

# Classificação de Imagens de Edema Macular Diabético usando Redes Neurais Convolucionais

Gilberto Luis De Conto Junior<sup>a,b</sup>, Ionildo José Sanches<sup>a</sup>

<sup>a</sup>*Departamento Acadêmico de Informática, Universidade Tecnológica Federal do Paraná, Rua Doutor Washington Subtil Chueire, 330, Ponta Grossa, Paraná, Brasil*

<sup>b</sup>*Autor para correspondência: gilbertoluis@alunos.utfpr.edu.br*

---

*Palavras-chaves:* edema macular diabético, tomografia de coerência óptica, rede neural convolucional

---

Diabetes Mellitus é uma condição médica que pode levar a complicações como a Retinopatia Diabética e o Edema Macular Diabético (DME), problemas que comprometem a visão. Diagnósticos precisos do DME são cruciais e podem ser aprimorados por técnicas modernas, como a Inteligência Artificial. Este estudo visa implementar uma rede neural convolucional (CNN) para auxiliar no diagnóstico de DME em imagens de Tomografia de Coerência Óptica.

O *dataset* utilizado foi obtido de (Kermany, D., Zhang, K., Goldbaum, M., Labeled optical coherence tomography (OCT) and Chest XRay Images for Classification. Mendeley Data, V2, 2018). Para o treinamento, foram selecionadas as 11.348 imagens do conjunto ‘DME’ e 11.348 imagens aleatórias do conjunto ‘Normal’. Para a etapa de teste foram mantidos os dois conjuntos, ‘DME’ e ‘Normal’, como disponibilizados no *dataset*. Foi utilizado o modelo ResNet-50 pré-treinado na base ImageNet. Neste trabalho foi inserida uma camada de *Dropout*, para evitar *overfitting*, uma camada *Flatten*, para transformar o formato da imagem em linear, e uma camada Densa, com ativação sigmoideal, como camada de saída para a classificação binária. Utilizou-se a técnica de transferência de aprendizado para melhorar o desempenho da rede neural, aproveitando *features* aprendidas por uma rede pré-existente. O otimizador utilizado foi o Adam e a taxa de aprendizado foi definida em 0,001.

As métricas de desempenho obtidas do modelo treinado foram uma acurácia de 96,40%, precisão de 96,77%, *recall* de 96,00%, *F-measure* 96,39% e especificidade de 96,80%. Estes resultados foram obtidos através da identificação correta do DME em um conjunto de teste composto por 500 imagens (250 da classe ‘Normal’ e 250 da classe ‘DME’).

A aplicação de CNNs, especificamente o modelo ResNet-50, demonstrou alta precisão na classificação de imagens com DME. Os autores da base de dados obtiveram uma acurácia de 96,6%, *recall* de 97,8% e especificidade de 97,4%. Os resultados parciais obtidos se mostraram promissores, o modelo proposto apresenta um desempenho robusto ainda que haja espaço para melhorias futuras. Trabalhos subsequentes poderão incluir a análise de outros modelos e a aplicação de técnicas de pré-processamento de imagens para potencialmente incrementar a precisão na detecção de DME.