

## INTRODUÇÃO

A *diabetes* é o nome atribuído a uma doença que ocorre quando o pâncreas não consegue produzir insulina suficiente, ou o corpo não consegue processá-la, fazendo com que o nível de glicose no sangue aumente. Uma de suas complicações é a *Retinopatia Diabética (RD)*, proveniente do enfraquecimento das artérias e veias oculares. Sem o devido tratamento, a RD leva à perda da acuidade visual e progressivamente até à cegueira. Por ser uma doença assintomática, ou seja, só nota-se seus sintomas quando ela já se encontra em estágio avançado, o diagnóstico precoce é importante. Este é feito através da análise de fotografias do fundo do olho do paciente (retinografia) por especialistas.

Através dos métodos aplicados por CARVALHO (2010), é possível a separação entre imagens que apresentam alguma alteração no fundo do olho do paciente e imagens normais. Entretanto, para garantir uma maior margem de acerto no diagnóstico, é necessário que as imagens apresentem boa qualidade.

O objetivo deste projeto de iniciação científica foi a aplicação de técnicas de aprendizado de máquina e processamento de imagens que pudessem atestar a qualidade das fotografias de fundo de olho.

## METODOLOGIA

Foi utilizado um conjunto de 1186 imagens de fundo de olho, analisadas por especialistas e separadas em duas classes: aquelas que alcançavam o padrão de qualidade desejado e aquelas que não alcançavam. Para tanto, foi levado em consideração se a imagem estava em foco e se sua mácula, região circular escurecida, estava centralizada, como na Figura 1.

Além disso, foi levado em conta a presença de reflexos dos cílios do paciente, pequenas círculos brilhantes espalhados pela imagem, como na Figura 2, que possivelmente poderiam ser identificados pelo classificador como anomalias da retina.



Figura 1. Imagem da retina em foco e com mácula centralizada



Figura 2. Imagem da retina com a presença de reflexos do cílio do paciente

Para cada fotografia da base de dados, seus *pontos característicos*, pontos da imagem invariantes a operações geométricas simples como rotação e mudança de escala, foram extraídos e descritos em informações de baixo nível (cor, textura, brilho, entre outros) utilizando o algoritmo *Speed-Up Robust Features (SURF)*. Cada imagem tornou-se um conjunto de regiões, denominadas *palavras visuais*, onde se dá mais importância à sua descrição que sua posição espacial.

As imagens de cada classe foram divididas aleatoriamente em 5 subconjuntos (*folders*) de mesmo tamanho. Separando um par de *folders* (um de cada classe) como sendo um *conjunto de teste*, foram selecionadas aleatoriamente palavras visuais dos *folders* restantes, denominados *conjunto de treinamento*, para gerar um *dicionário visual* --- um conjunto de palavras visuais capaz de representar tanto as imagens com qualidade como as que não atingem a qualidade padrão desejável. Este processo foi repetido de modo a obter 5 dicionários visuais, cada um tomando um par de *folders* como conjunto de treinamento. Representou-se cada imagem como um histograma das palavras visuais presentes no dicionário visual.

Foi utilizado a técnica de *Support Vector Machine (SVM)*, para modelar o classificador desejado. As etapas de sua construção estão esquematizadas na Figura 3. Foram utilizados os mesmos conjuntos de teste e treinamento selecionados ao construir os dicionários, de modo que na etapa de treinamento, foi realizada uma validação cruzada de modo a melhor ajustar os parâmetros do classificador empiricamente.

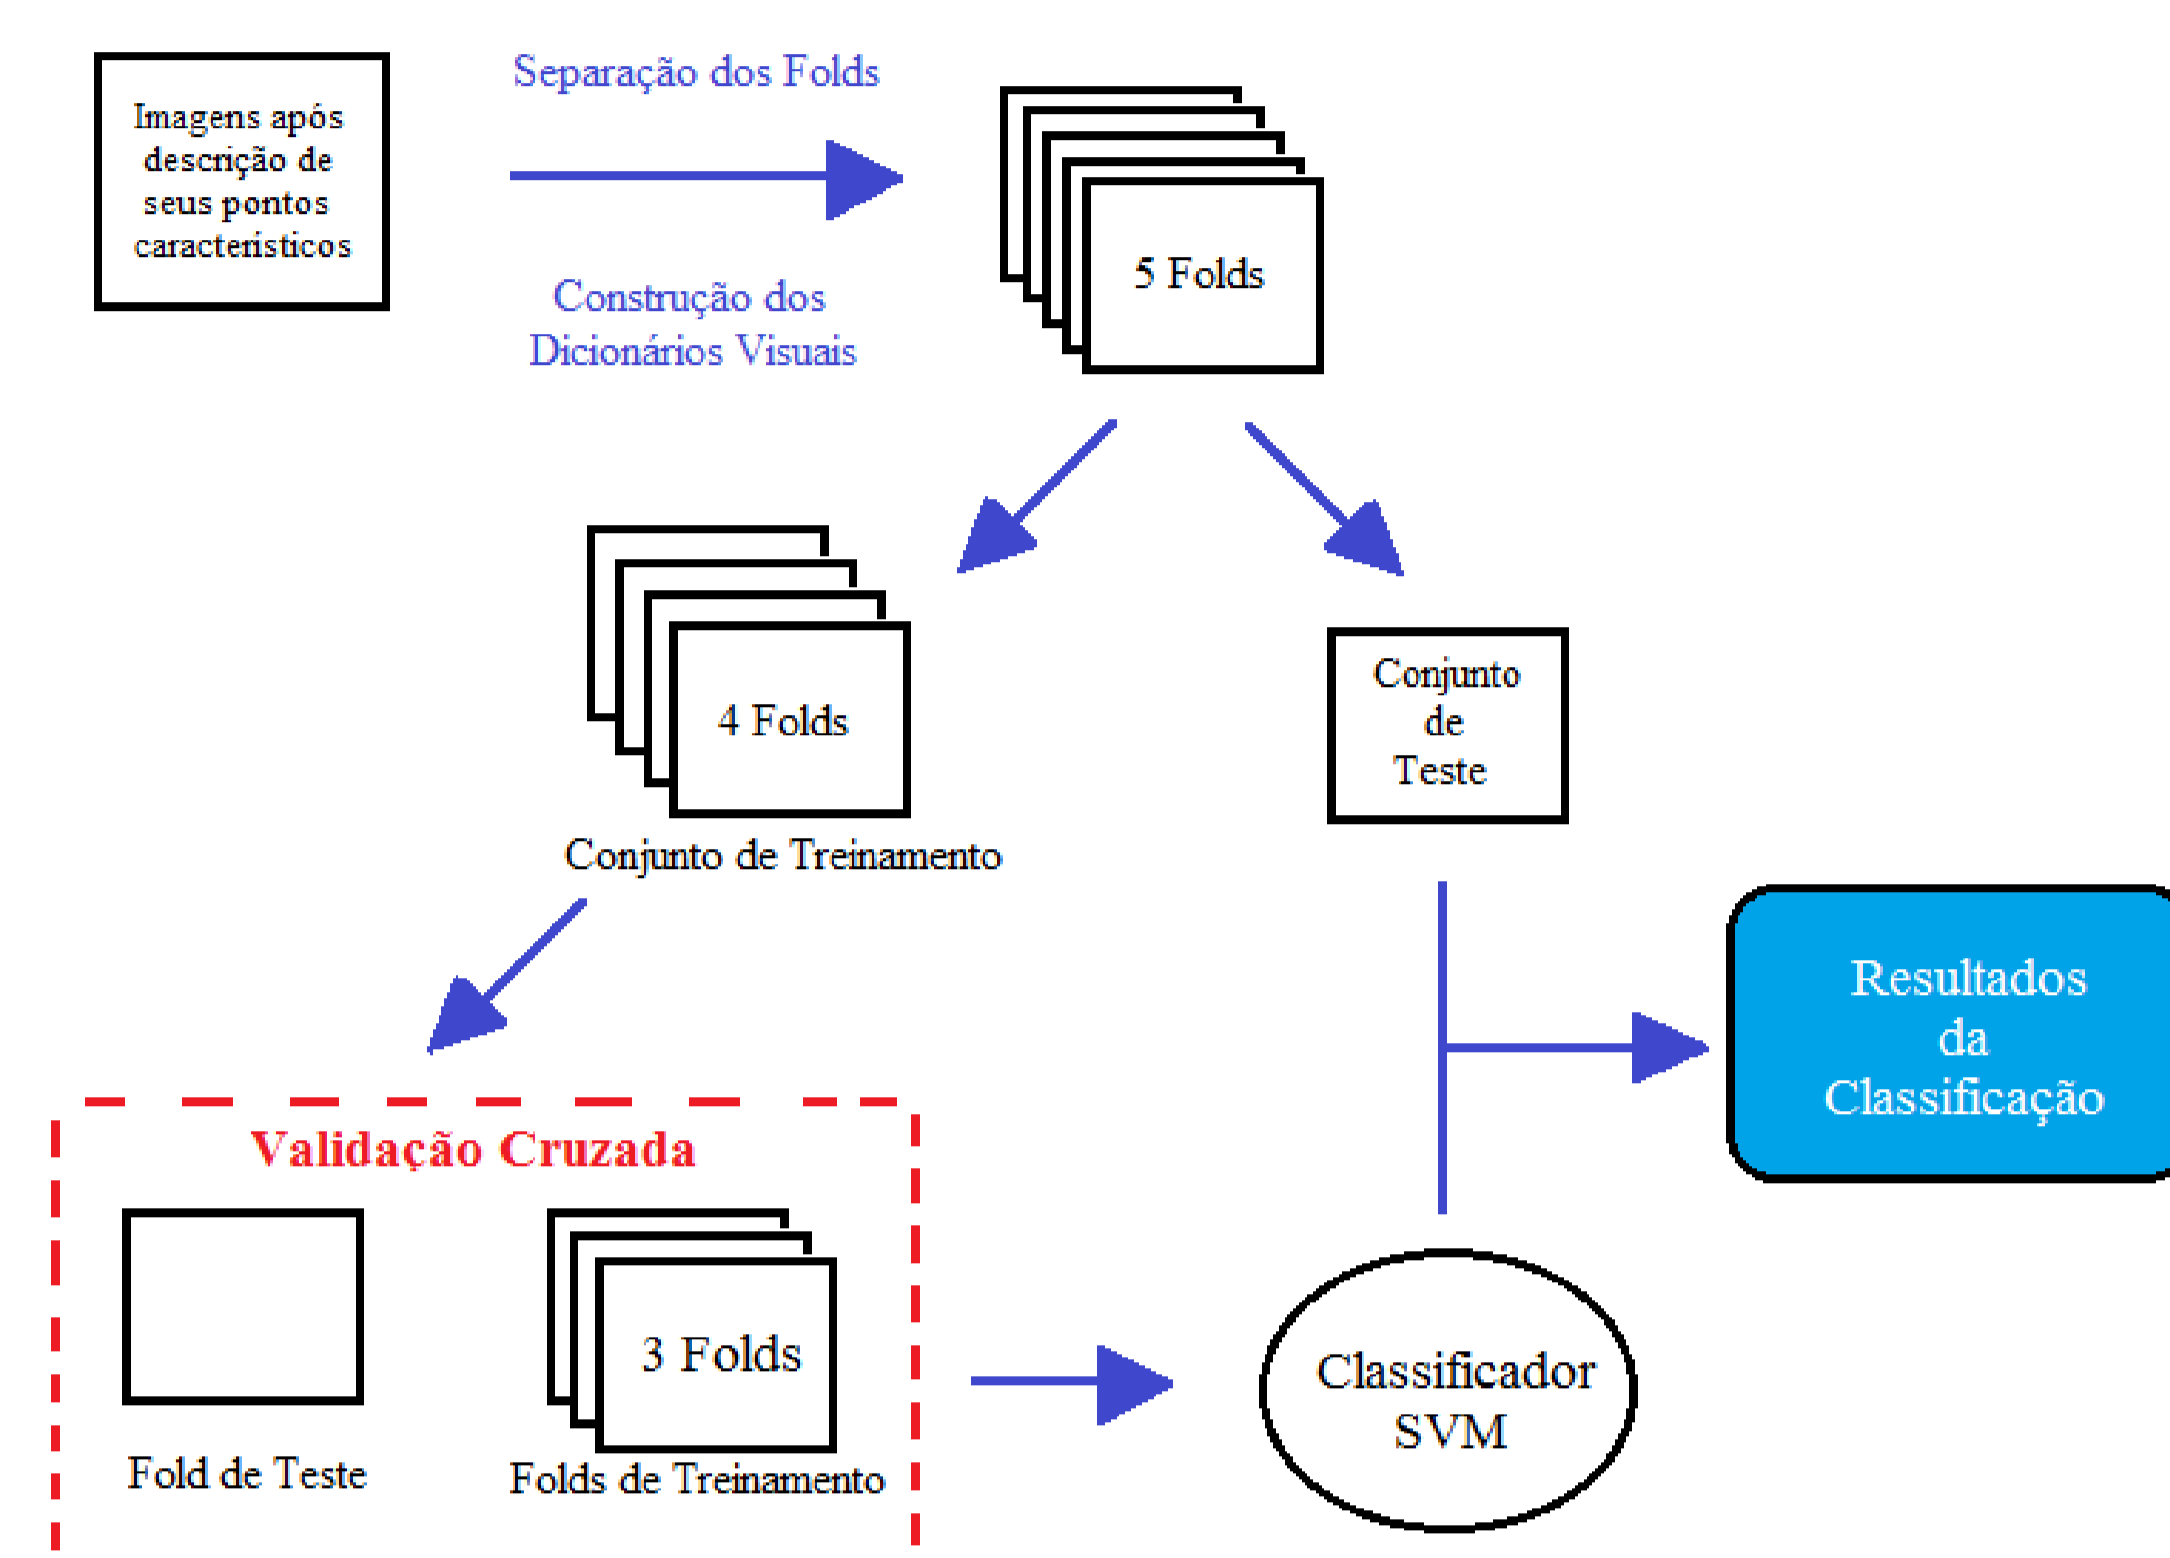


Figura 3. Esquema da etapa de classificação para um dicionário visual

Uma vez o classificador pronto, ele foi aplicado nos conjuntos de testes. O processo de treinamento e classificação foi repetido até que todos os pares fossem classificados. Utilizando a média dos valores obtidos de sensibilidade e especificidade, construiu-se as curvas ROC para analisar os resultados.

Nos experimentos, dois parâmetros --- número de palavras visuais nos dicionários e proporção de palavras visuais retiradas de imagens com e sem qualidade --- foram variados de modo a identificar sua influência na classificação e, conseqüentemente, obter a configuração que melhor classificaria as imagens.

## RESULTADOS

A primeira etapa dos experimentos consistiu em encontrar o comportamento da taxa de acerto mediante à variação do número de palavras visuais do dicionário. Foram realizados testes com dicionários de 200, 500 e 1000 palavras, mantendo a proporção de 50% entre palavras com e sem qualidade dentro do dicionário e os resultados estão expostos na Figura 4.

Já na segunda etapa dos experimentos, foi verificada a influência da proporção de palavras retiradas de imagens com e sem qualidade dentro de um dicionário de 1000 palavras visuais. Os resultados estão expostos na Figura 5.




Figura 4. Curvas médias dos experimentos com dicionários de 200, 500 e 1000 palavras visuais




Figura 5. Curvas médias dos experimentos variando a proporção de palavras com e sem qualidade

## CONCLUSÕES

Foi possível atestar que, no tratamento do problema, o tamanho do dicionário não parece influenciar significativamente o resultado final, uma vez que as curvas médias resultantes foram bastante semelhantes. Entretanto a proporção entre palavras visuais dentro do dicionário influi na taxa de acerto do classificador. Vê-se que há um ganho na faixa de sensibilidade de 70% a 90% quando mantém-se a proporção de 50% entre as palavras retiradas de imagens com qualidade e de sem qualidade.