

1 Introdução

1.1. Motivação

A máquina de vetor suporte (support vector machine - SVM) é uma técnica de aprendizado, baseada na teoria do aprendizado estatístico [1], [2], [3], [4], [5], [6], que obteve sucesso na solução de vários problemas, tanto de classificação quanto de regressão. SVM é baseada no princípio de minimização do risco estrutural que mostrou ter um desempenho de generalização superior ao princípio de minimização do risco empírico usado por redes neurais convencionais [7]. Essa característica permite que SVM tenha excelente desempenho de generalização em problemas de classificação de padrões.

Nas máquinas de vetor suporte, funções não lineares mapeiam os vetores de entrada em um espaço de características de dimensão maior, onde é construído um hiperplano de separação como solução do problema de classificação. Como exemplo de função tem-se polinômios e funções de base radial (Radial Basis Functions - RBF). A solução do problema é obtida considerando-se o erro de treinamento e a margem de separação entre as classes, o que se constitui em um conceito fundamental na formulação de SVMs. A margem de separação é controlada pelo usuário e está relacionada ao erro de classificação permitido pelo hiperplano de separação.

O treinamento de SVMs consiste na resolução de um problema quadrático com restrições lineares [1], [5], [8], [9], [10], [11], [12], que dependem dos vetores de treinamento, de alguns parâmetros e da margem de separação. A solução desse problema fornece a informação necessária para se escolher, entre todos os dados de entrada, os vetores mais importantes, conhecidos como vetores suporte, que definem o hiperplano de separação.

As máquinas de vetor suporte têm a habilidade inerente de resolver um problema de classificação de padrões de uma forma próxima ao ótimo, isto é, da melhor solução possível. No entanto da mesma forma que as redes neurais (RN), possuem uma limitação relacionada ao fato de gerarem um "modelo caixa preta", isto é, um modelo que não explica, de forma simples e clara, o processo

pelo qual sua saída é obtida, pois sua solução é uma combinação linear de funções kernel [1], o que certamente é de difícil interpretação. Entretanto, para alguns problemas, o conhecimento de como a classificação foi obtida é tão importante quanto a classificação propriamente dita. Uma solução para esse problema de falta de transparência de SVMs é o desenvolvimento de uma técnica de extração de regras.

Duas propostas de extração de regras com SVM são: RuExSVM e SVM+Prototypes. No algoritmo RuExSVM [13], treina-se uma SVM e encontram-se os vetores suporte; em seguida, constrói-se uma regra através de um hiper-retângulo associado a cada vetor suporte. Por último, as regras são ajustadas para se produzir um conjunto de regras compacto. No algoritmo SVM+Prototypes [14], [15], após o treinamento de uma SVM, são determinados os vetores suporte e o centro de cada classe. Para cada uma dessas classes, constrói-se um elipsóide a partir de seu centro e de um vetor suporte. Da mesma forma, para cada classe são geradas regras associadas a hiper-retângulos.

A principal dificuldade do algoritmo RuExSVM está relacionada à construção dos hiper-retângulos, o que envolve gastos de tempo e esforço computacional. Quanto ao algoritmo SVM+Prototypes, a maior dificuldade é a construção de elipsóides cujos eixos não são paralelos aos eixos cartesianos, principalmente no caso em que o espaço de entradas tem dimensão grande, isto é, com um número grande de atributos de entrada.

Deve ser destacado que as regras geradas pelos dois métodos acima possuem, em seus antecedentes, intervalos ou funções. Essa característica diminui a interpretabilidade das regras geradas, prejudicando a capacidade de extração de conhecimento útil.

Deste modo, de forma a aumentar o poder de interpretação lingüística das regras geradas, propõe-se, neste trabalho, uma metodologia para a extração de regras fuzzy das SVMs treinadas, baseada na idéia de que a utilização de conjuntos fuzzy nos antecedentes torna as regras mais flexíveis. Considera-se, ainda, que é possível atribuir valores lingüísticos aos conjuntos fuzzy, o que torna as regras obtidas mais claras e compactas. Por exemplo, na configuração com 3 conjuntos fuzzy, eles poderiam ser denominados “grande”, “médio” e “pequeno”. Assim, no caso da classificação da planta Íris, uma regra obtida é: Se x_1 é pequeno e x_2 é médio e x_3 é pequeno e x_4 é pequeno, então Íris Setosa.

1.2. Objetivos

O principal objetivo deste trabalho é desenvolver um modelo genérico de extração de regras fuzzy a partir de SVMs para classificação (envolvendo duas ou mais classes) com maior interpretabilidade lingüística do que os já existentes. Esse modelo é chamado de FREx_SVM.

A necessidade de se desenvolver um método de extração de regras está relacionada ao fato de uma SVM gerar um modelo cujo resultado final não é facilmente interpretável.

Tem-se também como objetivo estudar e comparar os métodos existentes de classificação para mais de duas classes, verificando se algum deles é mais apropriado para a extração de regras fuzzy.

1.3. Contribuições da Tese

A principal contribuição desse trabalho é:

- *Desenvolvimento de um modelo genérico de extração de regras fuzzy para a classificação em duas ou mais classes* ⇒ O modelo genérico de extração de regras fuzzy para a classificação em duas ou mais classes utiliza os vetores suporte obtidos pela SVM treinada para definir conjuntos fuzzy de cada atributo de entrada. Cada vetor suporte gera uma regra fuzzy.

Outras contribuições desse trabalho são:

- *Adaptação da definição de duas métricas apresentados em [16] para avaliar as regras fuzzy: acurácia e abrangência fuzzy* ⇒ Para a avaliação das regras geradas, foi necessária a utilização de duas métricas: a abrangência fuzzy, que mede o número de padrões afetados pela regra, e a acurácia fuzzy, que mede quão bem a regra descreve os dados;
- *Análise comparativa do desempenho dos métodos de classificação para múltiplas classes* ⇒ Através da realização de testes com alguns bancos de dados, os desempenhos dos três métodos de classificação em múltiplas classes mais utilizados (separação das classes duas a duas [5], [17], [18], [19], [20], decomposição um por classe [5], [17], [18], [21] e método de Crammer e Singer [17], [22]) são comparados, permitindo avaliar qual o mais adequado para a extração de regras.

1.4. Descrição da Teste

Esse trabalho envolveu cinco etapas:

- a) Estudo de SVMs binárias;
- b) Estudo dos métodos de classificação em múltiplas classes;
- c) Estudo de sistemas de inferência fuzzy;
- d) Desenvolvimento de um modelo genérico de extração de regras fuzzy para a classificação em duas ou mais classes;
- e) Estudo de Casos.

Uma vez que o trabalho realizado teve como base a utilização de SVMs, que foram originalmente definidas para a classificação em duas classes, foi feito um estudo inicial de SVMs binárias. Para o bom entendimento dessas máquinas foi necessária uma pesquisa preliminar sobre a metodologia de aprendizado, kernels e espaços de características. Além disso, para a compreensão do funcionamento de SVMs, alguns conceitos como teoria da generalização e da otimização são fundamentais, tendo sido bastante pesquisados. Por fim, para a efetiva utilização de SVMs, pesquisou-se sobre as técnicas de implementação existentes.

Como o interesse desse trabalho era a classificação em duas ou mais classes, foi necessária a realização de um levantamento bibliográfico dos métodos existentes para a classificação em múltiplas classes, incluindo uma análise comparativa das vantagens e desvantagens de cada método. Dentre os métodos pesquisados, três podem ser destacados como os mais utilizados: método de decomposição um por classe, método de separação das classes duas a duas e método de Crammer e Singer.

No estudo de sistemas de inferência fuzzy [6], três tópicos foram abordados: conjuntos fuzzy, lógica e inferência fuzzy, e métodos de extração de regras fuzzy.

Para o desenvolvimento de um modelo genérico de extração de regras fuzzy para a classificação em duas ou mais classes foi realizado um levantamento bibliográfico dos métodos de extração de regras já existentes, tanto para o caso de regras fuzzy quanto para o caso de regras simbólicas, incluindo vantagens e desvantagens de cada método. A pesquisa teve como objetivo principal o estudo das características principais desses métodos.

Antes de testar o modelo genérico de extração de regras fuzzy para a classificação em duas ou mais classes, foi necessária a escolha dos bancos de

dados mais adequados aos nossos propósitos, de acordo com o número e tipo de atributos, com o número de classes e com a relevância desses bancos de dados (utilização em artigos/teses relacionados ao tema do trabalho). Assim, foram escolhidas quatro aplicações diferentes, duas para classificação binária e duas para classificação em mais de duas classes. Os resultados obtidos pelo modelo proposto neste trabalho – FREx_SVM - foram comparados com os obtidos por outro métodos.

1.5. Estrutura da Tese

Esta proposta está dividida conforme descrito a seguir.

No capítulo 2, inicialmente são descritas as máquinas de vetor suporte para o caso de classificação binária. Em seguida, são apresentados os três métodos existentes de utilização de máquinas de vetor suporte em problemas de múltiplas classes: método de decomposição um por classe ("one-against-all"), método de separação das classes duas a duas ("one-against-one") e o método de Crammer e Singer.

No capítulo 3 são apresentados os dois principais métodos de extração de regras simbólicas a partir de SVM já existentes na literatura: RulExSVM e SVM+Prototypes.

No capítulo 4 é apresentado o modelo FREx_SVM, que, como já foi mencionado, tem como objetivo extrair regras fuzzy a partir de uma SVM treinada. Além da proposta e do desenvolvimento do modelo FREx_SVM, são apresentadas duas métricas para a avaliação das regras fuzzy: acurácia e abrangência fuzzy.

No capítulo 5 são discutidos os estudos de casos realizados para a extração de regras tanto para o caso binário quanto para o caso de múltiplas classes. No caso de classificação em mais de duas classes, são comparados os desempenhos dos métodos de classificação em múltiplas classes.

As conclusões e os trabalhos futuros encontram-se no capítulo 6.

Além dos capítulos citados, essa tese possui três apêndices. No primeiro encontra-se o princípio de minimização do risco estrutural. O apêndice 2 apresenta uma comparação do desempenho dos métodos de classificação em múltiplas classes para o reconhecimento das expressões faciais. No apêndice 3 são apresentadas as regras geradas em todos os casos avaliados.