

Proposta de Trabalho de Conclusão de Curso

Título

Diagnóstico automático de retinopatia diabética via imagem de fundo de olho.

Responsáveis

Lucas Medeiros Sobrinho de Sousa

Miqueias Vitor Lima

Orientadora

Nina Sumiko Tomita Hirata

Introdução

A Retinopatia Diabética (RD) é uma das principais causas de cegueira em população em idade de trabalho, porém estratégias de tratamento são efetivas em 90% dos casos para prevenir perda visual severa, especialmente se for detectada precocemente [1].

O diagnóstico desta patologia é realizado por inspeção visual da imagem de fundo do olho, avaliando certos tipos de anomalias na retina. A presença e distribuição de cada tipo de anomalia contribui para o grau da doença conforme o International Clinical Diabetic Retinopathy (ICDR), um protocolo científico bem estabelecido na medicina [1].

Idealmente, a Retinopatia Diabética deve ser monitorada em pacientes com diabetes, para possibilitar intervenções precoces. Devido ao método de inspeção visual, esse monitoramento requer a presença de oftalmologistas ou profissionais treinados. Quando consideradas situações de grande escala de pacientes, tais como atendimento em postos de saúde públicos, em geral, não se pode contar com a presença contínua e em suficiente número de tais profissionais.

Diante desse cenário, há grande interesse no desenvolvimento de sistemas computacionais para auxílio ao diagnóstico de RD. De fato, inclusive existem soluções na indústria que realizam a detecção e avaliação automática desta patologia já aprovadas pelo Food and Drug Administration (FDA) [3] e usadas comercialmente nos EUA e Europa.

No entanto, esses sistemas podem ter um custo elevado ou atender apenas populações com determinadas características, além de que não existem garantias de que sistemas empregados nos EUA funcionam igualmente bem em outros países. Por exemplo, a distribuição e caracterização da patologia pode diferir de uma região para outra. Por conta desse tipo de questionamento, e motivado pelo interesse no desenvolvimento de métodos computacionais para auxílio ao diagnóstico da RD, uma equipe da UNIFESP construiu o BRSET: um banco de dados *multilabel* de imagens de fundo de olho de pacientes brasileiros [4].

O BRSET contém, para cada imagem de fundo de olho, anotações sobre os tipos de lesões presentes. Este tipo de dado pode ser utilizado para treinar um modelo para determinar se uma dada imagem contém anomalias de um certo tipo.

Por outro lado, uma característica desejável em sistemas de auxílio a diagnóstico é que eles sejam capazes também de apontar evidências que justifiquem o resultado. Isto é, é muito mais significativo quando um sistema computacional indica que há grande possibilidade de que exista uma anomalia de um certo tipo e mostre, simultaneamente, onde tal anomalia se encontra na imagem. As evidências apontadas poderão servir para melhor fundamentar o diagnóstico médico.

Para desenvolver sistemas com esse tipo de capacidade, a máquina precisa ser treinada para detectar as anomalias. Isto, por sua vez, requer que as imagens sejam anotadas não apenas quanto ao tipo de lesões presentes, mas também quanto à localização de cada uma das lesões. Dentre as formas para anotar a localização, os mais comuns são os retângulos envoltórios (*bounding boxes*) e a segmentação semântica (ao nível de *pixel*). O segundo tipo de anotação, mais refinada, é importante se existe necessidade de quantificar a extensão (em termos de área afetada) das anomalias.

Os modelos atuais utilizados para processar dados do tipo imagem são as redes neurais convolucionais (CNNs) e os Transformers Visuais (ViT). As redes neurais modernas são também capazes de processar e gerar textos. Para o problema de diagnóstico da RD, torna-se natural utilizar as redes neurais convolucionais para o processamento de imagens. Desta forma, também é possível projetarmos sistemas para gerar uma "resposta" na forma de texto, de modo a enriquecer a informação fornecida.

Objetivos

Nesta proposta, pretendemos abordar o problema descrito acima. Mais especificamente, o objetivo principal é o desenvolvimento de um modelo para diagnóstico automático de retinopatia diabética, incluindo sua graduação conforme o ICDR, bem como os indicativos das lesões presentes na imagem.

O modelo deverá ser capaz de processar uma imagem de fundo de olho e gerar um relatório visual-descritivo, contendo um texto descritivo sobre as anomalias detectadas e apontando a localização das mesmas na imagem.

Pretendemos também servir uma página web para interação com esse modelo, de modo que usuários sem familiaridade com computação, possam utilizar o modelo para verificar a presença de eventuais anomalias relacionadas à RD em uma imagem de fundo de olho.

Metodologia

Primeiramente será realizado um estudo da literatura da área, para identificar conjuntos de dados publicamente disponíveis e principais publicações relacionadas à análise de RD por meio de técnicas baseadas em *deep learning*. Esta atividade, já está praticamente

concluída e pretendemos apenas realizar verificações periódicas para atualizações, se pertinentes.

Em relação ao conjunto de dados a serem utilizados, o principal será o BRSET, mencionado acima. Além dele podemos utilizar outros que já encontramos em domínio público para, por exemplo, fazer o pré-treinamento dos modelos (SynFundus [5], JustRAIGS [9]), avaliações comparativas e *fine tuning* (DDR [6], IDRiD [7] e DIARETDB1).

Uma referência central a ser utilizada neste trabalho é a arquitetura descrita em [8] para a confecção e treinamento do modelo. Até o momento, este foi o artigo que apresentou os melhores resultados em métricas relevantes para a tarefa de segmentação para a maioria dos datasets citados aqui.

Outra referência importante na construção de nosso modelo é a proposta Diabetic retinopathy lesion segmentation using deep multi-scale framework [10]. Essa arquitetura proposta apresenta elementos para lidar com os desafios relacionados à segmentação de lesões de baixa área usando *patches*, como na tarefa em questão. Além disso, o modelo é alimentado com a imagem original e uma cópia com processamento adicional, evidenciando as lesões e outras estruturas presentes na imagem de fundo de olho.

O nosso modelo deverá reproduzir alguns elementos-chave das arquiteturas citadas. Iremos testar diversos *backbones* (extratores de características) pré-treinados, incluindo um treinamento próprio usando o dataset SynFundus-1M [5]. Após isso, treinaremos os *decoders* para geração das máscaras de segmentação.

Para avaliar o desempenho do modelo iremos observar as métricas de acurácia, precisão, sensibilidade, especificidade, *f1 score*, mas principalmente a área abaixo da curva Precision-Recall (AUPR). Ela é recomendada para avaliar classes desbalanceadas em que a área abaixo da curva ROC (AUC) tem resultados excessivamente otimistas. Além disso, no desafio IDRiD, ela foi a principal métrica para classificação das equipes na modalidade segmentação de lesões.

Em relação ao sistema, temos como referência o HealthLens AI, um trabalho de conclusão do programa *Master of Information and Data Science* (MIDS) da Berkeley School of Information.

O trabalho consiste em um sistema de diagnóstico automático de Glaucoma servido em uma página web simples. Ao alimentar o sistema com uma imagem de fundo de olho, os modelos geram as segmentações relacionadas a essa patologia e as máscaras resultantes são usadas para compor tanto o escore diagnóstico, como para gerar visualizações no relatório final.

O formato de exposição do modelo e interação com usuário da nossa proposta é inspirada na HealthLens AI, principalmente a visualização das segmentações e elaboração do relatório descritivo-visual. No entanto, atacamos o problema da Retinopatia Diabética e focamos nossos esforços em uma solução mais voltada à população brasileira com o uso do BRSET.

O nossa arquitetura seguirá o diagrama esquemático conforme a Figura 1 a seguir.

Arquitetura do Modelo Fim a Fim

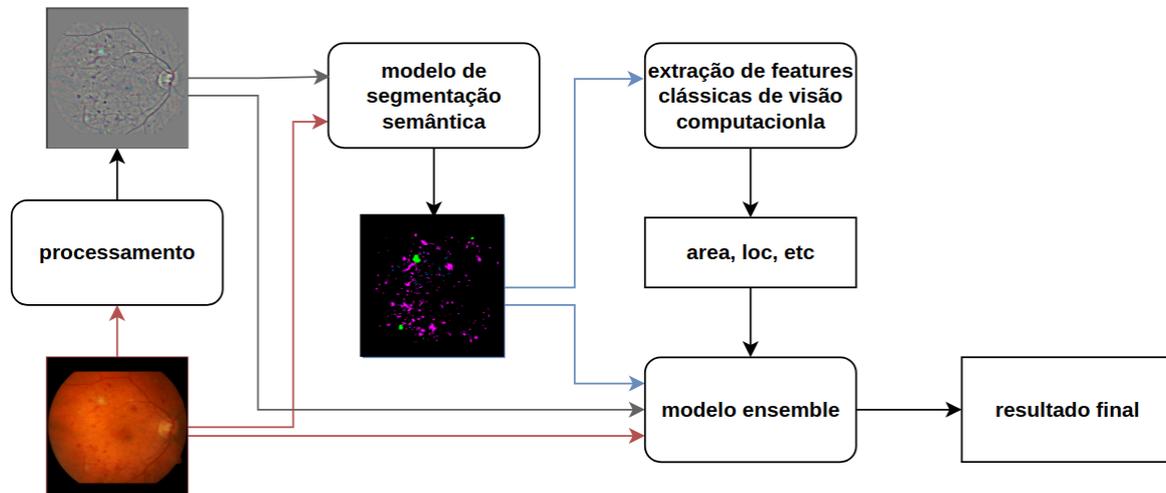


Figura 1 - Proposta de arquitetura do modelo fim a fim.

Cronograma

A Tabela 1 a seguir lista as principais etapas planejadas para o desenvolvimento deste trabalho.

Cronograma de Atividades											
	mar	abr	mai	jun	jul	ago	set	out	nov	dez	
desenhar arquitetura da aplicação web											
implementar aplicação web											
explorar trabalhos relacionados											
estudar ferramentas associadas											
implementar pipelines de treinamento e modelos											
treinar modelos											
ajuste fino dos modelos											
avaliar e discutir resultados e ajustes finais											
escrever trabalho											
apresentação do trabalho											

Tabela 1 - Cronograma de atividades

Referências

- [1] American Academy of Ophthalmology, Diabetic Retinopathy. (2016). url: <https://www.aaof.org/education/topic-detail/diabetic-retinopathy-europe>.
- [2] Amit Gattadahalli, et al. HealthLens AI. (2023). url: <https://www.ischool.berkeley.edu/projects/2023/healthlens-ai-revolutionizing-glaucoma-detection-cutting-edge-ai>
- [3] Grzybowski, A., & Brona, P. (2023). Approval and Certification of Ophthalmic AI Devices in the European Union. *Ophthalmology and therapy*, 12(2), 633–638. <https://doi.org/10.1007/s40123-023-00652-w>
- [4] Nakayama, L. F., Goncalves, M., Zago Ribeiro, L., Santos, H., Ferraz, D., Malerbi, F., Celi, L. A., & Regatieri, C. (2023). A Brazilian Multilabel Ophthalmological Dataset (BRSET) (version 1.0.0). *PhysioNet*. <https://doi.org/10.13026/xcxw-8198>.
- [5] Fangxin Shang, Jie Fu, Yehui Yang, Haifeng Huang and Junwei Liu and Lei Ma, (2024). SynFundus-1M: A High-quality Million-scale Synthetic fundus images Dataset with Fifteen Types of Annotation. <https://doi.org/10.48550/arXiv.2312.00377>
- [6] Tao Li, Yingqi Gao, Kai Wang, Song Guo, Hanruo Liu, Hong Kang. (2019). Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening. <https://doi.org/10.1016/j.ins.2019.06.011>
- [7] Prasanna Porwa, et al (2020). IDRiD: Diabetic Retinopathy – Segmentation and Grading Challenge. <https://doi.org/10.1016/j.media.2019.101561>.
- [8] Yin, Ming et al. (2023). Dual-Branch U-Net Architecture for Retinal Lesions Segmentation on Fundus Image. <https://doi.org/10.1109/ACCESS.2023.3333364>
- [9] de Vente, C et al. (2023). AIROGS: Artificial Intelligence for RObust Glaucoma Screening Challenge. <https://doi.org/10.48550/arXiv.2302.01738>
- [10] Tianjiao Guo, Jie Yang, Qi Yu. (2023). Diabetic Retinopathy Lesion Segmentation Using Deep Multi-scale Framework. <https://doi.org/10.1016/j.bspc.2023.105050>