

# ESTUDO E IMPLEMENTAÇÃO DE ALGORITMOS PARA A CLASSIFICAÇÃO AUTOMÁTICA DE RETINAS PATOLÓGICAS

Fernando Assunção Sousa (bolsista de ICV/UFPI), Rodrigo de Melo Souza Veras (Orientador, Depto de Informática e Estatística – UFPI)

## Introdução

Os sistemas de Diagnósticos Assistidos por Computadores (*Computer Aided Diagnosis - CAD*) estão sendo implementados e usados com o passar dos anos, pois possuem um grande potencial para fornecer uma solução alternativa aos programas de triagem em massa que precisam examinar um grande número de imagens em pouco espaço de tempo [1].

Os sistemas CAD em sua maioria estão em fase de investigação e não podem ser colocados em uso prático. As imagens de retina podem apresentar inúmeros tipos de lesões e artefatos, assim dificultando a implementação de um algoritmo que lide com uma grande quantidade de imagens de retina com várias características.

A Classificação das imagens com pré-processamento para identificar as que possuem patologias foi um solução encontrada para o problema da diversidade de imagens. Para o pré-processamento utilizou-se:

O Algoritmo *Speed-Up Robust Features* (SURF) [2], descritores locais é invariante a rotação e a escala, para extrair as informações das imagens gerando vetores de atributos.

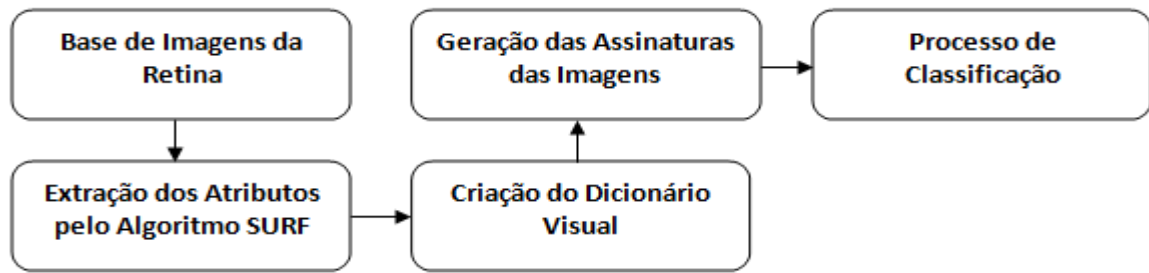
A *Support Vector Machines* (SVM) [3] para classificação das imagens de retina, sendo uma técnica de aprendizado para problemas de reconhecimento de padrão.

## Metodologia

Para alcançar os objetivos e metas traçados neste projeto, ele foi dividido em quatro fases: Fase Teórica (FT); Fase de análise (FA); Fase de Desenvolvimento (FD); Fase de Finalização (FF).

Na FT foram feitos levantamentos bibliográficos da área de processamento de imagens, bem como sobre a retina humana e acerca das tecnologias que poderiam ser utilizadas para programar os algoritmos do projeto, já na FA foi feito um levantamento sobre as bases de imagens de retina que foram utilizadas para testar os algoritmos estudados e desenvolvidos na FD, nesta foram implementados novos algoritmos visando melhorias nos já existentes, podemos cita o SURF, os Dicionários Visuais e SVM e por fim, na FF detalhamos os passos do algoritmo criado. Além disso, nessa fase foi executado e testado a eficiência do novo algoritmo em relação aos já existentes na literatura.

Para obtenção dos resultados pode ser observado em 5 etapas na Figura 1 que são: obtenção da bases de imagem, extração dos atributos a partir da base de imagens, com os atributos serão criados os Dicionários Visuais são utilizado para padronizar o comprimento dos vetores de atributos gerados pelo SURF usados para gerar as assinaturas das imagens e por fim o processo de classificação com uso do SVM que faz um mapeamento do espaço de entrada para um espaço de dimensionamento maior e após isso faz um cálculo de um hiperplano de separação.



**Figura 1. Fluxograma da classificação da imagem de retina**

### Resultados e Discussão

Foi feito um levantamento bibliográfico e estudo sobre Processamento Digital de Imagem (PDI) e como programá-los de forma a obter algoritmos que executem mais rápido, a ferramenta usada para programar os algoritmos foi o MATLAB<sup>1</sup>, e também um levantamento de algumas bases de imagens existentes, pois, praticamente todos os trabalhos relevantes usam uma dessas bases de imagens para testar os algoritmos desenvolvidos. As bases de imagens da retina usadas foram a STARE<sup>2</sup> e a ARIA<sup>3</sup>, exemplo das imagens das bases nas Figuras 2 e 3.



**Figura 2– Exemplos da base STARE, (a) sendo saudável e (b) doente.**



**Figura 3 – Exemplos da base ARIA, (a) sendo saudável e (b) doente.**

Para gerar dos resultados foi utilizado um conjunto de treinamento composto por 60% dos dados. O classificador foi executado 5 vezes no núcleo linear para identificar qual dos 4 tamanhos de dicionários tem melhor resultado na execução do algoritmo. A divisão dos dados pra teste e treinamento foi feita aleatoriamente a cada execução.

Para avaliar o desempenho do classificador utilizamos as seguintes taxas: sensibilidade, especificidade, Verdadeiro Preditivo Positivo (VPP), Verdadeiro Preditivo Negativo (VPN) e acurácia. Todas essas medidas podem ser calculadas baseadas e quatro valores: Verdadeiro Positivo (VP), número de imagens classificadas corretamente como saudáveis; Falso Positivo (FP), número de imagens erroneamente classificadas como saudáveis; Falso Negativo (FN), número de imagens

<sup>1</sup> <http://www.mathworks.com/products/matlab/>

<sup>2</sup> <http://www.ces.clemson.edu/~ahoover/stare/>

<sup>3</sup> <http://www2.it.lut.fi/project/imageret/diaretddb1/>

erroneamente classificadas como patológicas e Verdadeiro Negativo (VN), número imagens de classificadas corretamente como patológicas. Os resultados são apresentados nas Tabelas 1 e 2.

**Tabela 1. Avaliação pelo Classificador SVM na base STARE**

Tam. do Dicionário	VP	FP	FN	VN	Sensibilidade	Especificidade	VPP	VPN	Acurácia
6	2	0	18	18	10	100	100	50	52,63
10	3	9	0	26	100	74,29	25	100	76,32
16	7	0	6	25	53,85	100	100	80,65	84,21
20	10	1	5	22	66,67	95,65	91	81,50	84,21

**Tabela 2. Avaliação pelo Classificador SVM na base ARIA**

Tam. do Dicionário	VP	FP	FN	VN	Sensibilidade	Especificidade	VPP	VPN	Acurácia
6	7	5	10	21	41,18	80,77	58,33	67,74	65,12
10	13	2	5	23	72,22	92	86,66	82,14	83,72
16	8	3	9	23	47,06	88,46	72,73	71,88	72,09
20	13	4	3	23	81,25	70,83	76,44	88,46	83,72

### Conclusão

Analisando as Tabelas 1 e 2 pode-se observar que a porcentagem de maior acerto na classificação das imagens da base STARE é de 84,21%, enquanto na base ARIA é de 83,72% ambos valores calculados no teste com dicionário visual de tamanho 20 e o menor valor de acerto é encontrado na base STARE sendo de 52,63%.

Como o nosso objetivo é identificar retinas com patologias, as principais métricas que se deve levar em consideração são as medidas de especificidade. Dessa forma, apesar de as taxas de acurácia, em sua maioria, não terem ultrapassado 80% de acerto podemos afirmar que a proposta é válida. Isso é justificado, pois foram obtidas taxas de especificidade que chegaram a 100% em alguns dos casos de teste.

**Apoio:** Universidade Federal do Piauí – UFPI. Laboratório de Inteligência Computacional – LabInC.

### Referências

- [1]Noronha, K. e Nayak, K. P. (2012). Fundus image analysis for detection of diabetic eye diseases - a review. InInternational Conference on Bimedical Engineering (ICoBE)
- [2] Bay, H., Tuytelaars, T., e Gool, L. V. (2006). Surf: Speeded up robres. In European Conference on Computer Vision, pp 404–417.
- [3] Bishop, C. M. (2006). Pattern recognition and machine learning. In Machine Learning volume 1.

**Palavras-chave:** Classificação de Imagens. Retinas Patológicas. Extração dos Atributos.