


Aplicação de Técnicas de Visão Computacional e Aprendizado de Máquina Para a Detecção de Exsudatos Duros em Imagens de Fundo de Olho



Tiago Carvalho, Siome Goldenstein, Jacques Wainer

Palavras-chave: retinopatia diabética, pontos de interesse, dicionários visuais

1 - Motivação

A *diabetes mellitus* (DM) vem crescendo de forma rápida e segundo dados fornecidos pela Organização Mundial de Saúde (OMS) 300 milhões de pessoas desenvolverão a doença até 2025 [4]. A retinopatia diabética (RD) é um dos tipos de complicações provocados pela DM no organismo. Um método capaz de ajudar na triagem de pacientes portadores de RD seria de grande ajuda para especialistas da área.

2 - Contribuição


Neste trabalho, desenvolvemos um método robusto e com alta taxa de sensibilidade para detecção de exsudatos duros (uma anomalia da RD) em imagens de fundo de olho. Tal método é baseado em PoI e DV, o que o torna de fácil extensão para ser aplicado em outros tipos de anomalias.

3 - Pontos de Interesse (PoI)

Para representar o conteúdo visual de uma imagem, encontramos um conjunto de pontos de interesse (PoI) e caracterizamos uma região ao redor de cada ponto. É desejável escolher pontos de interesse invariantes a escala e orientação para que essa representação seja robusta a algumas transformações da imagem. Para isso utilizamos o método denominado *Speeded-Up Robust Features* (SURF) [1].


4 - Dicionário Visual (DV)

Para preservar o poder de distinção dos PoI e aumentar sua generalização, utilizamos o conceito de dicionários visuais (DV) [3]. Um dicionário de tamanho x é baseado nos $\frac{x}{2}$ PoI mais representativos de imagens normais, e pelos $\frac{x}{2}$ PoI mais representativos de imagens com anomalia. Tais pontos são escolhidos com base nas imagens de treinamento e denominam-se palavras visuais.



5 - Curvas ROC

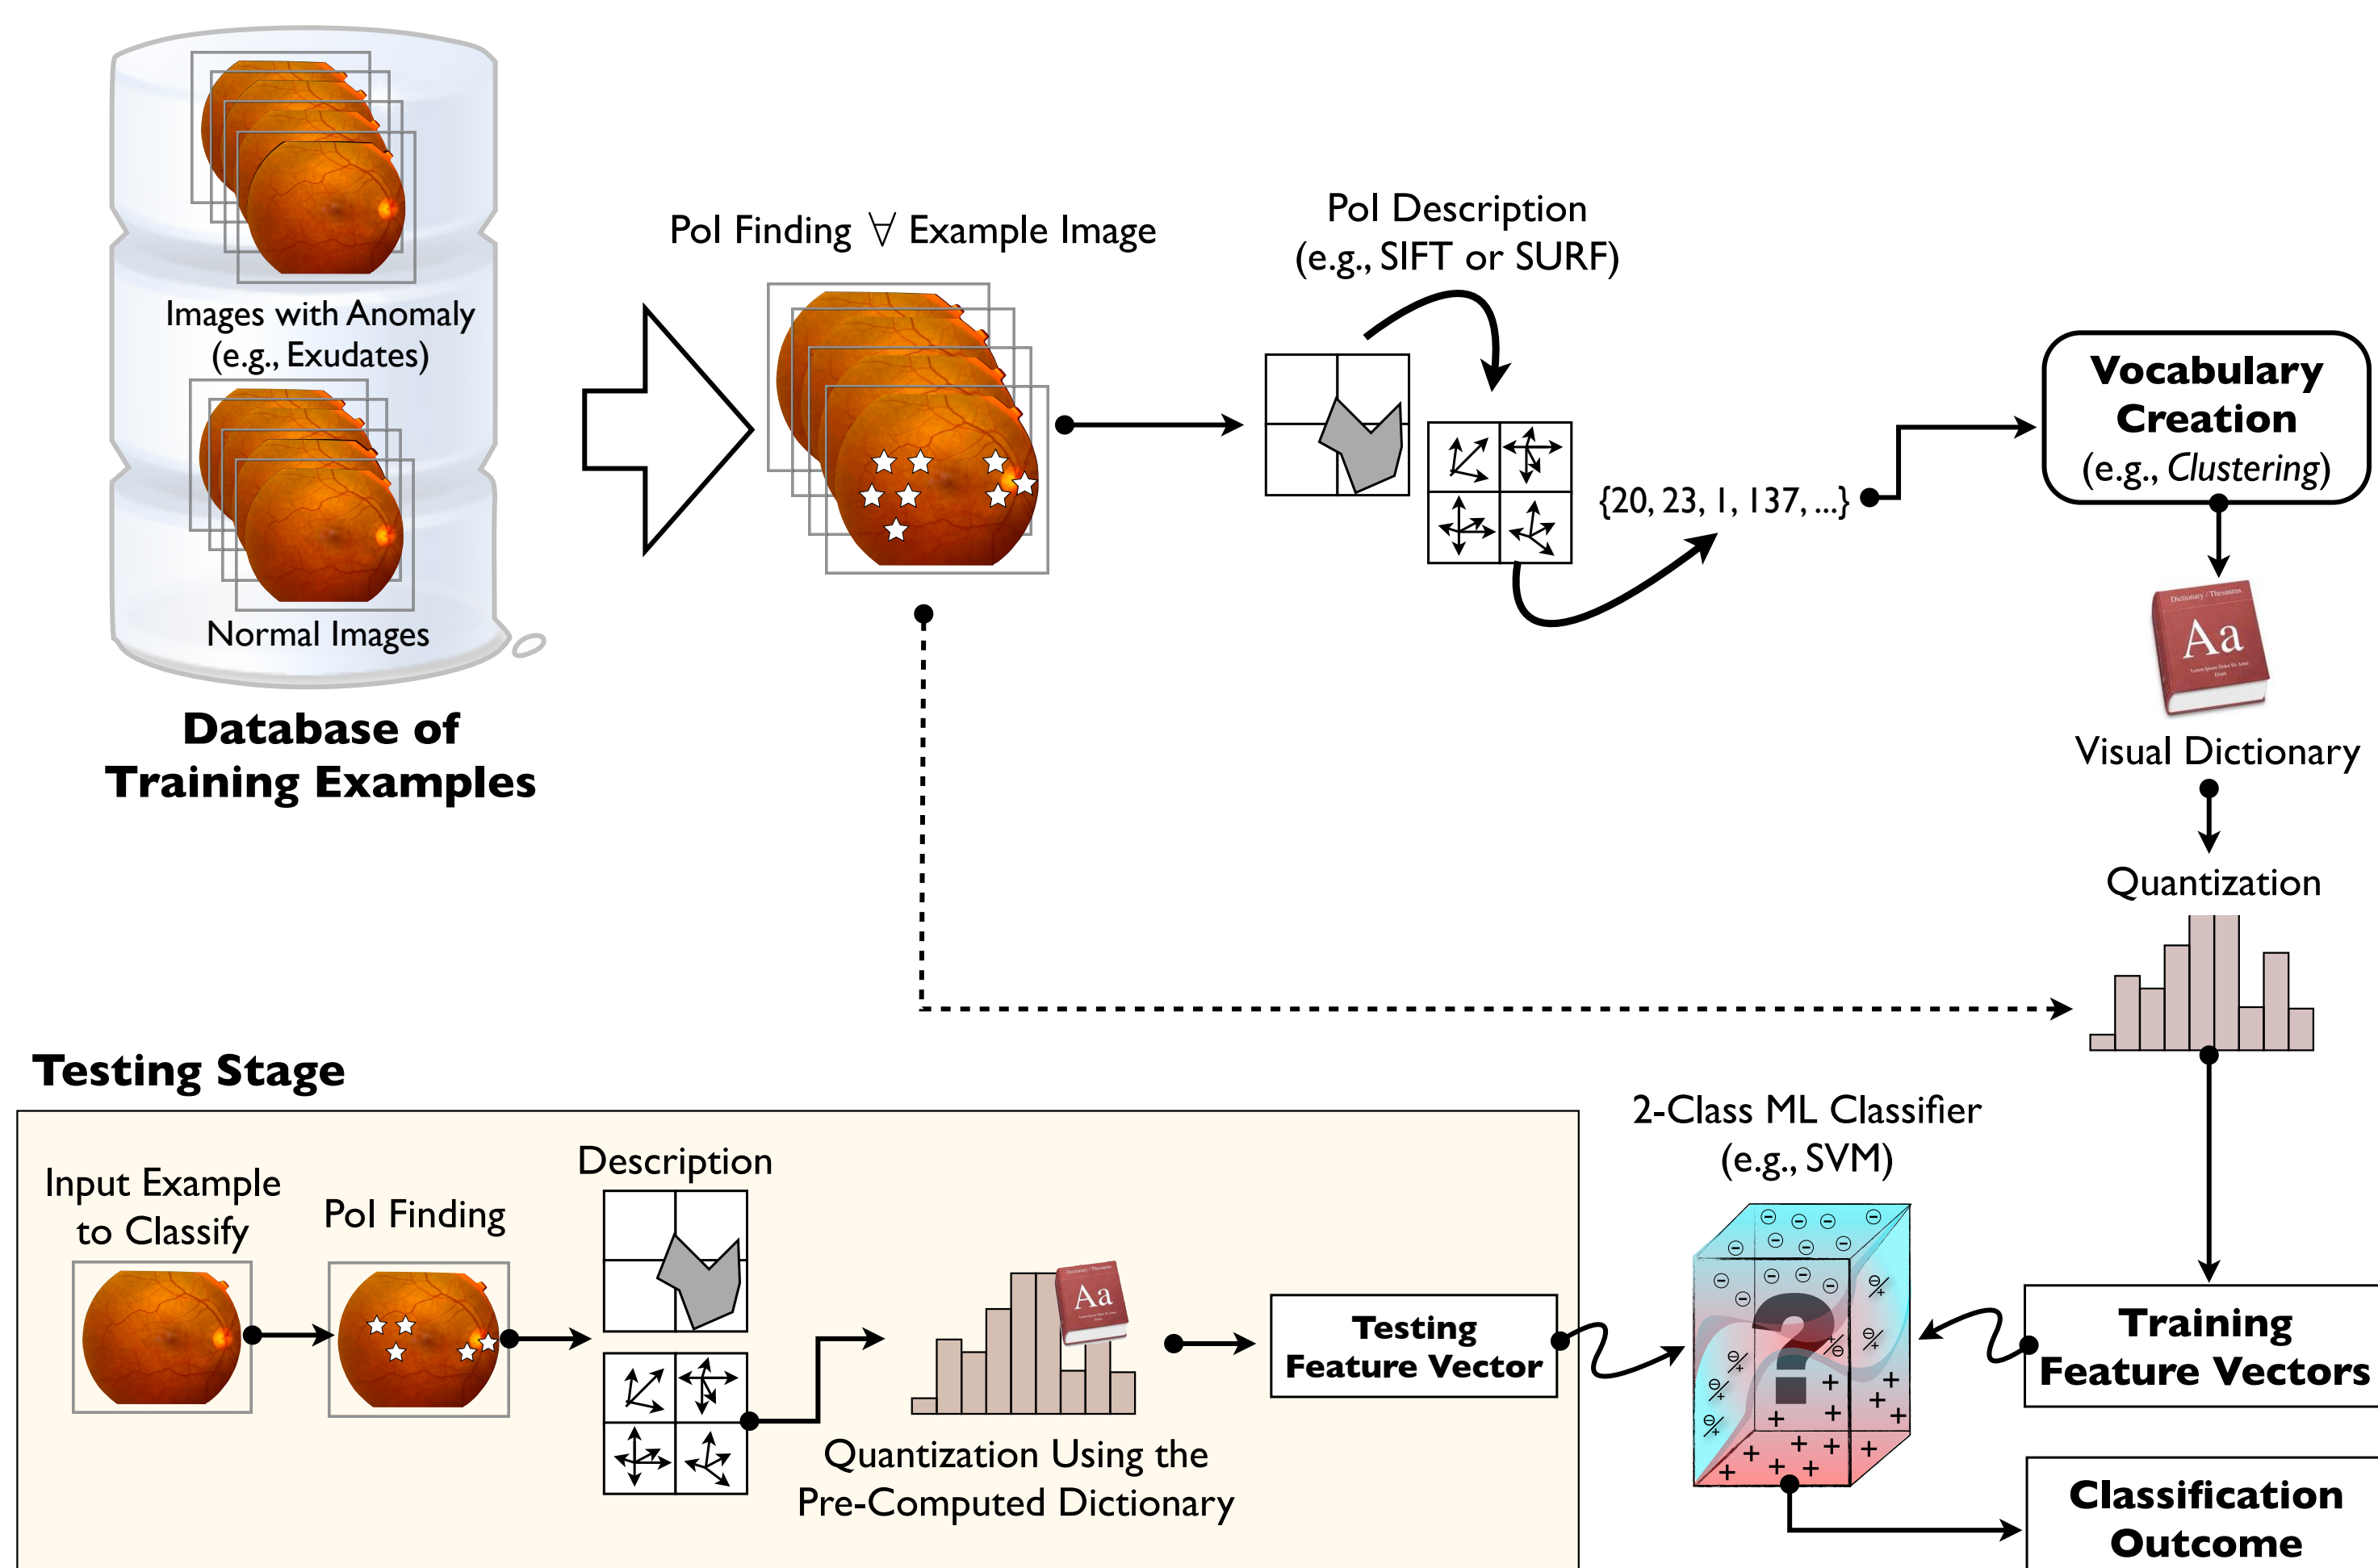
A curva ROC original é baseada em duas medidas de probabilidade denominadas sensibilidade (SE) e especificidade (ES). Ela apresenta através de um gráfico o equilíbrio de diferentes limiares entre obter uma maior taxa de verdadeiros positivos (sensibilidade) com um custo adicional de falsos positivos (1 – especificidade).



6 - Treinamento e Classificação

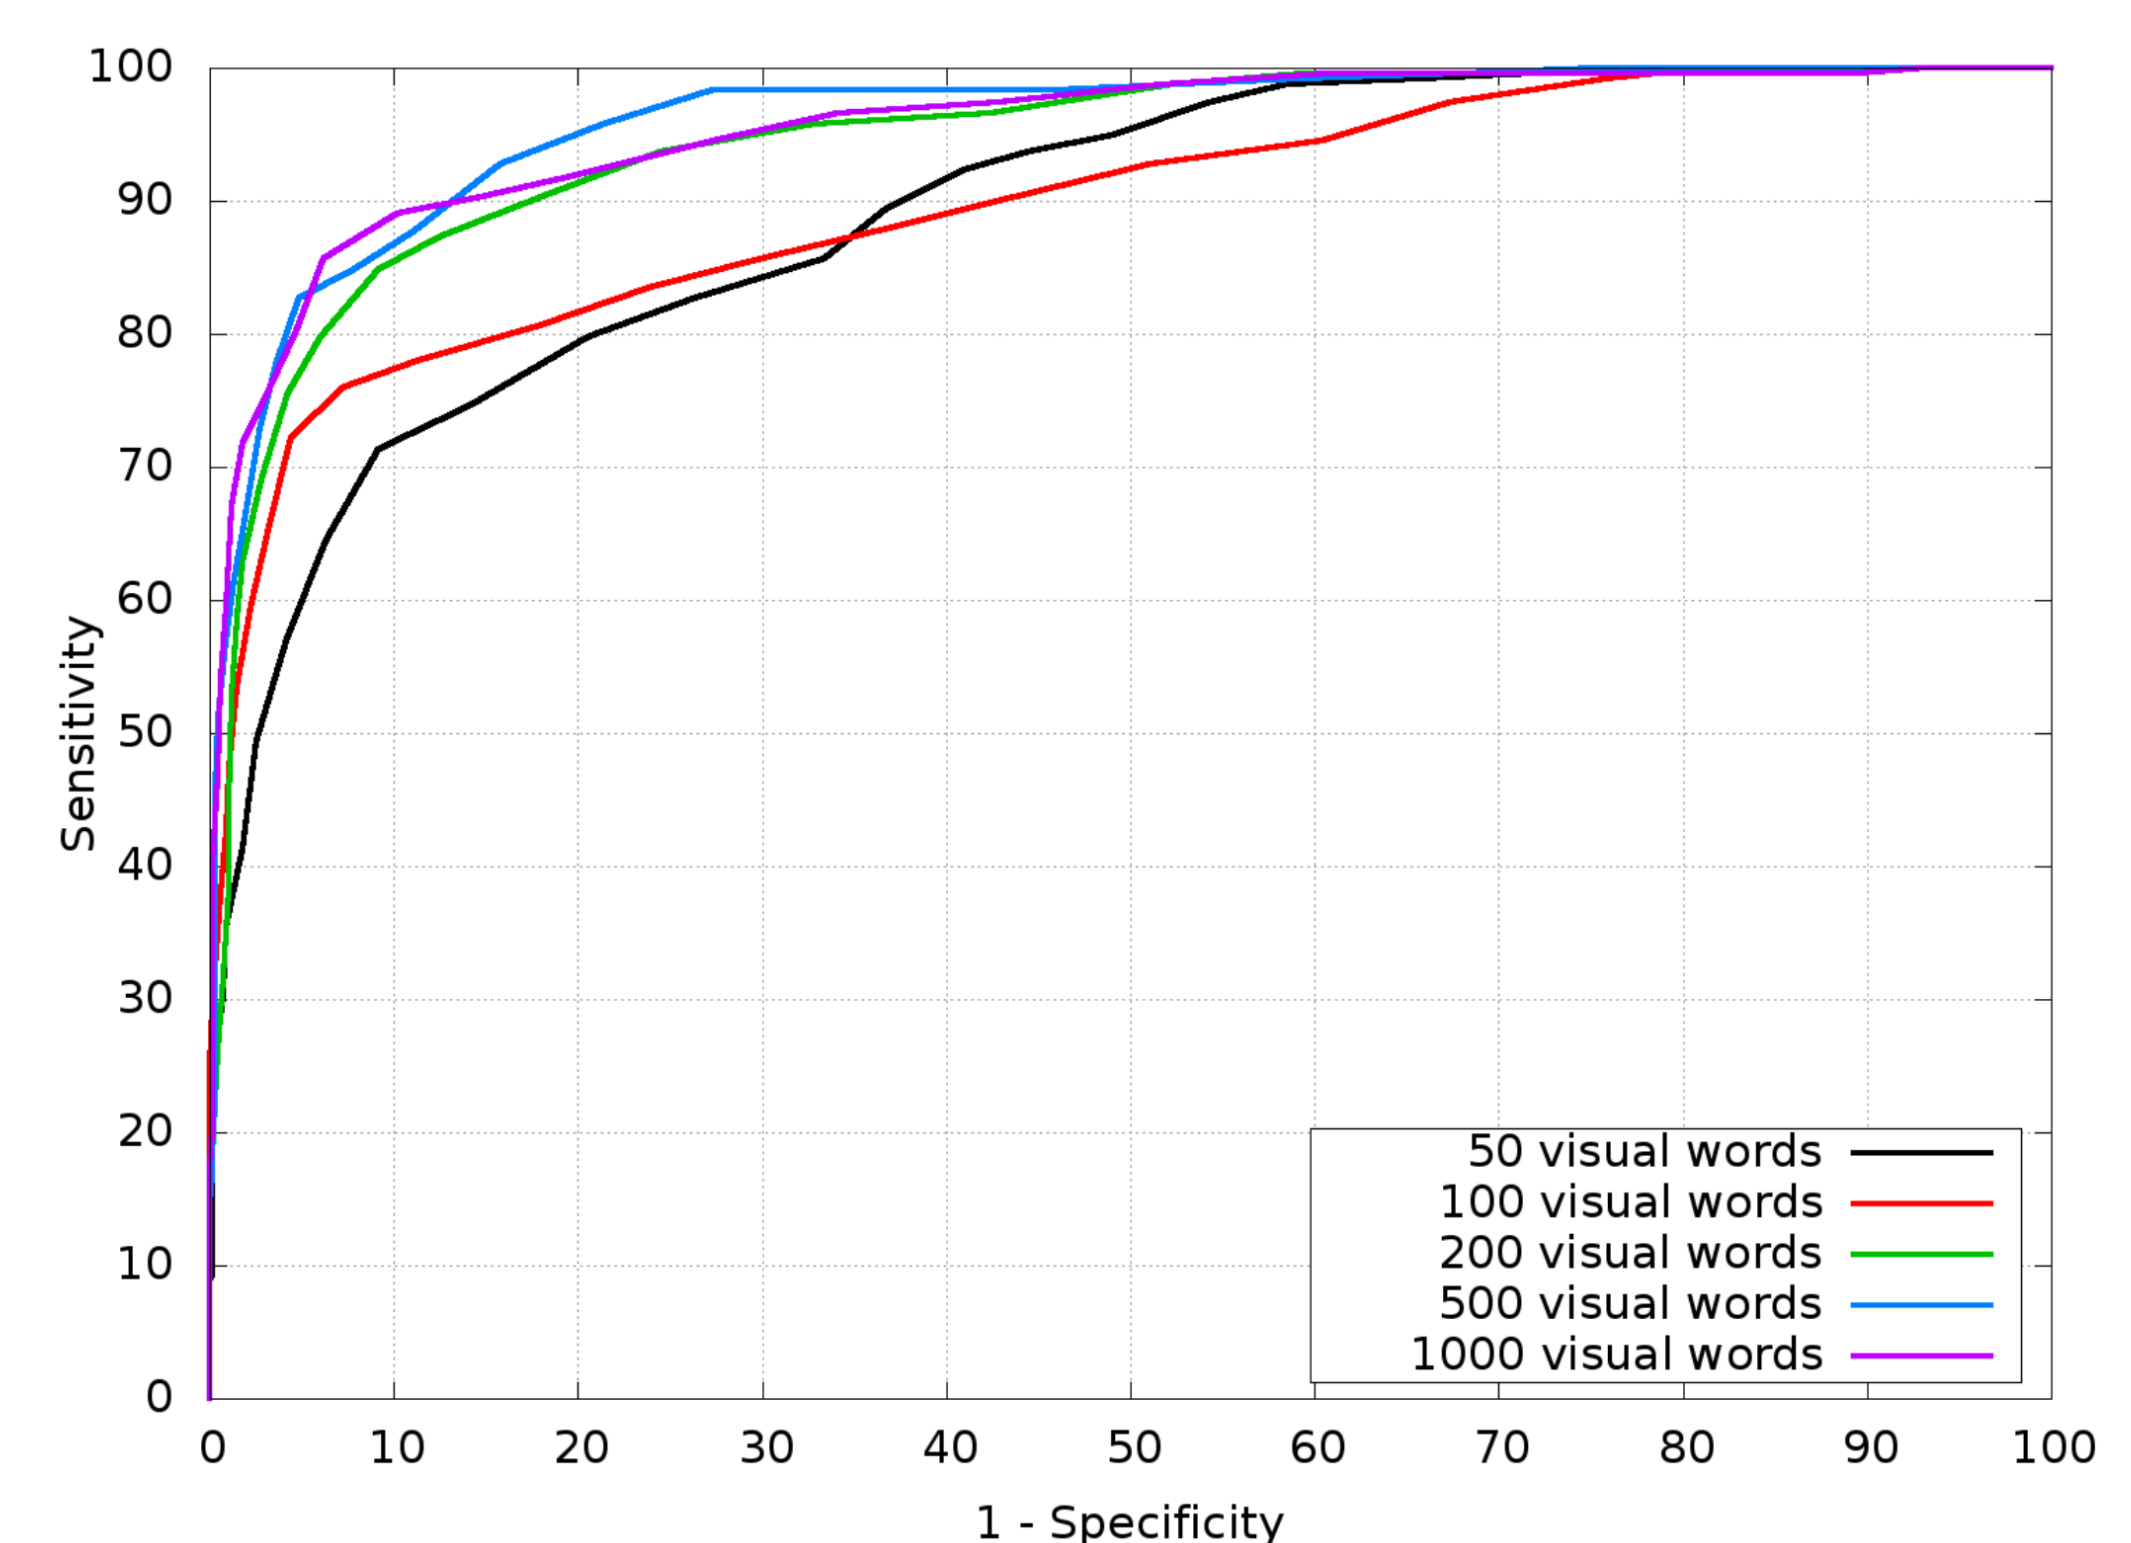
Para classificar as imagens utilizamos o *Support Vector Machines* (SVM) [2]. No processo de classificação, a base de dados é dividida em dois conjuntos: treino e teste. Os parâmetros de ajuste do classificador são obtidos utilizando um processo de busca automática sobre o conjunto de treino. Para validar os resultados, utilizamos o processo de validação cruzada baseada em cinco dobras.

7 - Metodologia



8 - Resultados

O gráfico abaixo exibe as curvas ROC utilizando diferentes números de palavras visuais. Utilizando 500 palavras visuais obtivemos 90% de sensibilidade com 87% de especificidade. A taxa de erro igual foi de 88% para 500 palavras e a área sob a curva de 95.3%.



Referências

- [1] H. Bay, A. Ess, T. Tuytelaars, and L. V. Gool. Speeded-up robust features (SURF). *Computer Vision Image Understand*, 110(3):346–359, 2008.
- [2] K. P. Bennett and C. Campbell. Support vector machines: Hype or hallelujah? *Association for Computing Machinery's Special Interest Group on Knowledge Discovery and Data Mining*, 2(2):1–13, 2000.
- [3] J. Sivic and A. Zisserman. Video google: A text retrieval approach to object matching in videos. In *9th IEEE International Conference on Computer Vision*, pages 1470–1477, 2003.
- [4] K. W. Tobin, E. Chaum, V. P. Govindasamy, and T. P. Karnowski. Detection of anatomic structures in human retinal imagery. *IEEE Transactions on Medical Imaging*, 26(12):1729–1739, 2007.

Agradecimentos

