

6 Conclusões e Trabalhos Futuros

6.1. Conclusões

As máquinas de vetor suporte têm obtido sucesso na solução de inúmeros tipos de problemas, como categorização de textos [25], categorização de SPAM [26], reconhecimento de caracteres manuscritos [3], [4], reconhecimento de textura [27], análise de expressões de genes [28] e reconhecimento de objetos em 3 dimensões [29]. O treinamento de SVMs é feito através da resolução de um problema quadrático com restrições lineares. Na solução desse problema quadrático são selecionados, entre todos os vetores de entrada, os vetores mais importantes, conhecidos como vetores suporte.

Como foi indicado no capítulo 1, o principal objetivo desta tese foi o desenvolvimento de um modelo genérico de extração de regras fuzzy a partir de SVMs para classificação (envolvendo duas ou mais classes). A expectativa era que, com esse modelo, fosse conseguida maior interpretabilidade lingüística do que os algoritmos existentes.

Com vistas à concretização desse objetivo, efetuou-se extenso trabalho de pesquisa compreendendo sistemas de inferência fuzzy, SVMs binárias e métodos de classificação em múltiplas classes.

O modelo genérico de extração de regras fuzzy a partir de SVMs para classificação (envolvendo duas ou mais classes) proposto nesta tese, em contraste com os modelos RuExSVM [13] e SVM+Prototypes [14], [15], tem a desejada vantagem de ter alto grau de interpretabilidade.

Para a avaliação do desempenho do modelo FReX_SVM foram selecionados alguns bancos de dados com características relevantes para sua validação e que têm sido utilizados em testes semelhantes. Os estudos de casos para classificação descritos no capítulo 5, realizados com 4 conjuntos de dados, confirmaram o bom desempenho esperado para o modelo FReX_SVM. O modelo FReX_SVM apresentou boa precisão, interpretabilidade e cobertura.

Como foi indicado no capítulo 5, os resultados dos testes comprovaram que a estratégia de extração de regras com a utilização de conjuntos fuzzy é

uma excelente opção tanto para classificação binária quanto para classificação em mais de duas classes, com o emprego dos três métodos de classificação. Além da vantagem da interpretabilidade, a cobertura das regras mostrou-se excelente. Para o problema da íris, apenas a configuração com sete conjuntos fuzzy não teve cobertura de 100% dos padrões de teste. No caso da classificação do tipo de vinho, a configuração com 3 conjuntos fuzzy obteve cobertura de 92,13% dos padrões de teste. Para o banco de dados Bupa Liver Disorders, a cobertura das regras para a configuração com 3 conjuntos fuzzy foi de 95,94%. Por último, no caso do Wisconsin Breast Cancer, essa cobertura, também com 3 conjuntos fuzzy, foi de 77,90%.

6.2. Trabalhos Futuros

Uma extensão interessante do modelo FREx_SVM seria sua combinação com algum algoritmo de seleção de características [57], [58]. Com menos atributos de entrada, as regras teriam menos antecedentes, facilitando a interpretação.

Para tentar melhorar o desempenho do FREx_SVM quatro pontos podem ser estudados: a) testar diferentes kernels, b) ter um número de conjuntos fuzzy diferente para cada coordenada, c) fazer um ajuste automático dos conjuntos fuzzy, d) mudar o formato dos conjuntos fuzzy de entrada e modificar a forma como o grau da regra é calculado.

A utilização de kernels diferentes do linear e do RBF poderá gerar vetores suporte diferentes dos obtidos aqui e assim formar outro conjunto de regras, com eventual melhor desempenho.

A possibilidade de se definir um número diferente de conjuntos fuzzy para diferentes atributos pode trazer benefícios, já que cada atributo terá um domínio diferente.

O ajuste automático dos conjuntos fuzzy permite que o suporte desses conjuntos e seus graus de pertinência sejam definidos a partir dos dados de entrada. Nesse caso, os graus de pertinência dos antecedentes se adaptam à localização dos dados usados para criar as regras. Assim, se os conjuntos fuzzy representam melhor os dados de entrada, as regras geradas pelo FREx_SVM podem ser mais precisas, melhorando seu desempenho.

Apenas a mudança de formato dos conjuntos fuzzy não alterará significativamente a base de regras. No entanto, se combinada com uma mudança no cálculo do grau da regra, podem-se obter formas diferentes de associar regras a vetores suporte. No modelo atual, o operador produto é empregado para o cálculo do grau atribuído a uma regra. Como opção para esse cálculo, pode-se utilizar a soma limitada ou o operador mínimo.