

Detecção dos Estágios Iniciais da Retinopatia Diabética Utilizando Redes Neurais Profundas

João Victor G Martins¹, Alessandra M Coelho¹, Matheus F O Baffa²

¹Departamento Acadêmico da Ciência da Computação
Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais
campus Rio Pomba (IF SudesteMG)
Rio Pomba – MG – Brasil

²Departamento de Computação e Matemática
Universidade de São Paulo (USP)
Ribeirão Preto – SP – Brasil

joaovictor.if2018@gmail.com

Abstract. *Diabetic Retinopathy is one of the main complications related to Diabetes Mellitus. It occurs when excess glucose in the blood damages the blood vessels within the retina. The diagnosis of the disease uses fundus eye images collected by detecting abnormal signs, either in the vascular structures or in the retina. The detection in early stages promotes a better prognosis and can prevent blindness in the patient. This paper addresses a Computer Vision methodology in order to detect the early stages of Diabetic Retinopathy. The proposed method, using Deep Neural Networks and the extraction of radiomic-based features, obtained an average accuracy of 91.06% in the experiments.*

Resumo. *A Retinopatia Diabética é uma das principais complicações relacionadas a Diabetes Mellitus. Ocorre quando o excesso de glicose no sangue danifica os vasos sanguíneos da retina. O diagnóstico da doença é feito por meio de imagens do fundo do olho, coletadas por meio da detecção de sinais anormais, tanto nas estruturas vasculares quanto na retina. A detecção em estágios iniciais promove melhor prognóstico, além de prevenir a cegueira do paciente. Assim, este artigo aborda uma metodologia de Visão Computacional para detectar os estágios iniciais da Retinopatia Diabética. O método proposto, utilizando Redes Neurais Profundas e extração de características radiômicas, obteve uma acurácia média de 91,06% nos experimentos.*

1. Introdução

A diabetes é uma doença causada pela produção insuficiente ou pela má absorção de insulina, hormônio que regula a glicose no sangue e garante energia para o organismo. A insulina é um hormônio que tem a função de quebrar as moléculas de glicose (açúcar), transformando-a em energia para manutenção das células do nosso organismo. Quando não administrada corretamente, a diabetes pode lesar diferentes órgãos do corpo humano, como o coração, as artérias, os rins e os olhos. As lesões causadas na retina pelo aumento da glicemia e das taxas de glicose são chamadas de Retinopatia Diabética [Ministério da Saúde 2021].

O exame de fundo de olho é o exame mais importante para o oftalmologista avaliar alterações oculares em pacientes diabéticos [Nentwich and Ulbig 2015]. Nesse exame são avaliadas as estruturas do fundo de olho, dando atenção ao nervo óptico, aos vasos sanguíneos da retina, e à retina propriamente dita, especialmente sua região central, denominada mácula.

A classificação dos estágios da Retinopatia Diabética demanda uma interpretação de diferentes padrões encontrados nos exames de fundo de olho, como a presença de exsudatos duros, exsudatos algodinosos, hemorragias e lesões vasculares [Nentwich and Ulbig 2015]. Entretanto, a visualização dessas anomalias em estágios iniciais é dificultada devido à região anômala ser muito pequena ou pela falta de experiência do oftalmologista. Dessa forma, o uso de tecnologias de Visão Computacional, podem auxiliar na detecção desses sinais, ainda que em pequena escala e quantidades.

Assim, o presente trabalho propõe o desenvolvimento de uma metodologia para classificação automática do estágio inicial da Retinopatia Diabética, utilizando uma Rede Neural Profunda, treinada a partir de características radiômicas extraídas de exames de fundo de olho. A principal contribuição do presente trabalho é o modelo de classificação para estágios iniciais, baseado em aprendizagem profunda e características radiômicas.

2. Materiais e Métodos

2.1. Materiais Utilizados

Neste trabalho foram utilizadas as imagens públicas de exames de fundo de olho, desenvolvidas pela Kaggle e pelo EyePACS, e distribuídas pela *framework* Tensorflow¹. A base de dados é composta por imagens categorizadas em diferentes estágios da Retinopatia Diabética, como saudável, retinopatia diabética leve, moderada, severa e proliferativa. Como o intuito do trabalho foi detectar padrões em imagens em estágios iniciais, foram considerados todos os exames diagnosticados como saudável e com retinopatia diabética leve. Ao todo, foram utilizadas 632 imagens de exames do fundo de olho, sendo elas, 316 de pacientes saudáveis e 316 de pacientes no estágio leve de Retinopatia Diabética.

2.2. Pré-Processamento e Padronização da Base

As imagens de fundo de olho disponíveis na base de dados variam muito em relação ao processo de aquisição. Essa característica da base de dados dificulta o processo de detecção de padrões visuais, utilizando métodos tradicionais de extração de características. Dessa forma, fez-se necessário o uso de um pré-processamento para padronizar e aproximar a base de dados de um padrão ouro de aquisição. Para isso, foram utilizadas duas metodologias de padronização de imagens disponíveis na literatura. A primeira consiste na aplicação do filtro gaussiano para suavização do ruído nas imagens, como proposto em [Rath 2021]. A segunda metodologia utilizada, proposta por [Gama et al. 2020], extrai a camada verde da imagem colorida e aplica equalização adaptativa do histograma. A imagem resultante desse processo foi a imagem padronizada utilizada nas etapas posteriores de análise.

¹Diabetic Retinopathy Detection. Disponível em: <https://www.tensorflow.org/datasets/>

2.3. Extração de Características

Para representar o conteúdo semântico da imagem, utilizou-se múltiplas técnicas de extração de características, baseadas na aplicação radiômica, por exemplo, as estatísticas de primeira ordem, as características de textura, como *Local Binary Patterns* (LBP), Haralick e Threshold Adjacency Statistics (TAS), e as características de forma. A radiômica consiste na extração e análise de grandes quantidades de características extraídas a partir de imagens radiológicas [Kumar et al. 2012]

As características foram extraídas utilizando as *frameworks* PyRadiomics² e Mahotas³. Ao todo, 356 características compuseram o vetor descritor final.

2.4. Metodologia de Classificação

A partir da extração de características, uma base de dados CSV (*Comma-Separated Values*) de vetores descritores foi criada para a busca de padrões visuais nas imagens. Para isso, desenvolveu-se uma Rede Neural Totalmente Conectada (*Fully-Connected Neural Network* – FCNN), baseada na abordagem da aprendizagem profunda, visando a busca por padrões e a criação de um modelo de classificação que permitisse identificar imagens provenientes de pacientes doentes e saudáveis.

A FCNN foi escolhida por ser uma arquitetura de Rede Neural Profunda altamente eficiente para bases de dados numéricas. A Rede Neural proposta foi composta por uma camada de entrada, com 356 neurônios e seis camadas internas com 83 neurônios cada. Nas camadas internas da Rede Neural foram utilizadas a função de ativação ReLU (*Rectifier Linear Unit*), com o algoritmo de otimização Adam. Na última camada, por se tratar de uma classificação binária, utilizou-se a função de ativação *Sigmoid*. Todas as camadas internas foram seguidas por uma operação de *Dropout*, com uma taxa de desligamento de 20%.

3. Experimentos e Resultados

Para avaliar a performance do método, foi seguido o protocolo de experimentação da Validação Cruzada, no método *K-Fold* de tamanho $k = 10$. Isso significa que a base de dados foi dividida em dez grupos e avaliada em dez iterações. Esse protocolo utiliza nove grupos ($k - 1$) para treinamento e um grupo para validação, de forma que, os dados utilizados para validação não foram vistos na fase de treinamento. No final, torna-se possível uma avaliação quantitativa média do modelo.

A avaliação quantitativa foi realizada pelo cálculo da taxa de acerto médio (acurácia), da sensibilidade e a da especificidade. O resultado final dessa avaliação foi realizado, a partir do cálculo da média dessas métricas de eficiência. A Tabela 1 contém os resultados obtidos ao longo dos dez experimentos da validação cruzada. O valor médio obtido de acurácia, sensibilidade e especificidade foram, respectivamente, de 91,06%, 90,17% e 92,03%.

Os resultados obtidos pela avaliação se mostraram equiparáveis e representativos, com taxas de acerto médio altas e uma média de acerto entre as classes balanceada, não sobrepondo e tendenciando o modelo para uma classe específica.

²PyRadiomics. Disponível em: <https://pyradiomics.readthedocs.io/en/latest/>

³Mahotas. Disponível em: <https://mahotas.readthedocs.io/en/latest/>

Tabela 1. Resultados obtidos ao longo dos dez experimentos da validação cruzada.

| K-Fold | Acurácia | Sensibilidade | Especificidade |
|--------|----------|---------------|----------------|
| 1 | 92,15% | 88,88% | 95,83% |
| 2 | 92,15% | 89,65% | 95,45% |
| 3 | 92,15% | 87,50% | 96,29% |
| 4 | 90,19% | 96,42% | 82,60% |
| 5 | 94,00% | 93,10% | 95,23% |
| 6 | 90,00% | 93,10% | 85,71% |
| 7 | 94,00% | 89,47% | 96,77% |
| 8 | 88,00% | 85,18% | 91,30% |
| 9 | 88,00% | 93,75% | 85,29% |
| 10 | 90,00% | 84,61% | 95,83% |
| Média | 91,06% | 90,17% | 92,03% |

4. Conclusão

A Retinopatia Diabética é uma doença que, se não tratada, pode levar o paciente à cegueira. O exame de fundo de olho é utilizado pelo oftalmologista para realizar a detecção de sinais anômalos e diagnosticar a Retinopatia Diabética. Neste trabalho foi proposto o desenvolvimento do método de classificação baseado na detecção de padrões, utilizando características radiômicas e Redes Neurais Profundas. Em trabalhos futuros, espera-se desenvolver um método de auxílio ao diagnóstico da Retinopatia Diabética, ainda que em estágios iniciais.

Referências

- Gama, Í., Coelho, A., and Baffa, M. (2020). Fundus eye images classification for diabetic retinopathy detection using very deep convolutional neural network. In *Anais do XVI Workshop de Visão Computacional*, pages 24–29. SBC.
- Kumar, V., Gu, Y., Basu, S., Berglund, A., Eschrich, S. A., Schabath, M. B., Forster, K., Aerts, H. J., Dekker, A., Fenstermacher, D., et al. (2012). Radiomics: the process and the challenges. *Magnetic resonance imaging*, 30(9):1234–1248.
- Ministério da Saúde (2021). Diabetes (diabetes mellitus). Disponível em: <<https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z-1/d/diabetes-diabetes-mellitus>>. Acesso em: 30 maio 2021.
- Nentwich, M. M. and Ulbig, M. W. (2015). Diabetic retinopathy-ocular complications of diabetes mellitus. *World journal of diabetes*, 6(3):489.
- Rath, S. R. (2021). Diabetic retinopathy 224x224 gaussian filtered. Disponível em: <<https://www.kaggle.com/sovitrath/diabetic-retinopathy-224x224-gaussian-filtered>>. Acesso em: 30 maio 2021.