

APLICAÇÃO DE APRENDIZAGEM DE MÁQUINA PARA A CLASSIFICAÇÃO AUTOMÁTICA DE RETINAS PATOLÓGICAS

Rodrigo Veras, Vinicius Machado, Romuere Silva, Flávio Araújo, Kelson Aires

Departamento de Informática e Estatística, Universidade Federal do Piauí, Teresina - PI

{rveras,vpmachado,romuere,flavio86,krtaires}@ufpi.edu.br

Resumo – Técnicas automáticas de identificação da doença oculares são muito importantes no campo da oftalmologia. As técnicas convencionais de identificação de doenças da retina são baseadas em observações manuais dos componentes da retina (disco óptico, mácula, vasos etc.) e são altamente suscetíveis e propensas a erros. Daí, a necessidade de técnicas automáticas que eliminem esses inconvenientes. Apesar de todos os avanços, os sistemas de identificação dos componentes da retina, ainda não podem ser utilizados na prática por causa da enorme diversidade de imagens. Em particular, imagens muito degradadas por patologias possuem muitos artefatos que dificultam a tarefa de detecção. Neste artigo, apresentamos uma proposta de aplicação de algoritmos de aprendizado de máquina na identificação de retinas patológicas. Dessa forma, um sistema automático de auxílio ao diagnóstico poderá identificar quais imagens deverão ter uma atenção maior do médico especialista.

Palavras-chave – aprendizagem de máquina, imagens de retina, diagnóstico auxiliado por computador

Abstract – Automated techniques for identification of eye disease are very important in the field of ophthalmology. Conventional techniques for the identification of retinal disease are based on manual observations of the components of the retina (the optic disc, macula, vessels, etc..) And are highly susceptible and prone to errors. Hence, there is a necessity for automated techniques that eliminate these drawbacks. Despite all the advances, the systems for identifying the components of the retina, still can not be used in practice because of the large diversity of images. In particular, images degraded by pathology has too many artifacts that complicate the task of detection. This paper presents a proposal for application of machine learning algorithms to identify pathological retinas. Thus, the computer-aided diagnosis system can identify which images should have a greater attention of the specialist doctor.

Keywords – machine learning, retinal image, computer aided diagnosis

1. INTRODUÇÃO

Com os avanços da tecnologia dos computadores, diversos tipos de diagnósticos assistidos por computador (CAD - *Computer Aided Diagnosis*) [1] têm sido desenvolvidos nos últimos anos. Os sistemas CAD ajudam a equipe médica na interpretação de imagens médicas e, conseqüentemente, proporcionam um “pré-diagnóstico”. Eles são de grande ajuda pois aliviam em muito as limitações do olho e do cérebro humano como fadiga e distração, respectivamente.

No campo oftalmológico, esses avanços tornaram possível a prevenção e o tratamento de doenças que há pouco tempo eram consideradas incuráveis. A prevenção primária e a detecção precoce, bem como o acesso a terapêuticas cirúrgicas oftalmológicas, são determinantes para a redução da morbidade¹ das doenças da visão.

Dessa forma, foram desenvolvidos um grande número de sistemas CAD de retina para o diagnóstico de vários tipos de doenças oculares, como glaucoma [2, 3], doenças maculares [4] e retinopatia diabética [5–7]. Estes sistemas CAD de retina tem potencial para fornecer uma solução alternativa aos programas de triagem em massa que precisam examinar um grande número de imagens de fundo de olho o mais rápido possível.

Até agora, a maioria dos sistemas CAD ainda estão em fase de investigação e não podem ser colocados em uso prático nas clínicas devido a várias razões. Uma dessas é a diversidade de imagens. Em particular, imagens de retina podem ter qualidades muito diferentes devido a vários tipos de lesões e artefatos. Como resultado, é muito difícil projetar um algoritmo de processamento de imagens que seja capaz de lidar com uma grande quantidade de imagens de retina com diversas características [8].

Uma solução para o problema da diversidade de imagens é realizar uma operação de classificação de imagens de retina como um procedimento de pré-processamento para a identificar aquelas “anormais”, ou seja as que possuem patologias. Com tal procedimento de pré-processamento sistemas de CAD mais robustos podem ser projetados com foco apenas nas imagens normais de retina. Já aquelas identificadas como “anormais” podem ser armazenadas para um exame manual por um especialista da área.

Este artigo apresenta uma proposta de identificação automática de imagens de retina patológicas. A abordagem proposta utiliza apenas as informações de cor da imagem e algoritmos clássicos de aprendizado de máquina. Além desta introdução, o documento está organizado da seguinte forma: na seção 2 são apresentados a base de imagem utilizada para os testes, bem como

¹Relação entre o número de casos de enfermidade e o número de habitantes em dado lugar e momento, ou relação entre sãos e doentes.

os procedimentos de extração dos atributos das imagens. Na seção 3 são mostrados os três classificadores testados. Os resultados são apresentados na seção 4 e as conclusões e trabalhos futuros são descritos na seção 5.

2. MATERIAIS E MÉTODOS

2.1 Base de imagens STARE

Utilizamos as imagens da base STARE² para realizar o treinamento e teste dos classificadores. Para isso usamos um subconjunto de 94 imagens. Este subconjunto é composto de 36 imagens de retinas saudáveis e 58 imagens que exibem uma ampla variedade de lesões e outros sintomas de doenças [9].

As imagens foram capturadas usando uma câmara TopCon TRV-50 com um campo de visão de 35°, e depois digitalizadas em imagens 605x700, com 24 bits por pixel. Cada imagem possui três planos de cores com oito bits por plano [9].

A figura 1 apresenta três exemplos de imagens da base STARE. Que vêm demonstrar como a diversidade das imagens dificulta a identificação dos componentes da retina. Suponha que queiramos identificar o disco óptico em uma tentativa de diagnóstico de glaucoma. Na figura 1(a) o contorno do disco óptico é bem definido o que torna mais fácil sua detecção. Já na figura 1(b) o plano de fundo é bastante heterogêneo e a região central possui intensidade de cor bem próxima a da região do disco óptico. A figura 1(c) apresenta uma imagem onde não é possível a identificação do disco óptico.

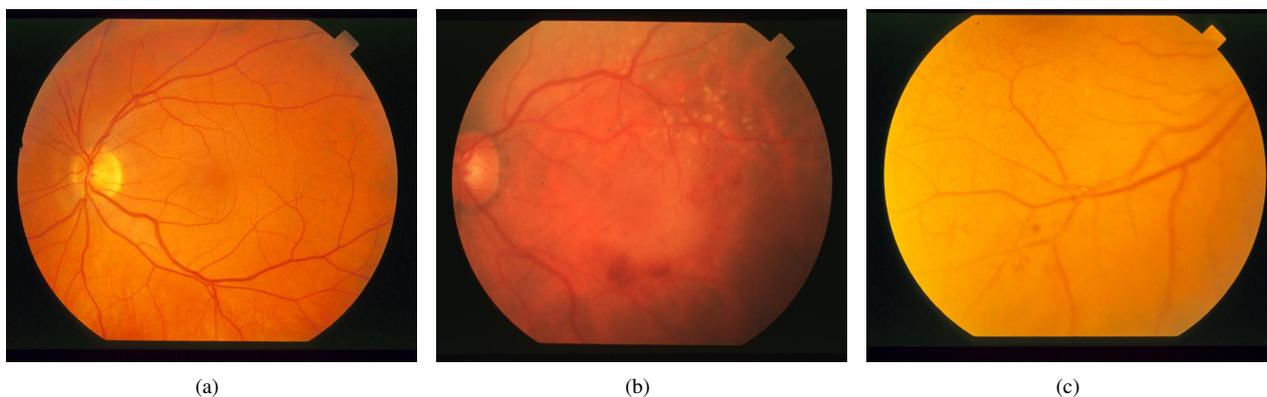


Figura 1: Exemplos de imagens da base STARE

Esta base de imagens já foi utilizada em vários trabalhos da literatura a saber, [10–13] (detecção do disco óptico), [14, 15] (detecção de exudatos) e [16] (detecção dos vasos) e constitui, por este motivo, uma base adequada para o desenvolvimento deste trabalho de comparação e avaliação de métodos.

2.2 Pré-Processamento da Imagem

Como mostrado na seção 2.1 as imagens originais possuem dimensões 605x700. Nosso objetivo é identificar imagens patológicas tendo como informação apenas as cores e o histograma da imagem. Dessa forma, o único pré-processamento realizado foi o de diminuição das medidas de cada imagem para 570x660. Essa diminuição visa remover grande parte do fundo preto de cada imagem. Dessa forma, a imagem resultante possui, proporcionalmente, mais pixels da retina.

2.3 Extração dos Atributos

Cada imagem de retina foi convertida em três vetores de atributos diferentes. O primeiro vetor contém apenas valores representativos das cores da imagem vermelho (R), verde (G) e azul (B) [17]. O segundo é composto por valores de *RGB* mais a distância métrica das componentes *R* e *G* [18] (essa distância será representada pela letra *D*). Por fim, o terceiro vetor foi construído pelos valores de *RGB* e três características do histograma da imagem: média, variância e energia [19] (essas três métricas forma o subvetor *H*).

A determinação dos valores representativos de *RGB* e *D* foi feita utilizando-se algoritmos de aglomeração de dados. Diversas técnicas de aglomeração têm sido ferramentas frequentemente recomendadas para trabalhos de classificação de padrões. Aglomeração nada mais é que um processo de particionamento de um conjunto de padrões em grupos (*clusters*) disjuntos, ou classes. É feito de tal forma que os padrões do mesmo agrupamento são classificados como iguais e padrões em agrupamentos diferentes, são marcados. O objetivo final de toda técnica de aglomeração é encontrar “agrupamentos naturais” através da análise de um conjunto de dados.

Inicialmente determinamos, utilizando o algoritmo SOM (*Self-Organizing Map*), a quantidade de grupos representativos da imagem. Para o conjunto de imagens dado, observamos que havia sempre 5 grandes grupos. Em uma segunda fase, a imagem de entrada é agrupada em 5 grupos. As componentes *R*, *G*, *B* e *D* são agrupadas individualmente. Para esta tarefa utilizamos os algoritmos *K-means* e *K-means Fuzzy*.

²Imagens disponíveis em <http://www.parl.clemson.edu/stare/nerve/stare-images.tar>

2.3.1 SOM

Os mapas auto-organizáveis (self-organizing map) são sistemas que se baseiam na aprendizagem competitiva. Dessa forma, os neurônios de saída da rede competem entre si para serem ativados. Como resultado, apenas um neurônio de saída, ou um neurônio por grupo, está ativo em um instante de tempo. O neurônio que vence a competição é chamado de neurônio vencedor [20].

Em mapas auto-organizáveis os neurônios estão dispostos em uma grade que pode ter qualquer dimensão, porém, as grades mais utilizadas são uni- ou bidimensionais. Uma das principais características desses mapas é que eles formam um mapa topográfico dos padrões de entrada no qual as localizações espaciais dos neurônios na grade são indicativos das características estatísticas intrínsecas contidas nos padrões de entrada [21]. O funcionamento do método pode ser visualizado no algoritmo 1.

A utilização de mapas auto-organizáveis é estimulada por uma característica biológica: o cérebro humano possui várias áreas para tratamento de diferentes estímulos sensoriais. Essas áreas estão organizadas na forma de mapas computacionais ordenados topologicamente. Dessa maneira, estímulos visuais e acústicos, por exemplo, são tratados em áreas diferentes do córtex cerebral [20].

Algoritmo 1 Algoritmo de aglomeração SOM.

- 1 Inicialização: Atribua valores aleatórios aos vetores de peso iniciais w_j .
- 2 Amostragem: Escolha uma amostra x do espaço de entrada e aplique este padrão à rede.
- 3 Casamento por Similaridade: Encontre o neurônio vencedor utilizando a Eq. (6.1).

$$i(x) = \operatorname{argmin} \|x - w_j\|, j = 1, 2, \dots, l$$

onde l é o número de neurônios.

- 4 Atualização: Ajuste os vetores de pesos sinápticos de todos os neurônios usando a equação:

$$w_j(n+1) = w_j + \eta(n)h_{j,i(x)}(n)(x - w_j(n))$$

onde η é o parâmetro de taxa de aprendizagem e $h_{j,i}$ a vizinhança topológica com centro no neurônio i excitando o neurônio j ;

- 5 Continuação: Retorne ao passo 2 até que não sejam observadas mudanças significativas nos vetores de pesos sinápticos.
-

2.3.2 K-means

O algoritmo *K-means* é largamente aceito como uma técnica “padrão” de detecção automática de classes pela análise de dados. Trata-se de um método baseado em heurística, que possui um grande poder de modelagem. O princípio de aglomeração consiste na determinação do modelo da distribuição dos exemplos no espaço atribuído. O *K-means* atinge esses objetivos de forma rápida e eficiente, utilizando um número fixo de classes iniciais, determinadas pelo usuário. Assim como todos os métodos particionais, o algoritmo *K-means* produz uma partição dos n objetos em K agrupamentos, geralmente otimizando uma função objetivo. Essa função objetivo geralmente é representada pelo somatório das distâncias entre os dados e o centro que o classifica, o que corresponde ao erro total absoluto. Existem algumas vantagens, como a possibilidade de mudanças de pertinência de objetos em relação a um agrupamento durante todo o processo de formação dos agrupamentos, e possibilidade de trabalhar com grandes bases de dados. Esse método requer tempo de ordem $O(n)$, onde n é o número de objetos no conjunto de dados [22].

O referido algoritmo é sensível à escolha das classes iniciais. O fato do número de classes ter que ser fixa e conhecida *a priori*, e de soluções diferentes poderem ser geradas dependendo do número K de classes escolhidas, constituem algumas desvantagens do *K-means*. Cada classe é representada por um ponto (centro) e, inicialmente, é formada somente por este. A escolha inicial correta do número de classes é um dos problemas mais fundamentais e ainda não solucionados. O problema de se escolher K de forma errada é que o método irá impor uma estrutura aos dados ao invés de buscar uma inerente a estes. A escolha dos centros deve ser feita dentro da base de dados, pelo usuário ou de forma aleatória.

Após escolhidos os centros, cada dado é assinalado como pertencente à classe cujo centro está mais próximo. Após todos os dados serem processados, a posição média de cada classe é então calculada e usada como o novo centro, e os dados processados novamente. Esse processo é repetido até que não mais ocorram mudanças nos centros encontrados ou um número limite de iterações definido pelo usuário seja atingido. O algoritmo 2 mostra melhor o funcionamento do *K-means*.

2.3.3 K-means Fuzzy

Como foi dito, o algoritmo *K-means* é um algoritmo de aprendizagem competitiva onde o vencedor é o único a ser atualizado a cada iteração. Este tipo de aprendizagem competitiva é denominada de competição dura (*hard competition*). Em outros algoritmos, como a rede SOM, não só o neurônio vencedor tem seu protótipo atualizado, mas também os protótipos de seus vizinhos sofrem modificações. Este tipo de aprendizagem competitiva é denominada de competição suave (*soft competition*). Entretanto, independente do tipo de competição, um vetor de atributos só pode pertencer a um único grupo, que é aquele representado pelo protótipo mais próximo.

Algoritmo 2 Algoritmo de aglomeração *K-means*.

- 1 Inicialize os K centros (w_1, \dots, w_k) , que representam as classes
- 2 Cada classe C_j é associada a um centro w_j
- 3 Para cada dado de entrada x , assinale-o como pertencente à classe C_j , caso w_j seja o centro mais próximo a este dado
- 4 Para cada classe C_j , atualize os centros w_j através da média de todas as amostras de dados assinaladas como pertencentes a cada classe C_j
- 5 Calcular a função de erro E :

$$E = \sum_{j=1}^k \sum_{x \in C_j} \|x - w_j\|^2$$

6. Repetir passos 3, 4 e 5 até que o erro E não mude significativamente

Já no caso das técnicas de agrupamentos nebulosos (*fuzzy clustering*), os dados podem possuir características que permitam que eles pertençam a diversos grupos com uma intensidade controlada por uma função de pertinência [23].

Dessa forma, a principal diferença do *K-means Fuzzy* para a sua versão clássica está no cálculo do erro, que é dado pela equação 1.

$$E = \sum_{j=1}^k \sum_{x \in C_j} u_j^z \|x - w_j\|^2 \quad (1)$$

Onde u_j é uma função que determina o grau de pertinência de um vetor x ao agrupamento representado pelo protótipo w_j e z representa o grau de nebulosidade da função.

3. CLASSIFICADORES

O objetivo de um classificador é dividir o espaço de atributos em regiões de decisão. Dessa forma, os vetores de atributos que estiverem contidos na mesma região de decisão compartilham a mesma classe. No nosso caso, a entrada do classificador é o vetor de atributos que representa uma imagem e a saída é a informação se esta imagem é saudável ou doente. Neste trabalho foram testados três classificadores que são apresentados a seguir.

3.1 Vizinho mais Próximo

O algoritmo de classificação baseado no vizinho mais próximo (Nearest Neighbor - NN) é uma técnica amplamente empregada para reconhecer padrões. O centro de seu funcionamento está em descobrir o vizinho mais próximo de uma dada instância. O NN é considerado um dos mais simples algoritmos de aprendizagem de máquina. Ele funciona bem quando a distância entre as médias é grande quando comparada com a dispersão de cada classe em relação a sua média. Um resumo do funcionamento do classificador é mostrado no algoritmo 3

Algoritmo 3 Algoritmo Vizinho Mais Próximo (*Nearest Neighbor, NN*).

- 1 Armazenar os exemplos em uma tabela.
- 2 Seja x_{novo} um vetor cuja classe é desconhecida, ou seja:

$$Classe(x_{novo}) = ?$$

- 3 Procurar na tabela o vetor armazenado mais próximo de x_{novo} .
- 4 Chamar de x_{prox} o vetor armazenado mais próximo de x_{novo} .
- 5 Atribuir a x_{novo} a mesma classe de x_{prox} , ou seja:

$$Classe(x_{novo}) = Classe(x_{prox})$$

- 6 Se a classificação for correta incluir x_{novo} na tabela.

3.2 Distância Mínima aos Centróides (DMC)

O algoritmo Distância Mínima aos Centróides funciona de forma similar ao do Vizinho Mais Próximo. Porém, agora, cada classe passa a ter um único vetor que a representa, chamado de centróide. Dessa forma, não há necessidade de armazenar todos os exemplos de uma classe o que nos leva a uma economia de memória. O centróide de uma classe é o seu vetor médio; ou seja, a média dos exemplos daquela classe. Assim, pode-se dizer que o centróide de uma classe é um modelo que representa aquela classe. Um resumo do funcionamento do classificador é mostrado no algoritmo 4

Algoritmo 4 Algoritmo Distância Mínima aos Centróides (DMC).

- 1 Armazenar apenas os centróides das classes em uma tabela.
- 2 Seja x_{novo} um vetor cuja classe é desconhecida, ou seja:

$$Classe(x_{novo}) = ?$$

- 3 Procurar na tabela o centróide mais próximo de x_{novo} .
- 4 Chamar de C_j o centróide mais próximo de x_{novo} .
- 5 Atribuir a x_{novo} a mesma classe de centróide mais próximo, ou seja:

$$Classe(x_{novo}) = Classe(C_j)$$

- 6 Se a classificação for correta, usar x_{novo} para recalculer C_j .

3.3 Rede Neural Artificial

Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é paralelo e, por vezes, distribuído. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso, denominado peso sináptico. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma rede neural artificial advém das interações entre as unidades de processamento da rede. O modelo de um neurônio artificial pode ser visto na Figura 3.3.

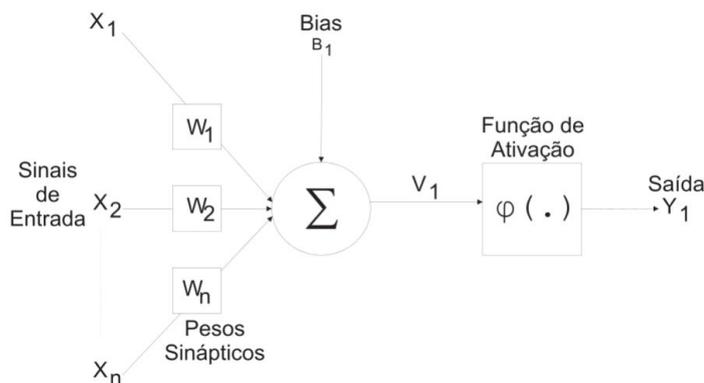


Figura 2: Modelo de Neurônio Artificial baseado em Haykin (2001)

O comportamento das conexões entre os neurônios é simulado por meio de seus pesos sinápticos. Os valores de tais pesos podem ser negativos ou positivos, dependendo das conexões serem inibitórias ou excitatórias. O efeito de um sinal proveniente de um outro neurônio é determinado pela multiplicação do valor (intensidade) do sinal recebido pelo peso da conexão correspondente ($x_i \cdot p_i$). É efetuada a soma dos valores $x_i \cdot p_i$ de todas as conexões, e o valor resultante é enviado para a função de ativação, que define a saída (y) do neurônio. Combinando diversos neurônios, forma-se uma rede neural artificial. De uma forma simplificada, uma rede neural artificial pode ser vista como um grafo onde os nós são os neurônios e as ligações fazem a função das sinapses.

A rede neural artificial é um sistema de neurônios ligados por conexões sinápticas e dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou hidden (ocultos) e neurônios de saída, que se comunicam com o exterior. A forma de arranjar perceptrons em camadas é denominado Multilayer Perceptron (MLP). O MLP foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Para isto são necessárias mais conexões, os quais só existem em uma rede de perceptrons dispostos em camadas. Na Camada escondida, camada oculta ou camada intermediária, como também é conhecida os neurônios são denominados escondidos porque eles não tem acesso direto a saída da rede MLP, onde os erros de aproximação são calculados.

4. RESULTADOS

O conjunto de treinamento foi composto por 60% dos dados. Os outros 40% foram utilizados para os testes. Cada classificador foi executado 100 vezes e os resultados apresentados correspondem à melhor execução do algoritmo. A divisão dos dados pra teste e treinamento foi feita aleatoriamente a cada execução.

Para avaliar o desempenho dos classificadores utilizamos as seguintes taxas: sensibilidade, especificidade, verdadeiro preditivo negativo (VPP), verdadeiro preditivo positivo (VPP) 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 erradamente classificadas como saudáveis; falso negativo (FN), número de imagens erradamente classificadas como patológicas e verdadeiro negativo (VN), número de imagens classificadas corretamente como patológicas. Esses valores estão definidos na tabela 1.

Tabela 1: Tabela de Avaliação

Predição	Saída desejada	
	Positivo (saudável)	Negativo (patológica)
Positivo (saudável)	VP	FP
Negativo (patológica)	FN	VN

À partir dessas quantidades os valores de sensibilidade, especificidade, VPP, VPN e acurácia são calculados usando as equações 2, 3, 4, 5, 6.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (2)$$

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (3)$$

$$\text{VPP} = \frac{VP}{VP + FP} \quad (4)$$

$$\text{VPN} = \frac{VN}{VN + FN} \quad (5)$$

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + FN + VN} \quad (6)$$

A sensibilidade representa a proporção de verdadeiros positivos, ou seja, avalia a capacidade do classificador prever uma imagem como saudável dado que realmente ela é. A especificidade reflete a proporção de verdadeiros negativos, isto é, avalia a capacidade do classificador prever uma imagem como não saudável (patológica) dado que ela realmente não é. A taxa de VPP representa a proporção de verdadeiros positivos em relação a todas as predições positivas, isto é, a imagem ser saudável dado que o classificador classificou o indivíduo como saudável. Já a taxa de VPN é a proporção de verdadeiros negativos em relação a todas as predições negativas, ou seja, a imagem não ser saudável dado que o classificador a classificou como não saudável. Por fim, a acurácia é a proporção de predições corretas, sem considerar o que é positivo e o que negativo e sim o acerto total.

Os resultados são apresentados nas tabelas 2, 3, 4. A primeira coluna das tabelas lista as diferentes entradas submetidas ao classificador. Os valores de sensibilidade, especificidade, VPP, VPN e acurácia foram descritos em porcentagem.

Tabela 2: Avaliação do Classificador NN

Atributos	VP	FP	FN	VN	Sensibilidade	Especificidade	VPP	VPN	Acurácia
Kmeans RGB	9	5	5	10	64.29	79.17	64.29	79.17	73.68
Kmeans RGB + D	10	4	4	20	71.43	83.3	71.43	83.33	78.94
Kmeans RGB + H	10	5	5	18	66.67	78.26	66.67	78.26	73.68
Kmeans Fuzzy RGB	12	4	3	19	80.00	82.61	75.00	82.61	81.57
Kmeans Fuzzy RGB + D	8	0	7	23	53.33	100	100	100	81.57
Kmeans Fuzzy RGB + H	10	2	7	19	58.82	90.48	83.33	90.48	76.31

Tabela 3: Avaliação do Classificador DMC

Atributos	VP	FP	FN	VN	Sensibilidade	Especificidade	VPP	VPN	Acurácia
Kmeans RGB	10	2	4	22	71.43	91.67	83.33	91.67	84.21
Kmeans RGB + D	9	3	6	20	60.00	86.96	75.00	86.96	76.31
Kmeans RGB + H	7	4	6	21	53.85	84.00	63.64	84.00	73.68
Kmeans Fuzzy RGB	11	7	3	17	78.57	70.83	61.11	70.83	73.68
Kmeans Fuzzy RGB + D	4	4	5	25	44.44	86.21	50.00	86.21	76.31
Kmeans Fuzzy RGB + H	6	4	5	23	54.55	85.19	60.00	85.19	76.31

Tabela 4: Avaliação do Classificador MLP

Atributos	VP	FP	FN	VN	Sensibilidade	Especificidade	VPP	VPN	Acurácia
Kmeans RGB	12	5	3	18	80.00	78.26	70.59	78.26	78.94
Kmeans RGB + D	3	8	0	27	100	77.14	27.27	77.14	78.94
Kmeans RGB + H	0	8	0	30	-	78.95	0	78.95	78.94
Kmeans Fuzzy RGB	3	8	1	26	75.00	76.47	27.27	76.47	76.31
Kmeans Fuzzy RGB + D	4	6	3	25	57.14	80.65	40.00	80.65	76.31
Kmeans Fuzzy RGB + H	0	9	0	29	-	76.32	0	76.31	76.31

5. CONCLUSÃO E TRABALHOS FUTUROS

Este artigo apresentou uma proposta de identificação de imagens de retina patológicas. Para isso utilizamos, apenas, algoritmos clássicos de aprendizado de máquina e as informações de cor da imagem. O método é simples e livre pré-processamento da imagem. Além disso, a transformação de uma imagem em um vetor de atributos com tamanho variando entre 15 e 20, faz com que a fase de classificação seja computacionalmente mais rápida.

Algumas considerações podem ser feitas à partir dos resultados dos testes: Entre os três classificadores utilizados, notadamente, o mais poderoso é a MLP. Porém, nos testes ela obteve, quase sempre, os piores resultados. Concluímos que há a necessidade de mais imagens tanto para o conjunto de teste como para o conjunto de treinamento. Quando a rede foi treinada com 80% dos dados obteve-se uma taxa de acerto de 88,23%. Isso mostra que os exemplos de treinamento foram insuficientes para que a rede pudesse ter um grande poder de generalização. Além disso, as linhas 3 e 6 da tabela 4 demonstram que a rede não conseguiu aprender o que é uma imagem saudável para o conjunto de entrada formado pelas características *RGB + H*. Dessa forma, os atributos relacionados ao histogramas pioraram o desempenho da MLP.

A melhor taxa de acerto (acurácia) foi obtida pelo classificador DMC tendo como atributos de entrada somente os valores de RGB (linha 1 da tabela 3). Como o nosso objetivo é identificar retinas com patologias, as principais métricas que devemos levar em consideração são as medidas de especificidade e VPN. Dessa forma, apesar de as taxas de acurácia, em sua maioria, não terem ultrapassado 80% de acerto podemos afirmar que a nossa proposta é válida. Isso é justificado pois, foram obtidas taxas de especificidade e VPN maiores que 90%, chegando até 100% em um dos casos de teste.

Pretendemos, agora, investigar a utilização padrões de cores diferentes do RGB, como o HSI (*Hue, Saturation, Intensity*), para esta tarefa. Bem como diferentes formas de fusão de bandas, visto que o vetor de atributos formado pelos valores de RGB com a adição da distância métrica das componentes *R* e *G* [18] apresentou melhores taxas de acerto em 2 dos três classificadores.

REFERÊNCIAS

- [1] K. Doi. "Computer-aided diagnosis in medical imaging: Historical review, current status and future potential". *Computerized Medical Imaging and Graphics*, , no. 31, pp. 198–211, 2007.
- [2] C. Muramatsu, Y. Hayashi, A. Sawada, Y. Hatanaka, T. Hara, T. Y. M.D. and H. Fujita. "Detection of retinal nerve fiber layer defects on retinal fundus images for early diagnosis of glaucoma". *Journal of Biomedical Optics*, vol. 15, no. 1, pp. 16–21, 2010.
- [3] J. Liu, T. Y. Wong, D. W. K. Wong, J. H. Lim, H. Li and N. M. Tan. "ARGALI: an automatic cup-to-disc ratio measurement system for glaucoma detection and AnaLysIs framework". In *SPIE Medical Imaging*, volume 7260, Flórida - EUA, Fevereiro 2009.
- [4] M. C. Luculescu and S. Lache. "Computer-aided diagnosis system for retinal diseases in medical imaging". *WTOS*, vol. 7, pp. 264–276, March 2008.
- [5] C. Martins, R.M.S.Veras, G.L.B.Ramalho, F.N.S.Medeiros and D. M. Ushizima. "Automatic Microaneurysm Detection and Characterization Through Digital Color Fundus Images". In *II Workshop on Computational Intelligence (WCI'2008) - SBRN*, pp. 45–50, Salvador - BA - Brasil, Outubro 2008.
- [6] D. Roberto and D. G. Andrea. "Model based retinal analysis for retinopathy detection". In *Engineering in Medicine and Biology Society, 2007. 29th Annual International Conference of the IEEE*, pp. 6731–6734, Lion, França, Agosto 2007.
- [7] R. Winder, P. Morrow, I. McRitchie, J. Bailie and P. Hartd. "Algorithms for digital image processing in diabetic retinopathy". *Computerized Medical Imaging and Graphics*, , no. 33, pp. 608–622, 2009.
- [8] J.Anitha, C. S. Vijila and D. Hemanth. "An Overview of Computacioanal Intelligende Techniques for Retinal Disease Identification Aplications". *International Journal of Reviews in Computing*, vol. 5, pp. 29–46, 2009.
- [9] F. t. Haar. "Automatic localization of the optic disc in digital colour images of the human retina". Master's thesis, Universidade de Utrecht, Utrecht, Dezembro 2005.

- [10] S. Barrett, E. Naess and T. Molvik. “Employing the Hough transform to locate the optic disk”. *Biomedical Sciences Instrumentation*, vol. 37, pp. 81–86, 2001.
- [11] M. Foracchia, E. Grisan and A. Ruggeri. “Detection of the optic disc in retinal images by means of a geometrical model of vessel structure”. *IEEE Transactions on Medical Imaging*, vol. 23, no. 10, pp. 1189–1195, Outubro 2004.
- [12] M. Lalonde, M. Beaulieu and L. Gagnon. “Fast and robust optic disc detection using pyramidal decomposition and Hausdorff-based template matching”. *IEEE Transactions on Medical Imaging*, vol. 20, no. 11, pp. 1193–1200, Novembro 2001.
- [13] C. Sinthanayothin, J. Boyce, H. Cook and T. Williamson. “Automated localisation of the optic disk, fovea, and retinal blood vessels from digital colour fundus images”. *British Journal of Ophthalmology*, vol. 83, no. 8, pp. 902–910, Agosto 1999.
- [14] A. Osareh. “Automated identification of diabetic retinal exudates and the optic disc”. Ph.D. thesis, Departamento de Ciência da Computação, Faculdade de Engenharia, Universidade de Bristol, Janeiro 2004.
- [15] A. Osareh, M. Mirmehd, B. Thomas and R. Markham. “Comparison of colour spaces for optic disc localisation in retinal images”. In *ICPR '02: Proceedings of the 16 th International Conference on Pattern Recognition*, volume 1, pp. 743–746, Washington, DC, EUA, Agosto 2002. IEEE Computer Society.
- [16] T. Walter and J. Klein. “Segmentation of Color Fundus Images of the Human Retina: Detection of the Optic Disc and the Vascular Tree Using Morphological Techniques”. *Lecture Notes in Computer Science*, vol. 2199, pp. 282–287, Janeiro 2001.
- [17] J. Anitha, C. K. S. Vijila, D. J. Hemanth and A. Ahsina. “Self Organizing Neural Network based Pathology Classification in Retinal Images”. In *NaBIC*, pp. 1457–1462, 2009.
- [18] R. A. A. Guerra. “Identificação automática do disco ótico em imagens coloridas da retina”. Master’s thesis, Faculdade de Engenharia da Universidade do Porto, Porto, Abril 2008.
- [19] S. Lu, J. Liu, J. H. Lim, Z. Zhang, T. N. Meng, W. K. Wong, H. Li and T. Y. Wong. “Automatic Fundus Image Classification for Computer-Aided Diagnosis”. In *31st Annual International Conference of the IEEE EMBS*, pp. 1453–1456, Minneapolis, Setembro 2009.
- [20] S. Haykin. *Redes Neurais: Princípios e Práticas*. Bookman, Porto Alegre, 2001.
- [21] T. Kohonen. *Self-Organizing Maps*. Springer-Verlag, Nova York, 1997.
- [22] J. A. F. Costa. “Classificação Automática e Análise de Dados por Redes Neurais Auto-Organizáveis”. Tese de doutorado, Universidade de Campinas - UNICAMP, 1999.
- [23] X. Y. Wang, J. Garibaldi and T. Ozen. “Application of The Fuzzy C-Means Clustering Method on the Analysis of non Pre-processed FTIR Data for Cancer Diagnosis”. In *in the Proceedings of the 8th Australian and New Zealand Conference on Intelligent Information Systems*, pp. 233–238, 2003.