

Avaliação de Técnicas de Transformação de Intensidade na Detecção Automática de Retinopatia Diabética em Imagens

Pablo Vieira¹, Romuere Silva^{1,2}, Thiago Lima¹, Nonato Carvalho¹,
Mateus Garcia², Francisco Carvalho Júnior.²

¹ Programa de Pós-Graduação em Engenharia Elétrica (UFPI) Picos/Teresina, Brasil.

² Sistemas de Informação (UFPI) Picos, Brasil.

pablolulkan@gmail.com, romuere@ufpi.edu.br

Abstract. *Diabetic retinopathy (DR) is a complication of diabetes. Patients with high glucose levels tend to deal with retinopathy. DR is one of the leading causes of blindness in working age. When detected in the early stages, some treatments may delay and reduce the risk of visual loss. Ophthalmologists diagnose DR by evaluating retinoscopic images in a costly process. This paper analyzes and evaluates the impact of intensity transformation techniques (contrast widening, logarithms and enhancement) in highlighting characteristics that distinguish retinoscopic images with DR. Contrast widening was promising, obtaining a gain of 11% accuracy and 25% kappa in relation to images without transformation.*

Resumo. *Retinopatia diabética (RD) é uma complicação do diabetes. Pacientes com níveis altos de glicose tendem a lidar com a retinopatia. RD é uma das principais causas de cegueira na idade ativa. Quando é detectada nos estágios iniciais, alguns tratamentos podem retardar e reduzir o risco da perda visual. Oftalmologistas diagnosticam RD avaliando imagens retinoscópicas num processo oneroso. Este trabalho analisa e avalia o impacto de técnicas de transformações de intensidades (alargamento de contraste, logaritmos e potenciação) em evidenciar características que distinguem imagens retinoscópicas com RD, o alargamento de contraste mostrou-se promissor obtendo ganho de 11% de acurácia e 25% de kappa em relação as imagens sem transformação.*

1. Introdução

A RD é uma complicação do diabetes que afeta os olhos. Níveis altos de açúcar no sangue podem causar estreitamento ou bloqueio nas artérias da retina, desencadeando a angiogênese, que permite o crescimento de novos vasos sanguíneos. Essas mudanças afetam a visão podendo causar cegueira [Gudla et al. 2018]. A RD é uma das principais causas de cegueira na população com idade ativa. Se a RD for detectada em estágios iniciais, o estreitamento dos fatores de risco modificáveis pode retardar a progressão [Peter 2019].

Oftalmologistas geralmente diagnosticam a presença e a gravidade da RD por avaliação de imagens retinoscópicas. Cerca de 75% dos pacientes vivem em áreas subdesenvolvidas, com especialistas e infraestrutura insuficientes [Gargeya and Leng 2017]. A importância de programas de triagem de RD e a dificuldade de obter um diagnóstico precoce e confiável, faz surgir a necessidade da criação de ferramentas de auxílio a diagnósticos automatizados. Este auxílio pode facilitar o diagnóstico em massa da RD.

Avanços tecnológicos como poder computacional, internet e aprendizado de máquina possibilitam cientistas atender os requisitos básicos da prática clínica [Porwal et al. 2018].

A detecção automática da RD em imagens se dá, geralmente, em 5 etapas: 1) Aquisição das imagens; 2) Pré-processamento; 3) Segmentação de regiões de interesse (disco óptico, exsudatos, hemorragias e microaneurismas); 4) Extração de atributos; e 5) Classificação. O pré-processamento é muito importante na análise de imagens médicas, o objetivo é obter a melhor representação possível da imagem, evidenciando regiões ou formas importantes. As principais técnicas de pré-processamento em imagens são as transformações de intensidade, onde os pixels são mapeados de acordo com alguma função.

Este trabalho analisa e avalia as técnicas de transformação de intensidade: alargamento de contraste, logaritmos e potenciação, na classificação automática de imagens com RD. A avaliação dessas técnicas se deu com a extração das características com os descritores *Gray-Level Co-Occurrence Matrix* (GLCM) e *Local Binary Pattern* (LBP) para a classificação com *Random Forest* (RF) e *Multilayer Perceptron* (MLP), cada processo se repetiu 10 vezes assim obtendo a média ponderada da acurácia e índice *kappa*.

2. Trabalhos Relacionados

Nessa seção expomos trabalhos que abordam problemas semelhantes ao nosso, podem ser conferidos na Tabela 1.

Tabela 1. Trabalhos Relacionados: Autor e período de publicação; Técnicas aplicadas; Resultados obtidos.

Trabalho	Técnicas usadas	Acurácia	Sensibilidade
[Ege et al.]	<i>Bayesiano, Mahalanobis</i> e KNN	–	69%, 83%, 99% e 80%
[Mansour 2018]	<i>Redes Neurais Convolucionais</i> (CNN)	97,93%	–
[Dutta et al. 2018]	CNN e <i>Fuzzy K-means</i>	82,3%	–
[ur Rehman et al. 2018]	<i>Wavelet</i>	98%, 97%	–

Este trabalho encontrou a melhor transformação de intensidade para a classificação de imagens com RD. Esta metodologia pode melhorar as técnicas existentes na classificação automatizada de imagens com RD, como também as apontadas acima.

3. Materiais e Métodos

Este trabalho analisa o impacto das técnicas de transformação de intensidade em detectar a RD em imagens retinoscópicas. Para entender melhor os processos expomos aqui materiais e métodos aplicados na pesquisa, a Figura 1 ilustra as etapas da metodologia.



Figura 1. Fluxograma ilustrativo das etapas da metodologia.

3.1. Aquisição de Imagens

O *dataset* utilizado neste trabalho foi o *Indian Diabetic Retinopathy Image Dataset* (IDRID)¹. As imagens foram obtidas com a câmera Kowa VX-10, possuindo 4288x2848 pixels. O conjunto consiste de 516 imagens coloridas retinoscópicas com informações da presença ou não de RD. A Figura 2 mostra exemplos de imagens da base [Porwal 2018].




Figura 2. Exemplos de retinas de pacientes da base IDRID. (a) saudável, (b) com RD.

3.2. Transformações de Intensidade

Funções de transformação de intensidade visam obter a melhor representação da imagem trabalhada, sendo calculadas através de funções que recebem o pixel e retornam o pixel transformado. Este trabalho utilizou três funções: Alargamento de Contraste (AC), Transformação de Potenciação Gama (TPG) e Transformação Logarítmicas (TL), escolhidas por serem amplamente utilizadas no estado da arte [Gonzalez and Woods 2010]

O AC é alcançado maximizando o conteúdo da imagem através da função de transformação de intensidade contínua (Equação 1). O AC para imagens em níveis de cinza é considerado um dos processos que facilitam operações como detecção e identificação [Kwok et al. 2008].

$$AC = \frac{1}{(1 + (k/r))^E}, \quad (1)$$

onde r é o pixel, k e E são parâmetros da AC.

A TPG é representada pela Equação 2. Valores $\gamma \leq 1$ mapeiam a faixa estreita de valores escuros. A medida que γ é reduzido, mais detalhes se tornam visíveis, porém ocorre o “desbotamento” da imagem. A medida que o γ é aumentado o contraste melhora, porém áreas escurecem perdem detalhes [Gonzalez and Woods 2010].

$$TPG = cr^\gamma, \quad (2)$$

onde c e γ são parâmetros da TPG

A TL é dada pela Equação 3. A TL tem como objetivo mapear intervalos estreitos de valores de baixa intensidade em intervalos mais altos valores de alta intensidade. Sendo utilizado para expandir valores de pixels mais escuros numa imagem ao mesmo tempo em que comprimi os valores de nível alto [Gonzalez and Woods 2010].

¹<https://idrid.grand-challenge.org/>

$$TL = C \log(1 + r), \quad (3)$$

onde C é um parâmetro da TL.

3.3. Descrição e Classificação

Este trabalho utilizou os descritores: *Gray Level Co-occurrence Matricese* e *Local Binary Patterns*.

Na análise estatística de textura com o GLCM, características são calculadas pela distribuição estatística das combinações observadas de intensidade em posições especificadas em relação umas às outras na imagem [Haralick et al. 1973].

O LBP analisa textura baseado na chamada unidade de textura, uma imagem pode ser caracterizada por seu espectro de textura. Uma unidade de textura pode ser representada por 5×5 pixels, para cada pixel é feita uma comparação com seus 8 vizinhos, no sentido horário ou anti-horário, se o valor do pixel central for maior que o do vizinho retorne 0, contrario 1, o que fornece um número binário para calcular o *histograma* (vetor de característica) [Ojala et al. 1996].

Este trabalho utilizou os classificadores: *Random Forest* e *Multilayer Perceptron*.

O RF consiste numa combinação de árvores onde cada classificador é gerado usando um vetor aleatório independentemente do vetor de entrada. O RF utiliza o índice *Gini* como uma medida de seleção de atributo, medindo a impureza de um atributo em relação a classe [Ho 1995].

Ao contrário de outras técnicas estatísticas, a MLP não faz suposições prévias sobre a distribuição dos dados. Ela pode modelar funções não-lineares e ser treinada para generalizar com precisão quando recebe dados não vistos antes. A MLP consiste num sistema de neurônios interconectados simples [Minsky 1954].

4. Resultados e Discussões

Neste trabalho as métricas avaliativas utilizadas foram: A acurácia que é basicamente o número de acertos (positivos) dividido pelo total de exemplos [Bland 2015]; O Índice *Kappa* que é uma métrica que mede a concordância entre observadores incluindo uma estatística que leva em conta o fato de que os observadores às vezes concordam ou discordam simplesmente por acaso [Cohen 1968]. Todas as classificações foram repetidas 10 vezes para obter a média ponderada aritmética tornando os resultados confiáveis.

As transformações de intensidades utilizadas possuem parâmetros de ajuste, que devem ser cuidadosamente escolhidos para obter bons resultados. A escolha pode ser feita numa busca por parâmetros, na qual esses parâmetros são variados num determinado intervalo para encontrar os que se enquadram melhor ao problema (validação cruzada). Os parâmetros utilizados nas transformações de intensidade foram para AC: $K = 180$ e $E = 10$; TL: $C = 26$; TPG: $C = 1$ e $\gamma = 4$. Estes parâmetros foram escolhidos em testes feitos no intervalo de 1 a 200, onde todos eles sofreram alterações, Os valores foram iniciados em 1 e finalizado em 200, os melhores resultados são ilustrados na Tabela 2.

Na Tabela 2, vemos que AC teve melhor resultado com acurácia 81% e *kappa* 62%. Isso se da por sua capacidade em maximizar informações contidas nas imagens (microaneurismas, exsudatos e hemorragias) e melhorar o contraste facilitando a

classificação [Kwok et al. 2008]. A diferença deste resultado para a melhor colocação de imagens sem processamento foi de 11,1% acurácia e 24,7% *kappa*, assegurando afirmar que a utilização do AC no pré-processamento de imagens na classificação da RD é indispensável. As demais transformações tiveram resultados piores que as imagens sem transformações.

Tabela 2. Resultados obtidos com as transformações de intensidade e sem as transformações, O melhor resultado se encontra destacado de negrito.

TRANSFORMAÇÃO DE INTENSIDADE	DESCRITOR	CLASSIFICADOR	ACURÁCIA	KAPPA
Alargamento de Contraste	LBP	Random Forest	0,811	0,622
Alargamento de Contraste	GLCM	Random Forest	0,719	0,435
Alargamento de Contraste	LBP	MLP	0,708	0,428
Alargamento de Contraste	GLCM	MLP	0,625	0,231
Logarítmicos	GLCM	Random Forest	0,593	0,132
Logarítmicos	LBP	Random Forest	0,588	0,140
Logarítmicos	LBP	MLP	0,683	0,358
Logarítmicos	GLCM	MLP	0,591	0,108
Potênciação	GLCM	Random Forest	0,648	0,266
Potênciação	LBP	Random Forest	0,637	0,234
Potênciação	LBP	MLP	0,625	0,205
Potênciação	GLCM	MLP	0,578	0,104
Nenhuma	LBP	Random Forest	0,700	0,375
Nenhuma	GLCM	Random Forest	0,609	0,179
Nenhuma	LBP	MLP	0,695	0,391
Nenhuma	GLCM	MLP	0,625	0,184

A Figura 3 ilustra o resultado obtido com o AC, notamos que as lesões que caracterizam a RD foram destacadas na Figura 3 (b) (microaneurismas, exsudatos e hemorragias) e as informações desnecessárias quase desaparecem com exceção do disco óptico. A transformação de alargamento de contrastes permitiu que os descritores extraíssem as características que facilitam a classificação da RD obtendo melhor resultado que as imagens sem as demais transformações ou sem nenhuma transformação.




Figura 3. Exemplo do resultado do AC. (a) imagem original, (b) imagem a com AC.

5. Conclusões

Este trabalho apresentou um estudo comparativo das principais técnicas de transformação de intensidade na detecção automática da RD em imagens retinoscópicas. Esta metodologia não objetiva a melhor classificação, e sim descobrir qual a técnica de transformação de intensidade pode trazer maiores ganhos no pré-processamento de imagens com RD. A partir dos resultados conclui-se que, o alargamento de contraste é a técnica de transformação

que melhor resultados traz em relação a imagens sem transformações de intensidade, e seu uso é fundamental no pré-processamento de imagens com RD. Em investigações futuras é interessante aplicar segmentação nas imagens resultantes do AC, pois essas apresentaram boas características para tal. A utilização de Redes Neurais Convolucionais nessas imagens também poderiam trazer melhores resultados à suas classificações.

Referências

- Bland, M. (2015). An introduction to medical statistics.
- Cohen, J. (1968). Weighted kappa: Nominal scale agreement provision for scaled disagreement or partial credit.
- Dutta, S., Manideep, B. C., Basha, S. M., Caytiles, R. D., and Iyengar, N. (2018). Classification of diabetic retinopathy images by using deep learning models. *International Journal of Grid and Distributed Computing*, 11(1):89–106.
- Ege, B. M., Hejlesen, O. K., Larsen, O. V., Møller, K., Jennings, B., Kerr, D., and Cavan, D. A. Screening for diabetic retinopathy using computer based image analysis and statistical classification. *Computer methods and programs in biomedicine*.
- Gargeya, R. and Leng, T. (2017). Automated identification of diabetic retinopathy using deep learning. *Ophthalmology*, 124(7):962–969.
- Gonzalez, R. C. and Woods, R. C. (2010). *Processamento digital de imagens*. Pearson.
- Gudla, S., Tenneti, D., Pande, M., and Tipparaju, S. M. (2018). Diabetic retinopathy: pathogenesis, treatment, and complications. In *Drug delivery for the retina and posterior segment disease*, pages 83–94. Springer.
- Haralick, R. M., Shanmugam, K., et al. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6):610–621.
- Ho, T. K. (1995). Random decision forest.
- Kwok, N. M., Ha, Q. P., Liu, D., and Fang, G. (2008). Contrast enhancement and intensity preservation for gray-level images using multiobjective particle swarm optimization. *IEEE Transactions on Automation Science and Engineering*, 6(1):145–155.
- Mansour, R. F. (2018). Deep-learning-based automatic computer-aided diagnosis system for diabetic retinopathy. *Biomedical engineering letters*, 8(1):41–57.
- Minsky, M. (1954). Theory of neural-analog reinforcement systems and its application to the brain-model problem. (9438).
- Ojala, T., Pietikäinen, M., and Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29:51–59.
- Peter, H. S. (2019). Diabetic retinopathy. Elsevier.
- Porwal, P., Pachade, S., Kamble, R., Kokare, M., Deshmukh, G., Sahasrabuddhe, V., and Meriaudeau, F. (2018). Indian diabetic retinopathy image dataset (idrid): a database for diabetic retinopathy screening research. *Data*, 3(3):25.
- ur Rehman, M., Abbas, Z., Khan, S. H., Ghani, S. H., et al. (2018). Diabetic retinopathy fundus image classification using discrete wavelet transform. In *2018 2nd International Conference on Engineering Innovation (ICEI)*, pages 75–80. IEEE.