implementado na biblioteca leva o nome de C-SVC.

Para resolução do problema quadrático o C-SVC decompõe o conjunto de Multiplicadores de Lagrange em subconjuntos menores selecionando um subconjunto com tamanho variável [4]. O C-SVC também implementa as técnicas *Shrinking* e *Caching* para redução do tempo computacional. O *Shrinking* tenta reduzir o tamanho do problema quadrático a ser resolvido eliminando Multiplicadores de Lagrange que não poderiam ser alterados com base em uma heurística demonstrada em [4]. A técnica de *Caching* simplesmente armazena cálculos de matrizes utilizados recentemente para utilizações futuras, reduzindo parte dos cálculos de *kernel* realizados nas interações finais.

Na resolução de problemas multi-classe o C-SVC utiliza o método “um-contra-um”, que consiste na resolução de um problema de duas classes para cada classe, atribuindo para todos os pontos um valor de classe baseado em uma estratégia de votação. Para pontos com valores de classe idênticos um algoritmo seleciona o de menor índice.

4. Conjunto de treinamento (*Dataset*)

Para gerar a base de aprendizagem quinze imagens do couro bovino no estágio couro cru foram selecionadas do repositório do projeto DTCOURO. As imagens foram capturadas usando uma câmera digital de cinco *megapixels* durante visitas técnicas a curtumes localizados na região de

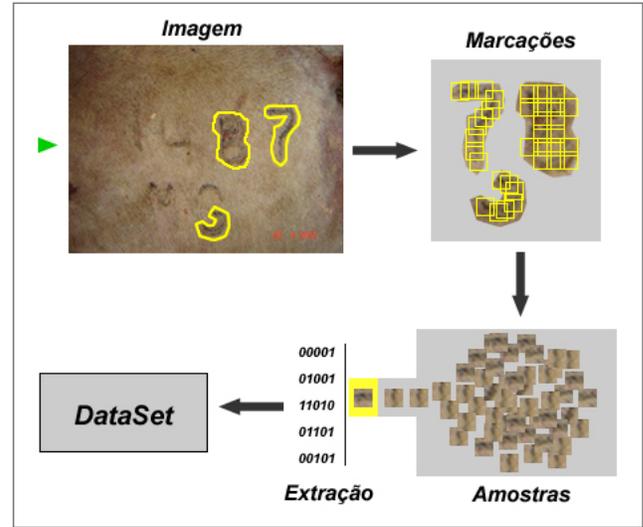


Figura 3. Ilustração do processo de marcação e extração de amostras.

Mato Grosso do Sul, Brasil em setembro de 2005. Para este experimento as imagens foram redimensionadas de uma alta resolução para 600×450 *pixels* com a intenção de economizar tempo de processamento e espaço em disco. Evidências empíricas mostraram que não há percas efetivas com o uso da escala adotada. Além do mais, as imagens foram capturadas com pouca variação de ambiente como iluminação, ângulo e distância.

Um conjunto de quatro tipo de defeitos foram escolhidos, são eles, marcas de carrapato, marca ferro, risco e sarna. Os defeitos foram manualmente segmentados com ajuda da ferramenta DTCOURO. Um total de trinta segmentações foram realizadas sobre as imagens, representando os exemplos dos defeitos previamente citados. Após a segmentação manual dos defeitos o módulo de extração de amostras do projeto DTCOURO foi usado para extrair amostras (“janelas” de 20×20 *pixels* “varrendo” todas as segmentações como mostra a Figura 3). Desta maneira um total de 14722 amostras de 20×20 *pixels* foram criadas a partir das segmentações.

O próximo passo foi a extração de atributos. Um conjunto de 139 atributos baseados em textura foram extraídos usando Mapas de Interações [5] e Matrizes de Co-ocorrência [8] e 6 atributos de cor com os extratores HSB e RGB. Para os extratores baseados em textura foram utilizadas as medidas de similaridade, entropia, dissimilaridade, correlação, momento da diferença inversa, segundo momento angular e diferença inversa. Mais informações sobre medidas de similaridades são encontradas em [2, 11]. Os extratores foram configurados de acordo com a Tabela 1.

	Mapas Int.	Matrizes Co.
Anglo inicial:	0	0
Anglo final:	180	180
Variação do ângulo:	10	10
Distância (pixels):	2	-
Variação da distância:	1	1

Tabela 1. Configuração dos extratores baseados em textura.

Para cada uma das 14722 amostras, um vetor de características \bar{x} foi calculado e armazenado no *dataset*. Ao mesmo tempo, todas as amostras foram tituladas com uma das seguintes classes: *Carrapato*, *Marca Ferro*, *Risco* e *Sarna*. A distribuição das amostras é a seguinte: 2819 *Carrapato*, 3716 *MarcaFerro*, 2804 *Risco*, 5383 *Sarna*, onde o número de amostras em cada classe é proporcional a área de cada região de defeito da imagem original.

4.1. Configurações do experimento

Os experimentos foram conduzidos utilizando a versão 3.5.2 do software Weka [21], a biblioteca *LibSVM* escrita por Chang e Lin [4] e a implementação WLSVM³. A implementação da SVM *LibSVM* foi testada juntamente com os classificadores *C4.5*, *K - NN*, *NaiveBayes*, *MultiLayer Perceptron (MLP)*. Para cada algoritmo foi utilizada uma validação cruzada com 5 dobras sobre o *dataset* para certificar uma estimativa mais confiável da generalização do erro [9].

4.2. Avaliação dos algoritmos supervisionados

Os experimentos são basicamente exploratórios e foram conduzidos com a intenção de avaliar a eficácia e eficiência da SVM aplicada ao problema de classificação do couro bovino e comparar seu desempenho com outros algoritmos. Os resultados foram analisados usando medidas tradicionais incluindo, percentual de acertos (Acurácia), tempo de treinamento, *precision* (captura o efeito do alto número de exemplos negativos na performance dos algoritmos), *recall* (representa taxa de positivos verdadeiros) e podem ser vistos na Tabela 2.

Os parâmetros de configuração do *Libsvm* são $C = 18,62$ e $\gamma = 1,54$, para o MLP foram utilizadas 74 camadas, os algoritmos *N.Bayes* e *C4.5* foram executados com as configurações padrão do ambiente WEKA.

Como pode ser observado na Tabela 2, os resultados mostram claramente uma alta performance atingida pela im-

	T. treina.	Recall	Precision	Acurácia
<i>C4.5</i>	52.40	0.97	0.97	95.43
<i>K - NN</i>	0.07	0.99	0.99	95.75
<i>N.Bayes</i>	4.55	0.70	0.71	70.22
<i>MLP</i>	7322.86	1.00	1.00	99.24
<i>LibSVM</i>	172.43	1.00	1.00	99.47

Tabela 2. Resultados da execução dos experimentos de classificação.

plementação *LibSVM*. O total de acertos final para os classificadores *K - NN* e *C4.5* e principalmente o *MLP* também são altos. A diferença entre a acurácia da *MLP* e da *LibSVM* é de apenas 0.23%, no entanto, analisando a melhoria relativa entre elas a *LibSVM* apresenta um ganho de 30.26%. O tempo de treinamento da *MLP* é muito alto em relação ao dos demais algoritmos, já o *K - NN* que possui o melhor tempo de treinamento não apresenta resultados de classificação similares aos melhores apresentados na Tabela 2. Note que a fase de treinamento do *LibSVM* é melhor que a da *MLP* em termos de eficiência.

Os valores de *precision* e *recall* destacados demonstram a conveniência de algoritmos de aprendizagem supervisionada para o problema de classificação de defeitos. Em adição, pode ser concluído que o conjunto de características extraídas das imagens originais favorecem a efetividade do classificador. A acurácia apenas confirma que os classificadores podem discriminar os defeitos com muita precisão.

5. Conclusão e Trabalhos Futuros

Embora a *SVM* não ser o algoritmo mais eficiente para propósitos de treinamento apresentou o melhores resultados de classificação, assim como o *MLP*. Note que a diferença entre a acurácia do *MLP* e do *LibSVM* pode ser negligenciada, uma vez que ambos resultados são satisfatórios. Uma interessante observação é que as soluções do *LibSVM* tendem a ser mais rápidas que *MLPs* para os propósitos de testes, além de não apresentar perda de acurácia em relação as mesmas. Outra observação importante é que em situações onde o tempo de treinamento é muito importante o uso de classificadores como *k - NN* e o *C4.5* é encorajado devido a suas taxas de acertos consideráveis.

Apesar de experimentos prévios terem sido realizados apresentando bons resultados de classificação, uma outra direção de pesquisa é a aplicação de soluções similares aplicadas a diferentes estágios do couro com diferentes características apresentadas. Dessa forma, serão realizados testes para verificação do ganho de informação de métodos de extração de atributos e segmentação de imagens relaciona-

³ Yasser EL-Manzalawy and Vasant Honavar, WLSVM : Integração da *LibSVM* com o ambiente Weka, 2005. Software disponível em <http://www.cs.iastate.edu/~yasser/wlsvm>

dos a cada tipo de defeito. Um estudo mais aprofundado sobre as MLPs e seus parâmetros será realizado para futuros experimentos aplicados ao problema de classificação do couro bovino. Uma nova etapa de testes também será realizada utilizando um conjunto maior de imagens em diferentes estágios do couro.

6. Agradecimentos

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco, UCDB, da Agência Financiadora de Estudos e Projetos, FINEP e da Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul, FUNDECT. Os autores também contaram com bolsas do Conselho Nacional de Desenvolvimento Científico e Tecnológico, CNPQ, nas modalidades ITI-A, PIBIC e Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora.

Referências

- [1] B. A. Automated system for detection and classification of leather defects. *NDT and E International*, 30:321–321(1), October 1997.
- [2] W. P. Amorim, R. Viana, R. B. Rodrigues, and H. Pistori. Desenvolvimento de um software de processamento e geração de imagens para classificação de couro bovino. *SIBGRAPI-Workshop of Undergraduate Works*, 2006.
- [3] C. J. C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2):121–167, 1998.
- [4] C.-C. Chang and C.-J. Lin. *LIBSVM: a library for support vector machines*, 2001. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [5] D. Chetverikov. Texture analysis using feature-based pairwise interaction maps. *Pattern Recognition*, 32(3):487–502, 1999.
- [6] A. B. da Costa. Estudo da competitividade de cadeias integradas no Brasil: Impactos das zonas de livre comércio. Technical report, Instituto de Economia da Universidade Estadual de Campinas, Dezembro 2002.
- [7] L. Georgieva, K. Krastev, and N. Angelov. Identification of surface leather defects. In *CompSysTech '03: Proceedings of the 4th international conference on Computer systems and technologies*, pages 303–307, New York, NY, USA, 2003. ACM Press.
- [8] H.-W. R. Hseu, A. Bhalerao, and R. G. Wilson. Image matching based on the co-occurrence matrix. Technical Report CS-RR-358, Coventry, UK, 1999.
- [9] F. Imbault and K. Lebart. A stochastic optimization approach for parameter tuning of support vector machines. In *Proceedings of the Pattern Recognition, 17th International Conference on (ICPR '04)*, pages 597–600, Washington, DC, USA, 2004. IEEE Computer Society.
- [10] T. Joachims. Text categorization with support vector machines: learning with many relevant features. In C. Nédellec and C. Rouveiroi, editors, *Proceedings of ECML-98, 10th European Conference on Machine Learning*, number 1398, pages 137–142, Chemnitz, DE, 1998. Springer Verlag, Heidelberg, DE.
- [11] R. Jobanputra and D. Clausi. Texture analysis using gaussian weighted grey level co-occurrence probabilities. In *Proceedings of the Canadian Conference on Computer and Robot Vision - CRV*, pages 51–57, 2004.
- [12] K. Krastev, L. Georgieva, and N. Angelov. Leather features selection for defects' recognition using fuzzy logic. In *CompSysTech '04: Proceedings of the 5th international conference on Computer systems and technologies*, pages 1–6, New York, NY, USA, 2004. ACM Press.
- [13] A. Kumar and G. Pang. Defect detection in textured materials using gabor filters. *IEEE Transactions on Industry Applications*, 38(2), March 2002.
- [14] H. Matthey, J. F. Fabiosa, and F. H. Fuller. Brazil: The future of modern agriculture. *MATRIC*, May 2004.
- [15] E. Osuna, R. Freund, and F. Girosi. Training support vector machines: an application to face detection. *CVPR'97, Puerto Rico*, pages 130–136, 1997.
- [16] H. Pistori, W. A. Paraguassu, P. S. Martins, M. P. Conti, M. A. Pereira, and M. A. Jacinto. Defect detection in raw hide and wet blue leather. In *CompImage*, 2006.
- [17] J. Platt. Sequential minimal optimization: A fast algorithm for training support vector machines, 1998.
- [18] M. Pontil and A. Verri. Support vector machines for 3d object recognition. *IEEE Trans. Pattern Anal. Mach. Intell.*, 20(6):637–646, 1998.
- [19] J. L. Sobral. Optimised filters for texture defect detection. In *Proc. of the IEEE International Conference on Image Processing*, volume 3, pages 565–573, September 2005.
- [20] V. N. Vapnik. An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10(5):988–999, 1999.
- [21] I. H. Witten and E. Frank. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, San Francisco, CA, USA, second edition, 2005.
- [22] C. Yeh and D. B. Perng. Establishing a demerit count reference standard for the classification and grading of leather hides. *International Journal of Advanced Manufacturing*, 18:731–738, 2001.