

CLASSIFICAÇÃO DO GRAU DA RETINOPATIA DIABÉTICA EM IMAGENS DE FUNDO DE OLHO

MARCELO DA SILVA DIAS¹; ALEJANDRO DA SILVA PEREIRA², CARLOS ALEXANDRE SILVA DOS SANTOS³, MARILTON SANCHOTENE DE AGUIAR⁴

¹Universidade Federal de Pelotas – marcelo.sdias@inf.ufpel.edu.br

²Universidade Federal de Pelotas – adspereira@inf.ufpel.edu.br

³Instituto Federal Farroupilha – carlos.santos@iffarroupilha.edu.br

⁴Universidade Federal de Pelotas – marilton@inf.ufpel.edu.br

1. INTRODUÇÃO

O diabetes resulta da produção insuficiente ou má absorção de insulina, hormônio vital para converter glicose em energia (MARTINS; COELHO; BAFFA, 2021). A Retinopatia Diabética (RD) é uma complicação microvascular do diabetes, sendo a principal causa de perda de visão em adultos (OPHTHALMOLOGY, 2017). Embora incurável, a cegueira pode ser evitada com a identificação precoce das lesões através de imagens da retina capturadas por câmeras de fundo de olho (KUMAR; RAMASWAMY KARTHIKEYAN, 2021). O diagnóstico e tratamento precoces são essenciais para reduzir o risco de complicações e perda permanente da visão.

A análise de imagens de fundo é o principal método para o diagnóstico da RD, permitindo a identificação de lesões como microaneurismas, hemorragias, exsudatos duros e exsudatos algodinosos. A classificação do estágio da doença baseia-se na quantidade de lesões retinianas presentes nas imagens de fundo de olho (GULATI et al, 2023). Os estágios da RD podem ser classificados em: Sem RD, Retinopatia Diabética Não Proliferativa (RDNP) - que pode ser dividida em leve, moderada e grave - e Retinopatia Diabética Proliferativa.

O diagnóstico precoce da RD continua sendo um desafio significativo em grande parte do mundo devido a diversos fatores: 1) o exame de fundo de olho é muitas vezes negligenciado, resultando em atrasos no tratamento; 2) a triagem de RD é um processo demorado, o que limita o número de pacientes que podem ser atendidos diariamente; e, 3) o número de oftalmologistas não atende à crescente demanda global, especialmente em regiões em desenvolvimento (LI et al, 2019).

Identificar a RD nos estágios iniciais é fundamental para minimizar os danos causados pela doença. Avanços recentes na área da inteligência artificial e o aumento dos recursos e capacidades computacionais têm possibilitado o desenvolvimento de aplicações de aprendizado profundo voltadas à classificação da RD (TSIKNAKIS et al, 2021). Nos últimos anos, diversos trabalhos têm explorado o uso de redes neurais profundas para análise de imagens médicas.

O diagnóstico manual da RD pelos oftalmologistas é demorado, exige esforço significativo e está sujeito a erros de diagnóstico (ALYOUBI et al, 2021). O uso de modelos computacionais não substitui a necessidade de especialistas, mas complementa o diagnóstico, acelerando o processo de análise de imagens e, consequentemente, ajudando a identificar precocemente possíveis manifestações da doença em pacientes.

Este trabalho tem como objetivo apresentar um modelo para classificação do estágio da retinopatia diabética em imagens de fundo de olho, utilizando redes neurais convolucionais e aprendizagem por transferência.

2. METODOLOGIA

Este trabalho utilizou uma metodologia que pode ser dividida nas seguintes etapas: 1) levantamento do referencial teórico; 2) seleção do conjunto de dados; 3) treinamento do modelo; e, 4) análise de resultados.

Inicialmente, foi realizada uma revisão da literatura, em que foram pesquisados artigos que possam dar uma base para o estudo. Os tópicos pesquisados incluem trabalhos associados com a RD, redes neurais convolucionais, aprendizado profundo e técnicas de transformações de dados.

A seguir foi realizada uma pesquisa por conjuntos de dados utilizados em artigos científicos que explorem a classificação dos níveis da RD. O conjunto de dados *Dataset for Diabetic Retinopathy* (DDR) foi selecionado devido ao número de imagens disponíveis. Este *dataset* é composto por 13.673 imagens coloridas do fundo do olho obtidas a partir de exames oculares, obtidas em 147 hospitais da China.

Para o treinamento do modelo foi utilizado o otimizador Adam, combinado com a função de ativação ReLU. Para prevenir o sobre-ajuste do modelo nos dados de treinamento, foi utilizada uma taxa de *Dropout* igual a 40%. Além disso, as imagens foram redimensionadas de acordo com o tamanho de entrada da rede que foi configurado para receber imagens com tamanho de $384 \times 384 \times 3$ no espaço de cores RGB (do inglês, *Red*, *Green*, *Blue*). Ainda, foram aplicadas transformações nos dados de treinamento para aumentar a robustez do modelo, incluindo rotação aleatória de até 20 graus, inversão horizontal aleatória, recorte redimensionado aleatório com escala variando de 0,8 a 1, ajuste de cor (brilho, contraste, saturação e matiz) e normalização das imagens com médias e desvios padrão específicos.

Para a análise dos resultados finais, foram testados modelos encontrados em artigos associados à classificação da RD. Após a realização de experimentos, a rede EfficientNet B4 foi o modelo que alcançou melhor desempenho para as métricas de acurácia (Acc), acurácia global (OA), acurácia média (AA), sensibilidade (Sen), F1-score e coeficiente *kappa* de Cohen (Kappa).

3. RESULTADOS E DISCUSSÃO

O trabalho proposto foi comparado com diversos modelos comumente utilizados para a categorização de imagens a partir de rótulos. Nos experimentos, foram avaliados os seguintes modelos: 1) EfficientNet B0, B1, B2, B3 e B4 (TAN; LE, 2019); 2) EfficientNetV2 (TAN; LE, 2021); 3) RegNet (RADOSAVOVIC et al, 2020); e, 4) VGG-19 (SIMONYAN; ZISSERMAN, 2014). Além disso, os resultados foram comparados com os modelos treinados por LI et al (2019): 1) VGG-16; 2) ResNet-18; 3) GoogLeNet; 4) DenseNet-121; e, 5) SE-BN-Inception.

Na Tabela 1 são apresentados os resultados obtidos na classificação para as classes 'sem RD', 'RDNP leve', 'RDNP moderada', 'RDNP grave', 'RDP' e 'não classificável' através das métricas OA, AA, Sen, F1-score e Kappa no conjunto de teste do *dataset* DDR.

Os valores destacados em negrito representam os melhores resultados obtidos em cada uma das métricas. Ao analisar a tabela, percebe-se que o trabalho proposto conseguiu atingir melhores resultados que os demais modelos, alcançando OA de 0,7681, AA de 0,7029, Sen de 0,6313, F1-score de 0,7700 e

Kappa de 0,7400. A maior dificuldade encontrada pelo modelo está na classificação das classes 'sem RD' e 'RDNP leve', como pode ser observado na Tabela 2. Esse resultado é esperado devido ao número de amostras para essas classes ser significativamente menor.

Tabela 1. Resultados obtidos na classificação através das métricas OA, AA, Sen, F1-score e Kappa no conjunto de teste do *dataset* DDR.

Modelo	OA	AA	Sen	F1-score	Kappa
VGG-16	0,7520	0,5898	-	-	0,6297
ResNet-18	0,7659	0,5827	-	-	0,6500
GoogLeNet	0,7498	0,5654	-	-	0,5654
DenseNet-121	0,7357	0,6119	-	-	0,6053
SE-BN-Inception	0,7639	0,5418	-	-	0,6472
EfficientNet B0	0,7133	0,5697	0,5579	0,7100	0,7000
EfficientNet B1	0,7247	0,5979	0,5641	0,5400	0,5500
EfficientNet B2	0,6943	0,6205	0,5119	0,6900	0,6600
EfficientNet B3	0,7040	0,6421	0,5268	0,7000	0,6600
EfficientNetV2 S	0,7206	0,6223	0,5580	0,7200	0,6900
RegNet Y 32GF	0,7523	0,6320	0,6104	0,7500	0,7300
VGG19 BN	0,6702	0,4687	0,4651	0,6700	0,6200
Trabalho Proposto	0,7681	0,7029	0,6313	0,7700	0,7400

Tabela 2. Resultados de Acc obtidos na classificação para as classes 'sem RD', 'RDNP leve', 'RDNP moderada', 'RDNP grave', 'RDP' e 'não classificável'.

Modelo	Sem RD	RDNP leve	RDNP moderada	RDNP grave	RDP	Não classificável
VGG-16	0,9537	0,0423	0,5625	0,3944	0,6436	0,9422
ResNet-18	0,9548	0,0582	0,6220	0,3662	0,5818	0,9133
GoogLeNet	0,9574	0,0265	0,5759	0,3380	0,5782	0,9162
DenseNet-121	0,8930	0,2275	0,5751	0,4085	0,6364	0,9306
SE-BN-Inception	0,9452	0,0476	0,6458	0,1268	0,5818	0,9046
EfficientNet B0	0,7500	0,0600	0,6900	0,2900	0,7700	0,8600
EfficientNet B1	0,7100	0,1200	0,7600	0,4000	0,7900	0,8000
EfficientNet B2	0,6800	0,2100	0,7200	0,3900	0,8700	0,8600
EfficientNet B3	0,6700	0,2100	0,7700	0,6200	0,6900	0,8900
EfficientNetV2 S	0,7000	0,2900	0,7600	0,3400	0,8300	0,8200
RegNet Y 32GF	0,7500	0,0900	0,7600	0,5600	0,8400	0,7900
VGG19 BN	0,6700	0,0000	0,6600	0,1900	0,5200	0,7800
Trabalho Proposto	0,7500	0,1100	0,7700	0,8600	0,8900	0,8400

4. CONCLUSÕES

Este trabalho apresentou resultados de uma abordagem utilizando redes neurais convolucionais do tipo EfficientNet B4 para realizar a classificação do grau da RD em imagens de fundo de olho. Foram aplicadas técnicas de transformação de dados e aprendizado por transferência para melhorar a precisão do modelo. O trabalho proposto alcançou um OA de 76,81%, AA de 70,29%, Sen de 63,13%, F1-score igual a 77,00% e Kappa de 74,00% no conjunto de testes.

Os resultados mostram que redes neurais convolucionais possuem potencial para a classificação dos graus da RD em imagens de fundo de olho. Entretanto, mesmo atingindo resultados promissores, ainda é necessário melhorar a precisão do modelo, principalmente na classificação de ‘RDNP leve’, que se mostrou ser o nível de RD mais difícil de se detectar.

Para melhorar a detecção e obter melhores resultados, espera-se explorar novas arquiteturas, explorar técnicas de balanceamento de classes e adicionar etapas de pré-processamento para aprimorar a extração de características das imagens de fundo durante o processo de treinamento da rede.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ALYOUBI, W. L., ABULKHAIR, M. F., and SHALASH, W. M. (2021). Diabetic retinopathy fundus image classification and lesions localization system using deep learning. *Sensors*, 21(11).
- GULATI, S., GULERIA, K., and GOYAL, N. (2023). Classification of diabetic retinopathy using pre-trained deep learning model- densenet 121. In 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT), pages 1–6, Delhi, India. IEEE.
- KUMAR, N. S.; RAMASWAMY KARTHIKEYAN, B. Diabetic Retinopathy Detection using CNN, Transformer and MLP based Architectures. In: INTERNATIONAL SYMPOSIUM ON INTELLIGENT SIGNAL PROCESSING AND COMMUNICATION SYSTEMS (ISPACS), 2021., 2021, Hualien, Taiwan. Proceedings... IEEE, 2021. p.1–2.
- LI, T. et al. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening. *Information Sciences*, Beijing, China, v.501, p.511–522, 2019
- MARTINS, J., COELHO, A., BAFFA, M. Detecção dos Estágios Iniciais da Retinopatia Diabética Utilizando Redes Neurais Profundas. In: VIII ESCOLA REGIONAL DE COMPUTAÇÃO APLICADA À SAÚDE, 2021, Porto Alegre, RS, Brasil. Anais... SBC, 2021. p.42–45
- OPHTHALMOLOGY, I. C. of. Updated 2017 ICO Guidelines for Diabetic Eye Care. ICO Guidelines for Diabetic Eye Care, Brussels, Belgium, p.1–33, 2017.
- RADOSAVOVIC, I., KOSARAJU, R. P., GIRSHICK, R. B., HE, K., and DOLLAR, P. (2020). Designing network design spaces. *CoRR*, abs/2003.13678
- SIMONYAN, K. and ZISSERMAN, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*
- TAN, M. and LE, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, pages 6105–6114. PMLR.
- TAN, M. and LE, Q. (2021). Efficientnetv2: Smaller models and faster training. In *International conference on machine learning*, pages 10096–10106. PMLR.
- TSIKNAKIS, N., THEODOROPOULOS, D., MANIKIS, G., KTISTAKIS, E., BOUTSORA, O., BERTO, A., SCARPA, F., SCARPA, A., FOTIADIS, D. I., and MARIAS, K. (2021). Deep learning for diabetic retinopathy detection and classification based on fundus images: A review. *Computers in Biology and Medicine*, 135:104599.