

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

Ricardo Cezar Bonfim Rodrigues

24 de abril de 2006

## 1 Antecedentes e Justificativa

Hoje, em diversos processos industriais, defeitos em madeiras, metais, couros, tecidos entre outros são classificados por seres humanos [C. Yeh 2001]. Em geral, esta tarefa consiste em analisar manualmente 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 desenvolvimento de sistemas automatizados para a classificação de características em texturas pode se tornar viável quando inserido no contexto de médias e principalmente de grandes escalas de produção industrial. Pois assim como nas pessoas, a capacidade de aprendizagem pode também ser aplicada em máquinas, que ao possuir um determinado tipo de “conhecimento”, são capazes de realizar tarefas equivalentes ou até superiores às realizadas por uma pessoa.

O DTCOURO<sup>1</sup> propõe o desenvolvimento de um sistema automatizado para o processo de classificação do couro bovino em diferentes estágios de cadeia produtiva. Neste sistema de observação automatizada, a análise será realizada a partir de imagens digitais coletadas do produto alvo, utilizando técnicas de visão computacional, inteligência artificial e engenharia de *software*.

Neste trabalho serão estudadas técnicas para a implementação de um dos módulos do sistema DTcouro que identifique e classifique defeitos no couro bovino, a partir de atributos extraídos de imagens. Este módulo utilizará técnicas de aprendizagem de máquinas, que deverão garantir alto desempenho, confiabilidade, e qualidade na classificação.

## 2 Objetivos

Esta seção apresenta o objetivo geral do sistema DTCOURO e o objetivo específico como um dos módulos propostos para este trabalho.

---

<sup>1</sup>Projeto para a Detecção Automática de Defeitos em Peles e Couros Bovinos

## 2.1 Geral

Desenvolver um módulo do sistema DTcouro, com programas fontes livres, que seja capaz de identificar e classificar defeitos no couro bovino automaticamente, através de imagens capturadas por câmeras digitais e técnicas de aprendizagem de máquina.

## 2.2 Específicos

1. Implementação de algoritmos de aprendizagem de máquinas baseados em Máquinas de Vetores de Suporte ou *Support Vectors Machines* (SVM).
2. Integração do módulo com o sistema DTCOURO.
3. Determinação do conjunto de atributos mais apropriados para cada classificação.
4. Análise comparativa do desempenho das Máquinas de Vetores de Suporte no problema da classificação do couro, em relação aos algoritmos baseados em Redes Neurais Artificiais.
5. Divulgação de resultados parciais e finais.

## 3 Revisão de Literatura

Os conceitos apresentados nesta seção servem de base para o entendimento da proposta de trabalho deste projeto. Na primeira subseção são apresentados algumas considerações ao problema da classificação do couro. As seguintes subseções fundamentam métodos que serão utilizados no desenvolvimento do classificador.

### 3.1 Classificação do Couro

O couro é um dos materiais mais utilizados em indústrias de calçados, bolsas entre outros, no mundo todo. Mas para a sua utilização, as indústrias exigem uma determinada qualidade para garantir uma boa aparência de seus produtos. Como em qualquer material natural, o couro pode apresentar defeitos em sua superfície.

No couro bovino, a maioria dos defeitos é causada por ferimentos que ocorrem durante sua fase produtiva, quando os animais são expostos à ectoparasitas e ao manejo inadequado [Jacinto 2004], outros ocorrem durante o seu transporte ao frigorífico e conservação em fases pré-processadas. Essas características no couro diminuem sua área utilizável, e conseqüentemente provocam danos econômicos.

Não existe um padrão industrial universal para a classificação de defeitos na superfície de couros [C. Yeh 2001]. Fica a cargo de cada industria analisar e definir o percentual que poderá ser utilizado de cada região com defeitos. As

observações no couro para a sua classificação geralmente ocorrem com o couro já pré-manufaturado (*wet blue*).

### 3.2 Reconhecimento de Padrões (*Pattern Classification*)

O processo de classificação de padrões é basicamente o ato de realizar uma ação baseada na categoria de padrões retirados de dados “crus” [Duda et al. 2000]. Este processo é muito utilizado em atividades diárias como: identificação de face, leitura de escrita manual, identificação de objetos pelo tato entre outros. Dessa forma a construção ou programação de máquinas capazes de reconhecer padrões é muito útil em várias áreas como, por exemplo: identificação de cadeias de DNA, reconhecimento de impreções digitais, e reconhecimento de escrita manual [Duda et al. 2000].

Um sistema de classificação de padrões é dividido em vários módulos e pode ser desenvolvido de várias maneiras. Segundo [Duda et al. 2000] um sistema típico para o reconhecimento de padrões apresenta os seguintes componentes:

- **Sensores** são responsáveis por captar sinais dos objetos analisados e alimentar a entrada do sistema. As limitações e características destes dispositivos afetam o nível de dificuldade do problema.
- **Segmentação e Agrupamento** é responsável por filtrar os dados captados pelos sensores, separando-os do fundo ou de outros objetos.
- **Extração de Atributos** caracteriza um objeto de acordo um conjunto de atributos para que o mesmo possa ser classificado. Esses atributos são muito similares para objetos da mesma classe.
- **Classificação** é responsável por atribuir os objetos a uma categoria com base nos vetores de atributos gerados pelo componente de extração, podendo definir arbitrariamente a categoria a qual o objeto pertence ou informar a porcentagem correspondente a cada categoria.
- **Processamento final** é responsável por medir as taxas de erro, diminuir o custo da operação, também pode incorporar algum conhecimento sobre o domínio do problema, melhorando o desempenho do sistema.

Um dos métodos que vem sendo muito utilizados na definição de características do classificador é o treinamento [Duda et al. 2000], ou seja, a utilização de amostras de padrões para “ensinar” o classificador. Este método é interessante, pois na maioria dos problemas reais leva-se muito tempo para supor quais são os melhores atributos para classificação. Então a criação de um classificador envolve a definição de um modelo geral do mesmo juntamente com o treinamento de padrões para a aprendizagem dos padrões desconhecidos.

A aprendizagem geralmente é feita de forma supervisionada ou não supervisionada. Na forma supervisionada o professor fornece o custo de cada padrão em um conjunto de treinamento, e busca reduzir a soma

dos custos destes padrões [Duda et al. 2000]. No método não supervisionado o sistema forma conjuntos “naturalmente” a partir dos padrões de entrada. O modo como é feito o agrupamento é definido internamente pela componente responsável pelo agrupamento. Resultando em um conjunto diferente quando comparado com outros algoritmos de agrupamento.

### 3.3 Máquina de vetores de suporte

Máquina de vetores de suporte ou *support vectors machine* (SVM), introduzida por Vapnik e sua equipe [Osuna et al. 1997], é basicamente uma implementação do método de minimização de risco estrutural [Zhen Hou 2005, Vapnik 1999], para o treinamento de classificadores (aprendizagem de máquinas). Uma de suas principais características é um bom desempenho no reconhecimento de padrões em grandes volumes de dados, como nos problemas de processamento de imagens.

A classificação de dados linearmente separáveis utilizando uma SVM consiste na criação de um hiperplano ótimo que separa os dados em duas classes como mostra a Figura (1a). Dado um espaço em que os dados possam assumir apenas dois valores (+1, -1), um hiperplano separa estes dados de forma que um dos lados contenha apenas dados da classe 1, e do lado oposto apenas dados da classe -1 [Burges 1998]. Esse processo é feito com base em um treinamento prévio num conjunto finito de amostras.

Assumindo um conjunto de dados não separáveis linearmente, como mostra a Figura (1b), a SVM é construída a partir da transformação do conjunto de dados inicial em um novo conjunto de padrões linearmente separáveis, de acordo com o teorema de Cover da separabilidade de padrões [Zhen Hou 2005]. Para realizar esse tipo de transformações, são utilizadas funções de núcleo.

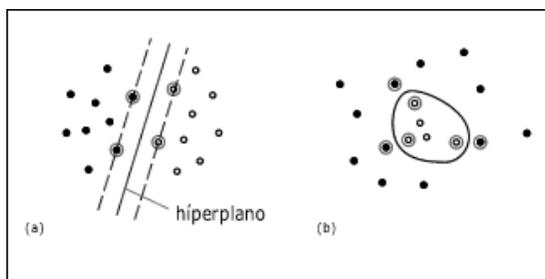


Figura 1: (a) classificação de duas classes separáveis linearmente. (b) classificação de duas classes não separáveis linearmente. Os vetores de suporte são representados por um círculo adicional

Apesar do conceito ter sido introduzido em 1968 [Cortes and Vapnik 1995], as SVM tiveram suas primeiras aplicações na década de 90 [Vapnik 1999]. Atualmente estão sendo muito utilizadas para a resolução de diferentes problemas como, reconhecimento de faces de pessoas, reconhecimento de escrita manual,

reconhecimento de objetos entre outras [Burges 1998].

## 4 Metodologia

Segue abaixo os objetivos específicos para o desenvolvimento do módulo.

1. Implementação de algoritmos de aprendizagem de máquinas baseados em Máquinas de Vetores de Suporte (SVM).
  - (a) Estudo do módulo de pré-processamento e geração de imagens.
  - (b) Estudo de *plugins* e funções da ferramenta ImageJ.
  - (c) Estudo da ferramenta de aprendizagem de máquina Weka aplicada às SVMs.
  - (d) Desenvolvimento de *plugins* baseados em SVMs, integrados com a ferramenta Weka.
2. Integração do módulo com o sistema DTCOURO.
  - (a) Análise dos módulos existentes do sistema DTCOURO.
  - (b) Adaptação da *interface* para o novo módulo.
  - (c) Testes com o sistema integrado.
3. Determinação do conjunto de atributos mais apropriados para cada classificação.
  - (a) Análise do conjunto de atributos para o treinamento da SVM com diferentes métodos de núcleo, aplicados a cada defeito.
  - (b) Análise do conjunto de atributos para o treinamento da SVM com amostras do couro em fase produtiva.
  - (c) Análise do conjunto de atributos para o treinamento da SVM com amostras do couro cru.
  - (d) Análise do conjunto de atributos para o treinamento da SVM com amostras do couro pré-processado (*wet blue*)
4. Análise comparativa do desempenho das SVMs no problema da classificação do couro, em relação aos algoritmos baseados em redes neurais artificiais.
  - (a) Utilização de algoritmos baseados em redes neurais artificiais aplicados ao problema, utilizando a ferramenta Weka.
  - (b) Utilização de algoritmos baseados em SVMs, aplicados ao problema.
  - (c) Geração de percentual de acertos para cada método.
  - (d) Geração de resultados.
5. Divulgação de resultados parciais e finais.

- (a) Elaboração de relatório de atividades parciais.
- (b) Elaboração de relatório de atividades finais.
- (c) Geração de artigo científico.

## 5 Cronograma

| Etapa | Meses |   |   |   |   |   |   |   |   |    |    |    |   |   |   |
|-------|-------|---|---|---|---|---|---|---|---|----|----|----|---|---|---|
|       | 1     | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 1 | 2 | 3 |
| 1.a   |       |   |   | X | X |   |   |   |   |    |    |    |   |   |   |
| 1.b   |       |   |   |   | X | X |   |   |   |    |    |    |   |   |   |
| 1.c   |       |   |   |   | X | X |   |   |   |    |    |    |   |   |   |
| 1.d   |       |   |   |   |   | X | X | X | X |    |    |    |   |   |   |
| 2.a   |       |   |   |   |   |   |   | X |   |    |    |    |   |   |   |
| 2.b   |       |   |   |   |   |   | X |   |   |    |    |    |   |   |   |
| 2.c   |       |   |   |   |   |   |   | X |   |    |    |    |   |   |   |
| 3.a   |       |   |   |   |   |   |   | X | X |    |    |    |   |   |   |
| 3.b   |       |   |   |   |   |   |   | X | X |    |    |    |   |   |   |
| 3.c   |       |   |   |   |   |   |   |   | X | X  |    |    |   |   |   |
| 3.d   |       |   |   |   |   |   |   |   |   | X  | X  |    |   |   |   |
| 4.a   |       |   |   |   |   |   |   |   | X | X  |    |    |   |   |   |
| 4.b   |       |   |   |   |   |   |   | X | X | X  |    |    |   |   |   |
| 4.c   |       |   |   |   |   |   |   | X | X | X  |    |    |   |   |   |
| 4.d   |       |   |   |   |   |   |   |   |   |    | X  |    |   |   |   |
| 5.a   |       |   |   |   |   |   |   |   | X | X  | X  | X  |   |   |   |
| 5.b   |       |   |   |   |   |   |   |   |   |    | X  | X  | X |   |   |
| 5.c   |       |   |   |   |   |   |   |   |   |    |    |    | X | X | X |

## Referências

- [Burges 1998] Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2):121–167.
- [C. Yeh 2001] C. Yeh, D. B. P. (2001). Establishing a demerit count reference standard for the classification and grading of leather hides. *International Journal of Advanced Manufacturing Technology*, 1(18):731–738.
- [Cortes and Vapnik 1995] Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3):273–297.
- [Duda et al. 2000] Duda, R. O., Hart, P. E., and Stork, D. G. (2000). *Pattern Classification*. John Wiley e Sons, INC., USA.
- [Jacinto 2004] Jacinto, M. A. C.; Pereira, M. A. (2004). Indústria do couro: programa de qualidade e estratificação de mercado com base em características do couro. *Simpósio de produção de gado de corte*, pages 75–92.
- [Osuna et al. 1997] Osuna, E., Freund, R., and Girosi, F. (1997). Training support vector machines: an application to face detection. *CVPR'97, Puerto Rico*, pages 130–136.
- [Vapnik 1999] Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10(5):988–999.
- [Zhen Hou 2005] Zhen Hou, J. M. P. (2005). Texture defect detection using support vector machines with adaptive gabor wavelet features. *Proceedings of the Seventh IEEE Workshop on Applications of Computer Vision*, 1:275–280.