

Využitie umelej inteligencie na vyhľadavanie očných ochorení na obrazoch z optickej koherenčnej tomografie


Ing. Samuel Gibala

Vedúca práce: MUDr. Veronika Kurilová PhD.

Motivácia

Strata zraku predstavuje jednu z najťažších životných situácií. Ochorenia ako diabetický edém makuly, makulárna diera či choroidálna neovaskularizácia patria medzi najčastejšie príčiny slepoty [1]. Diagnostika prostredníctvom optickej koherenčnej tomografie (OCT) je dnes štandardom, avšak manuálne vyhodnocovanie snímok je časovo náročné a môže byť chybové.

Cieľom práce bolo využiť umelú inteligenciu na urýchlenie a spresnenie diagnostiky, čím možno prispieť k efektívnejšej liečbe a zachovaniu kvality života pacientov.



Štruktúra makuly (upravené) [2]

Praktické uplatnenie

Navrhnuté riešenia majú veľký potenciál podporiť oftalmológov v klinickej praxi. Môžu slúžiť ako pomocný diagnostický nástroj, ktorý umožní:

- rýchle a spoľahlivé rozpoznanie očných ochorení,
- zníženie rizika diagnostických chýb,
- skrátenie času potrebného na vyhodnotenie vyšetrenia,
- poskytovanie transparentných a interpretovateľných výsledkov, ktorým môžu lekári dôverovať.

1

Metodika práce

Na riešenie úloh bol použitý dataset Retinal OCT C8 [3], ktorý bol po konzultácii s odborníkom oftalmológom zredukovaný na šesť diagnostických kategórií z dôvodu klinického prekryvania.

Následne boli porovnané 3 prístupy klasifikácie očných ochorení na snímkach z OCT:

1. **Extrakcia príznakov z predtrénovaných CNN modelov** (ResNet50, VGG16, InceptionV3) v kombinácii s jednoduchšími klasifikátormi (MLP, SVM, Random Forest).
2. **Dotrénovanie CNN modelov** v rôznych scenároch podľa rozsahu trénovaných parametrov.
3. **Moderné transformerové a hybridné architektúry** (Vision Transformer [4], MedViT [5]).

Nakoľko OCT snímky vykazujú zvýšený šum, analyzovaný bol aj vplyv predspracovania snímok aplikovaním redukcie šumu (Non-local Means Denoising a Bilateral filtering).


Ďalším krokom bola **analýza vysvetliteľnosti modelov** pomocou Grad-CAM vizualizácií [6], ktoré zvýrazňujú oblasti obrazu najviac ovplyvňujúce rozhodnutie siete. Tento prístup umožňuje overiť, či sa modely sústreďujú na medicínsky relevantné štruktúry, čo je kľúčové pre ich dôveryhodnosť v klinickej praxi.

2

Dosiahnuté výsledky

Výsledky experimentov ukázali, že najvyššiu klasifikačnú presnosť dosiahol model MedViT s predspracovaním pomocou metódy Non-local Means Denoising, a to až **95,95 %**. MedViT sa ukázal ako najrobustnejší a najvyváženejší model z hľadiska všetkých metrík (precision, recall, F1 skóre, ROC-AUC). Dotrénované konvolučné neurónové siete dosahovali najlepšie výsledky pri dotrénovaní všetkých vrstiev siete, napríklad model VGG16 s presnosťou **95,22 %**. Naopak, prístup založený na extrakcii príznakov bol menej úspešný, najlepší model SVM s ResNet50 príznakmi dosiahol presnosť **88,71 %**.

Dôležitou súčasťou práce bola aj analýza vysvetliteľnosti modelov. Grad-CAM vizualizácie ukázali, že modely s vysokou presnosťou sa skutočne zameriavajú na diagnosticky relevantné oblasti snímok, čo zvyšuje ich dôveryhodnosť pre klinické využitie.



Pôvodný OCT snímok (vľavo) a Grad-CAM vizualizácia (vpravo)

3

Referencie

- [1] HEISSIGEROVÁ, J. Oftalmologie. 3. aktualizované a doplnené vydání. Praha: Maxdorf, 2023. ISBN 978-80-7345-769-3.
- [2] OSCAR WYLEE. Anatomy of the Macula [online]. 2024. [cit. 2025-09-20]. Dostupné z: <https://www.oscarwylee.com.au/glasses/eye/anatomy/macula>.
- [3] NAREN, O. S. Retinal OCT Image Classification - C8 [online]. Kaggle, 2024 [cit. 2025-09-02]. Dostupné z doi: 10.34740/KAGGLE/DSV/9595300.
- [4] DOSOVITSKIY, A. et al. An image is worth 16x16 words: Transformers for image recognition at scale. arXiv preprint arXiv:2010.11929. 2020.
- [5] MANZARI, O. N.; AHMADABADI, H.; KASHIANI, H.; SHOKOUHI, S. B.; AYATOLLAHI, A. MedViT: A robust vision transformer for generalized medical image classification. Computers in Biology and Medicine. 2023, 157, 106791. Dostupné z doi: 10.1016/j.combiomed.2023.106791.
- [6] GILDENBLAT, J. PyTorch-Grad-CAM [online]. 2021. [cit. 2025-10-25]. Dostupné z: <https://github.com/jacobgil/pytorch-grad-cam>.