



UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Autorizada pelo Decreto Federal nº 77.496 de 27/04/76
Recredenciamento pelo Decreto nº 17.228 de 25/11/2016



PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
COORDENAÇÃO DE INICIAÇÃO CIENTÍFICA

XXVI SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2022

AUMENTO DE DESEMPENHO DO MÓDULO DE RECUPERAÇÃO DE IMAGENS PARA O SISTEMA PATHOSPOTTER

Ozenilson Cruz¹; Angelo Duarte²

1. Bolsista PIBIC/CNPq, Graduando em Engenharia de Computação, Universidade Estadual de Feira de Santana, e-mail: ozenilsonalisson@gmail.com
2. Angelo Duarte, Departamento de Tecnologia, Universidade Estadual de Feira de Santana, e-mail: beltrano@provedor.br

PALAVRAS-CHAVE: Computational Vision; Image Retrieval; Nephropathology.

INTRODUÇÃO

De acordo com a Sociedade Brasileira de Nefrologia (SBN), cerca de 850 milhões de pessoas em todo o mundo sofrem de algum tipo de doença renal (Andrade & Tavares, 2020). Entre elas, as doenças glomerulares foram a terceira principal causa de doenças renais primárias no Brasil em 2017, estando atrás somente da hipertensão e da diabetes (Thomé *et al.*, 2019). O diagnóstico das doenças glomerulares é feito através da análise microscópica do rim e necessita de um patologista especialista.

Diante da evolução crescente da tecnologia na era atual, especialmente da visão computacional, diversas ferramentas para auxiliar no diagnóstico de doenças foram criadas. Dentre elas, o PathoSpotter-Search de Aguiar *et al.* (2021) auxilia na recuperação de imagens patológicas semelhantes de um conjunto de dados utilizando um sistema de Recuperação de Imagem Baseada em Conteúdo - Content-Based Image Retrieval (CBIR). A ferramenta conseguiu atingir um desempenho de cerca de 53% de precisão média para uma determinada divisão do conjunto de dados e 48% para outra e foi avaliada por um especialista que a considerou útil como ferramenta para auxiliar na coleta de imagens semelhantes de conjuntos de dados.

Apesar da avaliação do especialista, o desempenho ainda está abaixo do esperado, por isso, novas técnicas utilizadas em trabalhos relacionados foram utilizadas com o intuito de aprimorar o sistema.

METODOLOGIA

Um sistema de busca de imagens necessita de uma combinação eficiente de um extrator de características e uma boa métrica de pontuação de similaridade entre os descritores. Dessa forma, o sistema segue os passos similares aos de Aguiar *et al.* (2021): organização de separação do conjunto de dados, criação de um bom extrator de recursos Convolutional neural networks (CNNs) e verificação de boas métricas de distância entre vetores para comparar as características das imagens.

1. Conjunto de dados

O conjunto de dados utilizado conta com 2588 imagens distribuídas em quatro classes: 515 imagens para lesão do tipo hypercellularity, 775 do tipo membranous, 608 do tipo sclerosis e 690 sem lesão. Dentre as imagens com lesões do tipo hypercellularity: 92 são do tipo endocapillary, 181 endomesagial e 242 mesangial.

Como as imagens do tipo hypercellularity são similares e conseqüentemente difíceis de distinguir, foram realizados dois conjuntos de dados considerando a distribuição das classes. No conjunto 1, foram utilizadas as imagens dos tipos hypercellularity, membranous, sclerosis e normal. Já o conjunto 2 foi composto por imagens dos tipos endocapillary, endomesagial, mesangial e normal.

2. Extrator de Características

Considerando a boa performance das CNNs em diversas aplicações de visão computacional na medicina como nos trabalhos de Allegretti et al. (2021), Ramanjaneyulu et al. (2018) e Kapadia & Paunwala (2021) que fizeram uso das arquiteturas ResNet-50, VGG16 e Xception, respectivamente, como extrator de características e tiveram um bom desempenho, este trabalho fez uso das CNNs Inception, ResNet-50, VGG16 e Xception como extratores de características.

Diferente do trabalho anterior que utilizou o Kimia Path960 (Kumar et al., 2017) para treinar os modelos CNNs, as redes foram treinadas com parte do conjunto de dados apresentado anteriormente, utilizando todas as imagens de todos os tipos de corantes, mas apenas com as classes normal, esclerose e membranosa. Outros modelos treinados utilizam um conjunto de dados chamado Kimia Path24C (Shafiei et al., 2021), que contém mais de 23 mil imagens de patologias de diferentes partes do corpo, distribuídas em 24 classes. Contudo, foram utilizadas apenas 4 mil imagens.

3. Métricas de distância

Considerando a implementação anterior e pesquisas como a de Partil & Talbar (2010), foram escolhidas como métricas de similaridade as distâncias entre vetores Bray-Curtis, Cosseno, Euclidiana e uma combinação das distâncias bray-curtis, para avaliar a textura, e cosseno, para avaliar os ângulos. A arquitetura geral dos experimentos pode ser vista na Figura 1.




Figura 1: Arquitetura da CBIR. Inicialmente as características da imagem a ser buscada e das imagens de um banco de dados são extraídas utilizando as CNNs. Em seguida é feito um cálculo de similaridade entre as imagens utilizando métricas de distância e um vetor com k imagens mais similares é retornado.

RESULTADOS E DISCUSSÃO

Os resultados da precisão média das duas melhores distâncias experimentadas podem ser observados na Tabela 1.

Tabela 1. Precisão média das distâncias bray-curtis e cosseno com vetores de característica não normalizados.

Classes	A	B	A	B	A	B	A	B
	Inception		ResNet50		VGG16		Xception	
1	76,7%	77,4%	50,7%	51,4%	77,6%	78,3%	72%	72,5%
2	66,8%	64,9%	66,1%	67%	76,8%	72,2%	71,4%	71,5%
3	60,8%	60,5%	52,6%	50,3%	62,1%	61,4%	63,2%	63,5%
4	53,3%	52,7%	41,7%	43,1%	56,2%	55,7%	57,3%	56,6%
Média	64,4%	63,8%	52,7%	52,8%	68,1%	66,9%	65,9%	66%

Legenda: 1. Hypercellularity, 2. Membranous, 3. Normal, 4. Sclerosis, A = (bray-curtis); B = (cosseno)

Os resultados apresentados na Tabela 1 mostram que as distâncias bray-curtis e cosseno não apresentaram grande diferença uma da outra, trazendo resultados similares independente da rede utilizada. A VGG16 foi a que obteve o melhor resultado, com precisão média igual a 68,1% usando a distância bray-curtis como métrica de pontuação de similaridade.

Observando os resultados gerais dos experimentos, nota-se que as redes encontram dificuldade em diferenciar as imagens com a lesão do tipo hypercellularity, devido a apresentarem características parecidas. Outro ponto a se destacar é que as redes que utilizaram parte do conjunto de dados para treinamento mostraram resultados superiores às redes que utilizaram outro conjunto de dados, inclusive para as classes que não foram treinadas, como, por exemplo, a classe hypercellularity.

Diferentemente do trabalho anterior, o melhor resultado foi considerando as classes mais diferentes. No trabalho anterior, a melhor precisão considerando o primeiro conjunto de dados foi de 48,7%, utilizando a rede VGG16 com a distância cosseno, e no segundo conjunto com 53% de precisão, também com rede VGG16 e a distância cosseno. Já no atual, com o primeiro conjunto de dados obteve a melhor precisão igual a 68,1%, com a rede VGG16 e distância bray-curtis treinada com o conjunto de dados local, e 51,9% de precisão com o segundo conjunto, também com a rede VGG16 fazendo uso da distância bray-curtis e treinada com o conjunto de dados local.

Comparando os trabalhos anteriores com o atual, o experimento que utilizou o conjunto de imagens mais diferentes teve uma melhora de quase 20% e o como imagens mais similares uma redução de 1%.

CONCLUSÃO

O objetivo deste trabalho foi aprimorar o sistema de recuperação de imagens, PathoSpotter-Search. Para tal, foram avaliados os desempenhos de quatro arquiteturas de redes convolucionais (Inception, ResNet50, VGG16 e Xception) combinadas com quatro métricas de distância (bray-curtis, cosseno, euclidiana e uma combinação entre as distância bray-curtis e cosseno) e testadas com um conjunto de dados com imagens de agrupadas por tipo de lesão e não lesionadas. A avaliação foi realizada utilizando a média da precisão média da recuperação de imagens considerando todas as classes do conjunto utilizado para pesquisa.

A rede VGG16 mostrou-se eficiente na recuperação de imagens que, em conjunto com a métrica de distância bray-curtis, obteve uma precisão média de 68,1%, para um conjunto aprimorando o trabalho anterior que conseguiu um desempenho de 48,7% considerando as mesmas classes, todavia, ainda estando fora dos padrões estipulados como meta. Em trabalhos futuros, novas abordagens serão executadas e avaliadas a fim de conseguir um desempenho superior à 75%.

REFERÊNCIAS

- ANDRADE, M. C.; TAVARES, M. S. 2020. Dia Mundial do Rim. SBN, 12 mar. 2020. Disponível em: <<https://www.sbn.org.br/noticias/single/news/dia-mundial-do-rim/>>. Acesso em: 31 jul. 2022.
- THOMÉ, F. S. *et al.* 2019. Brazilian chronic dialysis survey 2017. *Brazilian Journal of Nephrology*, v. 41, p. 208-214.
- AGUIAR, E. *et al.* 2021. PathoSpotter-Search: A Content-Based Image Retrieval Tool for Nephropathology. In: *Anais Estendidos do XXXIV Conference on Graphics, Patterns and Images*. SBC. p. 146-149.
- ALLEGRETTI, S. *et al.* 2021. Supporting skin lesion diagnosis with content-based image retrieval. In: *2020 25th International Conference on Pattern Recognition (ICPR)*. IEEE. p. 8053-8060.
- RAMANJANEYULU, K.; SWAMY, K. V.; RAO, C. S. 2018. Novel CBIR system using CNN architecture. In: *2018 3rd International conference on inventive computation technologies (ICICT)*. IEEE. p. 379-383.
- KAPADIA, M. R.; PAUNWALA, C. N. 2021. Content based medical image retrieval system for accurate disease diagnoses using modified multi feature fused Xception model. *Indian Journal of Computer Science and Engineering (IJCSE)*, v. 12, n. 1, p. 89-100.
- KUMAR, M. *et al.* 2017. A comparative study of CNN, BoVW and LBP for classification of histopathological images. In: *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE. p. 1-7.
- SHAFIEI, S. *et al.* 2021. Colored Kimia Path24 Dataset: Configurations and Benchmarks with Deep Embeddings. arXiv preprint arXiv:2102.07611.

PATIL, S.; TALBAR, S. 2010. Content based image retrieval using various distance metrics. In: International Conference on Data Engineering and Management. Springer, Berlin, Heidelberg. p. 154-161.