

Ing. Péter Mácsik

Autoreferát dizertačnej práce

Metódy diagnostiky diabetickej retinopatie na obrazoch sietnice

na získanie akademického titulu „doktor“ („philosophiae doctor“, v skratke „PhD.“)

v doktorandskom študijnom programe: robotika a kybernetika
v študijnom odbore: kybernetika

Forma štúdia: denná

Miesto a dátum: Bratislava 2024

Dizertačná práca bola vypracovaná na ústave robotiky a kybernetiky FEI STU v Bratislave.

Predkladateľ: Ing. Péter Mácsik
Ústav robotiky a kybernetiky FEI STU
Ilkovičova 2961/3, 841 04 Bratislava

Školiteľ: prof. Ing. Jarmila Pavlovičová, PhD.
Ústav robotiky a kybernetiky FEI STU
Ilkovičova 2961/3, 841 04 Bratislava

Oponenti: prof. Ing. Vanda Benešová, PhD.
Ústav počítačového inžinierstva a aplikovanej informatiky FIIT STU
Ilkovičova 6276/2, 842 16 Bratislava

doc. Ing. Dušan Koniar, PhD.
Katedra mechatroniky a elektroniky FEIT
Univerzitná 8215/1, 010 26 Žilina

Autoreferát bol rozoslaný:

Obhajoba dizertačnej práce sa bude konať dňa:

o.....h
na Fakulte elektrotechniky a informatiky STU, Ilkovičova 3, 841 04 Bratislava

prof. Ing. Vladimír Kutiš, PhD.
dekan FEI ST

Abstrakt

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE

FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Študijný program:	robotika a kybernetika
Dizertačná práca:	Metódy diagnostiky diabetickej retinopatie na obrazoch sietnice
Autor:	Ing. Péter Mácsik
Vedúci záverečnej práce:	prof. Ing. Jarmila Pavlovičová, PhD.
Miesto a rok predloženia práce:	Bratislava 2023

Vyšetrenie očnej sietnice má veľký význam pre skorú diagnostiku viacerých chorôb. Jednou z nich je diabetická retinopatia (DR), ktorá je dôsledkom cukrovky a môže viesť až k oslepnutiu pacienta. Počítačové algoritmy ponúkajú nákladovo efektívne riešenie pre relatívne spoľahlivú detekciu choroby. Obsahom práce je návrh a testovanie metód klasifikácie DR na fundusových obrazoch. V dizertačnej práci sú riešené dve úlohy pomocou hlbokého učenia: binárna klasifikácia a viactriedna klasifikácia. Pri úlohe binárnej klasifikácie DR boli použité lokálne binárne konvolučné neurónové siete s deterministickými a stochastickými fixnými filtrami, ktoré umožňujú redukcii trénovateľných parametrov. Tieto siete v experimentálnej časti boli porovnané s referenčnou štandardnou konvolučnou neurónovou sieťou ResNet18. Viactriedna klasifikácia bola riešená pomocou skupinového učenia, kde bol navrhnutý nový spôsob dosahovania diverzity. Jednotlivé modely skupinového učenia boli trénované na odlišne predspracovaných obrazoch a v experimentoch boli použité predtrénované architektúry Xception a EfficientNetB4. Navrhnuté skupinové modely dosiahli lepšie celkové klasifikačné výsledky.

Kľúčové slová: diabetická retinopatia, hlboké učenie, binárna a viactriedna klasifikácia, konvolučné neurónové siete, fixné filtre, lokálne binárne vzory, prenos učenia, skupinové učenie

Obsah

1	Úvod.....	1
1.1	Automatizovaná detekcia očných ochorení	3
1.2	Výzvy v klasifikácii DR hlbokými sieťami	4
2	Redukcia počtu trénovateľných parametrov v CNN – binárna klasifikácia... 7	
2.1	Lokálna binárna konvolučná sieť založená na fixných filtroch	8
2.2	Materiály a metódy	10
2.3	Výsledky	13
2.4	Diskusia	14
3	Zabezpečenie diverzity v skupinovom modeli – viactriedna klasifikácia	17
3.1	Skupinové hlboké učenie založené na odlišne predspracovaných obrazoch	17
3.2	Materiály a metódy	19
3.3	Výsledky	22
3.4	Diskusia	25
4	Zhodnotenie	28
4.1	Prínosy dizertačnej práce	29
	Zoznam použitej literatúry	31
	Príloha A: Účasť na projektoch	I
	Príloha B: Zoznam publikácií autora	II

1 Úvod

Diabetická retinopatia je očné ochorenie, ktoré vzniká vplyvom cukrovky (diabetes mellitus), pričom v pokročilých štádiách môže viesť k zhoršeniu zraku a v najhoršom prípade aj k úplnému oslepnutiu pacienta. Podľa štatistických údajov najmenej tretina diabetikov trpí aj nejakým očným ochorením, z ktorých je najčastejšia diabetická retinopatia [1]. Zároveň platí, že DR je najčastejšou príčinou slepoty v dospelom veku, ktorej by sa dalo predísť, v prípade ak by bola včas odhalená, čo by umožnilo nastavenie a vykonávanie vhodnej liečby [2–6]. Pre včasné odhalenie tejto choroby je dôležité vykonávať pravidelný skríning u všetkých pacientov, ktorí trpia cukrovkou. Pre skríning sú vhodné fundusové obrázky, ktoré znázorňujú očné pozadie, na ktorom je spozorovateľná štruktúra očného pozadia, t. j. systém krvných ciev, optický disk, fovea, makula a v prípade prítomnosti ochorenia rôzne abnormálne štruktúry, resp. chorobné lézie. Na základe týchto abnormalít a príznakov, kvalifikovaní lekári sú schopní posúdiť prítomnosť, resp. závažnosť tohto ochorenia. Hlavné klinické príznaky DR (pozri Obr. 1.1) sú nasledovné:

1. Mikroaneuryzmy (MA) – sú vyčnievajúce kapiláry a patria medzi prvé klinicky spozorovateľné príznaky DR. Vznikajú tzv. „nafukovaním” v častiach, kde sú cievy zoslabené. Objavujú sa ako malé červené bodky, avšak po čase môžu zmiznúť.
2. Hemoragie (HEM) – sa vyskytujú v dôsledku prasknutia zoslabených kapilár. Môžu to byť malé bodky, alebo väčšie krvavé škvrny prítomné v hlbších vrstvách sietnice. Hemoragie a mikroaneuryzmy sa dajú ľahko pomýliť ak sa hemoragie objavia ako malé bodky, pretože majú podobné vizuálne znaky.
3. Tvrdé exudáty (EX) – pozostávajú z lipoproteínov a iných proteínov, ktoré unikajú sietničnými cievami.
4. Mäkké exudáty (SE) – objavujú sa v pokročilom štádiu DR. Vznikajú pri cievnych absorpciách.
5. Intraretinálne mikrovaskulárne abnormality (IrMA) – sú skratové cievky a javia sa ako abnormálne vetvenia, alebo rozširovanie existujúcich krvných ciev v sietnici. Sú prekursorom neovaskularizácie a ťažko sa od seba rozlišujú.
6. Neovaskularizácia sietnice – je prirodzená tvorba nových krvných ciev, zvyčajne vo forme funkčných mikrovaskulárnych sietí. Vyskytuje sa pri najväznejších štádiách.

Tab. 1.1: Popis štádií DR a odporúčané rozhodnutia na ďalší postup [7, 8] podľa medzinárodnej stupnice ICDRDSS [9, 10].


Diabetická retinopatia	Sporované príznaky na dilatačnej oftalmoskopii	Odporúčané rozhodnutie
Žiadna	Žiadne príznaky	Sledovanie – nový skríning za 12-24 mesiacov
Mierna (NPDR)	Iba mikroaneuryzmy	Sledovanie – nový skríning za 12 mesiacov
Stredne pokročilá (NPDR)	Viac ako mierna NPDR, t. j. obsahuje mikroaneuryzmy a iné príznaky (napr. Hemoragie, tvrdé exsudáty), avšak menej ako veľmi pokročilá NPDR	Sledovanie – nový skríning za 6-9 mesiacov
Veľmi pokročilá (NPDR)	Stredne pokročilá DR spolu aspoň z jedným z nasledujúcich, avšak ešte nie je to Proliferatívna DR: <ul style="list-style-type: none"> - Intraretinálne hemoragie (viac ako 20 vo všetkých štyroch kvadrantoch) - Intraretinálne mikrovaskulárne abnormality (IRMA) v 1 alebo vo viacerých kvadrantoch - Flebopatia vo dvoch alebo vo viacerých kvadrantoch 	Lekárske odporúčanie na adekvátnu liečbu
Proliferatívna (PDR)	Veľmi pokročilá DR spolu aspoň s jedným z nasledujúcich: <ul style="list-style-type: none"> - Neovaskularizácia sietnice - Intravitreálna/Preretinálna hemoragia 	Lekárske odporúčanie na adekvátnu liečbu

Diabetická retinopatia je klasifikovaná podľa príznakov a závažnosti do dvoch hlavných skupín, NPDR a PDR [9, 10].

Neproliferatívna diabetická retinopatia (NPDR) – je charakterizovaná príznakmi ako mikroaneuryzmy, tvrdé a mäkké exsudáty, hemoragie alebo IRMA. Táto skupina sa ďalej rozdeľuje do podskupín: mierny, stredný a vážny NPDR.

Proliferatívna diabetická retinopatia (PDR) – je pokročilé štádium a zároveň najväčší stav diabetickej retinopatie. Vyznačuje sa tvorbou nových ciev, ktoré sa bežne vyskytujú na optickom disku alebo vznikajú na iných častiach sietnice. V počiatočnom štádiu PDR sa začína neovaskularizácia a preretinálna hemoragia. V neskorých štádiách môže spôsobiť odlúčenie sietnice a neovaskulárny glaukóm [11].

Podrobné rozdelenie, sa vykonáva pomocou medzinárodnej klasifikačnej stupnice závažnosti DR (ICDRDSS z angl. International Classification of Diabetic Retinopathy Severity Scale), ktorá rozdeľuje túto chorobu do piatich štádií podľa kritérií, ktoré sú definované v Tab. 1.1. Znáznornenie jednotlivých štádií a typov klinických príznakov na fundusových obrazoch sa nachádza na Obr. 1.1.



Obr. 1.1: Príklady fundusových obrazov podľa ICDRDSS so znázornením chorobných lézií.

1.1 Automatizovaná detekcia očných ochorení

Základným problémom DR je, že sa stane nevyliciteľnou pri pokročilých štádiách, preto je dôležité jej včasné odhalenie. Predstavuje to však veľké výzvy pre systémy zdravotnej starostlivosti v dôsledku veľkého počtu potenciálnych pacientov a malého počtu skúsených odborníkov, ktorí sú schopní a dostatočne kvalifikovaní stanoviť diagnózu. Ako alternatívne riešenie tohto problému sa začali skúmať a vyvíjať rôzne automatizované počítačové diagnostické systémy (angl. Computer Aided Diagnosis – CAD), ktoré sú nápomocné pri včasnej diagnóze DR. V tomto smere bolo vykonaných niekoľko pokusov a bolo navrhnutých niekoľko prístupov založených na strojovom učení, ktoré ukázali sľubnú efektívnosť pri rozpoznávaní DR na obrazoch sietnice [12, 13].

V posledných rokoch dostupnosť veľkého množstva údajov a zvýšenie výpočtového výkonu, ktoré ponúkajú grafické karty (GPU), viedli k výskumu rôznych algoritmov

hlbokého učenia (DL z angl. Deep Learning), ktoré preukázali vynikajúci výkon v rôznych úlohách počítačového videnia, pričom postupne prekonal tradičné metódy strojového učenia. Preto, ako nový smer pre riešenie rôznych úloh počítačovej analýzy obrazov očného pozadia, sa začali skúmať práve metódy DL.

Typ úlohy pri diagnostike DR, na ktorú počítačové algoritmy založené na hlbokom učení poskytujú riešenie, je klasifikácia na úrovni celého obrazu. V praxi to znamená, že na vstup predložíme obraz sietnice a ako výstup získame nejakú diskretnú triedu, ktorá v ideálnom prípade zodpovedá príslušnému štádiu ochorenia. Úlohy riešené v tejto práci patria práve do tejto skupiny. Takýto algoritmus je možné použiť ako pomôcku pri pravidelnom skríningu. Umožňuje neporovnateľne rýchlejší spôsob vyhodnotenia v porovnaní s človekom, pre veľký počet obrazov sietnice. Takýto systém ako prvá úroveň skríningového nástroja je schopný vyfiltrovať jednoznačné prípady a v prípade potreby vykonať adekvátne odporúčanie na liečbu. Následne na vyhodnotenie nejasných prípadov lekárom zostane väčší časový priestor. Existuje viacero klasifikačných schém používaných v praxi, podľa ktorých tieto algoritmy môžu vyhodnocovať DR (pozri Obr. 1.2), napr. binárna, ternárna, či ICDRDSS [10, 14].

Binárna	Zdravá (0)	Poškodená (1, 2, 3, 4)		
Binárna	Ne-Prisúditelná (0, 1)		Prisúditelná (2, 3, 4)	
Ternárna	Stupeň 0 (0)	Stupeň 1 (1, 2)	Stupeň 2 (3, 4)	
Ternárna	Zdravá Stupeň 0 (0)	NPDR Stupeň 1 (1, 2, 3)		PDR Stupeň 2 (4)
ICDRSS	Zdravá (Stupeň 0)	Mierna (Stupeň 1)	Stredná (Stupeň 2)	Veľmi pokročilá (Stupeň 3)
				PDR (Stupeň 4)

Obr. 1.2: Vyhodnocovacie schémy DR na sietnici (v zátvorkách sú uvedené jednotlivé štádiá).

1.2 Výzvy v klasifikácii DR hlbokými sieťami

Nedostatok dát – Jedným z najväčších problémov podľa prehľadového článku od Asiri a kol. [12], pri navrhovaní robustných klasifikačných metód pomocou hlbokého učenia, najmä založených na modeloch CNN s hlbšími architektúrami, je dostupnosť veľkého množstva označených tréningových dát. Platí to obzvlášť v oblasti medicíny. Hlavnou prekážkou nie je samotná dostupnosť obrazových dát, ale dosiahnuteľnosť označení týchto obrazov, či už na úrovni celého obrazu, alebo na úrovni jednotlivých pixelov. V prípade

fundusových obrazov, označovanie vyžaduje veľké úsilie, čas, a skúsenosti od viacerých oftalmológov, čo pochopiteľne pri ich nedostatočnom počte môže spôsobovať vysoké náklady a rôzne ďalšie komplikácie. Tento problém je možné riešiť viacerými spôsobmi. Prvou možnou alternatívou je zavedenie novej augmentačnej techniky. Bežne používané techniky augmentácie obrazov (najčastejšie geometrické transformácie ako rotácia, zrkadlenie atď.) nevytvárajú nové vzorky, ale existujúce vkladajú do inej perspektívy. Nová augmentačná technika by mohla vytvárať nové syntetické príznaky na sietnici a zároveň generovať úplne nové dáta. Možnou cestou pre takéto generovanie dát je generatívne učenie, napr. generatívna konfrontačná sieť (angl. generative adversarial network – GAN). Ďalšou alternatívou na riešenie problému je návrh nového CNN modelu, ktorý je vysoko účinný, ale na druhej strane používa menší počet parametrov pri tréovaní, čo nám umožní tréovanie na menšom počte dát bez preučenia [12].

Nevyváženosť dát (angl. imbalanced dataset) – Ďalšia výzva uvedená aj v prehľadovom článku [12] je nerovnomerné zastúpenie obrazov jednotlivých štádií choroby – klasifikačných tried. Množstvá obrazov s rôznymi poškodeniami a nálezmi DR sú odlišné a tento rozdiel v niektorých prípadoch je významný, čo spôsobuje zaujatosť pre špecifické triedy počas tréovania hlbokých neurónových sietí. Rozsiahle procesy retinálneho skríningu po celom svete vedú k získaniu obrovských databáz obrazov. Väčšina obrazov je však normálna, t. j. neobsahuje žiadne podozrivé nálezy, čo indikuje nerovnomernosť medzi zdravými a „poškodenými“ vzorkami – je to problém, ktorý sa často objavuje pri vytváraní medicínskych databáz pomocou lekárskeho zobrazovania. Riešenie môže byť podobné, ako pri predošlom probléme, t. j. generovanie nových dát, napr. augmentáciou existujúcich, alebo generovanie úplne nových syntetických dát v triedach, v ktorých je menšie zastúpenie obrazov [12].

Presnosť viactriednej klasifikácie a detekcia lézií – Podľa prehľadového článku od Alyoubi a kol. [13], vedecké práce skúmajúce vyhodnocovanie DR algoritmi hlbokého učenia sa doteraz vo väčšej miere zameriavali na binárnu klasifikáciu DR, t. j. zdravý/ chorý. Podľa tohto článku je to 73 %, pričom len zvyšných 27 % vedeckých štúdií sa zaoberá viac ako dvojtriednou klasifikáciou. Na druhej strane 70 % súčasných štúdií nezisťuje prítomnosť chorobných lézií, zatiaľ čo len zvyšných 30 % sa touto problematikou zaoberá, napr. pomocou sémantickej segmentácie. Spomedzi nich len 6 % štúdií uspelo v klasifikácii a odhalení všetkých lézií. Existencia spoľahlivého skrínového systému DR, ktorý je

schopný odhaliť rôzne typy lézií a štádiá DR vedie k efektívnemu systému sledovania (angl. follow-up system) pacientov s chorobou DR, čo môže odvrátiť nebezpečenstvo straty zraku. Na základe tejto analýzy autori posúdili, že medzera, ktorú by bolo potrebné pokryť, je existencia a vývoj systémov, ktoré by dokázali určiť päť štádií DR s vysokou presnosťou, ako aj detekciu DR lézií. Tento bod je považovaný za aktuálnu výzvu pre výskumníkov na ďalšie skúmanie [13].

1.2.1 Ciele dizertačnej práce

Mnoho algoritmov založených na hlbokom učení bolo vyvinutých pre rôzne úlohy analýzy obrazov očného pozadia s cieľom vyvinúť automatickú počítačom podporovanú diagnostiku diabetickej retinopatie. Rôzne výskumy a množstvo publikácií ukazuje, že táto oblasť je už do značnej miery preskúmaná. Avšak stále je tu priestor pre nové a vylepšené riešenia. Z tohto dôvodu v rámci tejto dizertačnej práce sa budeme venovať práve tejto oblasti, t. j. metódam hlbokého učenia vhodným na skríning, resp. vyhodnocovanie diabetickej retinopatie z digitálnych obrazov.

Na základe získaných poznatkov z preštudovanej literatúry, resp. výziev a nedostatkov, ktoré aktuálne postihujú oblasť vyhodnocovania DR metódami hlbokého učenia, sme si stanovili nasledovné ciele:

- Návrh vlastnej CNN siete s fixnými filtrami pre redukcii parametrov.

Úspešný návrh takejto siete ponúkne alternatívu pre riešenie problému „malého počtu dát“. V neposlednom rade, takáto sieť poskytne alternatívne riešenie aj pre zariadenia, ktoré sú vybavené nízkou pamäťovou kapacitou a obmedzenými výpočtovými zdrojmi, čo je prínosom napr. pre skríning založený na mobilných zariadeniach.

- Vytvorenie modelu skupinového učenia pomocou manipulácie vstupných dát.
- Zlepšenie viactriednej klasifikácie DR pomocou skupinového učenia (kombinácia viacerých modelov CNN pre klasifikáciu na úrovni celého obrazu) – experimentovanie s rôznymi hlasovacími schémami a ich vyhodnotenie.

Vytvorenie takéhoto riešenia bude schopné prispieť k zlepšeniu skríningu, účinnejšou viactriednou klasifikáciou DR, keďže správne rozpoznanie štádií ochorenia je kľúčové pri hodnotení rizika a plánovaní liečby DR.

Dizertačná práca obsahuje experimentálne overenie navrhnutých postupov a jednotlivých riešení.

2 Redukcia počtu trénovalných parametrov v CNN – binárna klasifikácia

Hlboké konvolučné neurónové siete zaznamenali v posledných rokoch obrovský úspech pri riešení mnohých problémov v oblasti počítačového videnia a to vďaka obrovskému vývoju mnohých efektívnych architektúr. Do tejto skupiny patria napr. Inception, ResNet, DenseNet a rôzne ďalšie. Spočiatku takéto siete síce vykazovali pozoruhodný výkon pri riešení rôznych zložitých úloh, avšak postupom času ich rastúca hĺbka a zložitosť viedli k zvýšeným výpočtovým nárokom. Na druhej strane tým, že sa modely zväčšovali a boli čoraz zložitejšie, ich pamäťové a výpočtové požiadavky sa stali prekážkou, čo obmedzovalo ich praktické využitie a nasadenie v aplikáciách v reálnom svete. Začalo to spôsobovať problém pre zariadenia, ktoré disponujú obmedzenými výpočtovými zdrojmi. Všeobecnými príkladmi sú autonómne vozidlá, roboty, smartfóny, inteligentné kamery, inteligentné nositeľné zariadenia atď. [15–18]. V oblasti klasifikácie DR ako príklad môžeme uviesť skrining založený na mobilných zariadeniach [18–20].

Pre riešenie tohto problému výskumníci začali skúmať a navrhovať tzv. „lightweight“ architektúry aby našli rovnováhu medzi veľkosťou a výkonom modelu. Príkladmi takýchto architektúr sú MobilNet [21], ShuffleNet [22], či SqueezeNet [23]. Ďalšie pokusy smerovali aj ku návrhu alternatívnych konvolučných vrstiev s binárnymi váhami. Binárne váhy priniesli dramatické výpočtové úspory vďaka efektívnej implementácii binárnych konvolúcií. Na druhej strane, úplná binarizácia váh CNN vedie k strate výkonu v porovnaní so štandardnými váhami siete. Juefei-Xu a kol. [16], vo svojej štúdii predstavili alternatívny prístup k zníženiu výpočtovej zložitosti CNN pričom zachovali porovnateľný klasifikačný výkon voči štandardnému CNN. Zaviedli tzv. lokálnu binárnu konvolučnú vrstvu (LBC), ktorá aproximuje nelineárne aktivovanú odozvu štandardnej konvolučnej vrstvy.

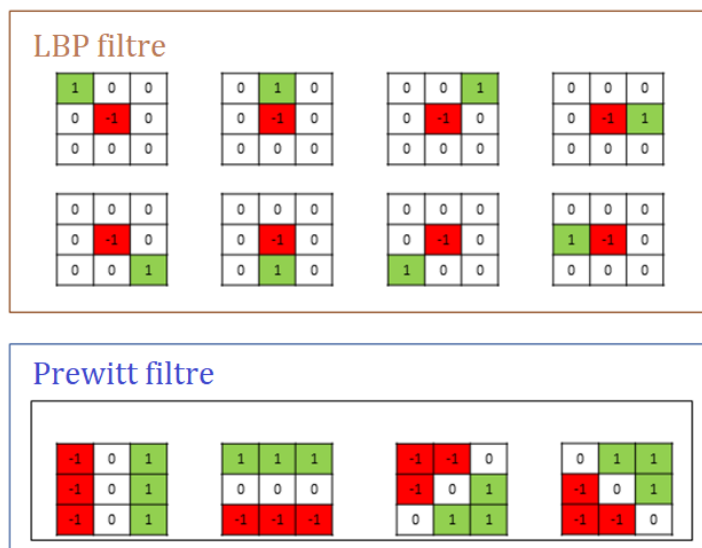
Ako sme si už pripomenuli v sekcii 1.2 Výzvy v klasifikácii DR hlbokými sieťami, výzvu malého množstva medicínskych dát je možné riešiť alternatívne aj navrhnutím nového CNN modelu, ktorý je vysoko účinný, ale na druhej strane používa menší počet parametrov pri tréovaní, čo umožňuje tréovanie na menšom počte dát bez preučenia [13]. Keďže sieť LBCNN spĺňa tieto kritériá, rozhodli sme sa ju použiť ako základ pre ďalšie experimenty, v ktorých sme ju aplikovali pre binárnu klasifikáciu DR. Následne sme ďalej experimentovali s ďalšími modifikáciami tejto siete. V rámci týchto experimentov sme vytvorili

deterministický spôsob generovania filtrov v LBCNN, čím sme dosiahli ďalšie významné pamäťové úspory, pričom sme sa snažili, zachovať porovnateľné klasifikačné výsledky. Porovnali sme Juefei-Xu a kol. zavedený stochastický a novo, nami vytvorený deterministický spôsob generovania fixných filtrov, pričom obe alternatívy sme porovnali aj so štandardnou CNN – architektúrou ResNet18. Porovnaná boli vykonané na dvoch databázach očného pozadia s odlišnou veľkosťou, APTOS a EyePACS.

2.1 Lokálna binárna konvolučná sieť založená na fixných filtroch

Prínos tejto práce, publikovanej v článku Local Binary CNN for Diabetic Retinopathy Classification on Fundus Images [24] – je práve návrh alternatívnej LBCNN siete, s deterministickými filtrami. Ako referenčná architektúra bola zvolená architektúra ResNet18, kvôli jej jednoduchosti a vysokej popularite. Pre zachovanie čo najobjektívnejšieho pracovného prostredia, aj pri modeloch LBCNN bola použitá kostra práve tejto architektúry s miernou modifikáciou, ktorá spočívala vo výmene klasických konvolučných vrstiev s filtrami s veľkosťou 3×3 , za alternatívne LBC. Pre porovnanie sme použili aj filtre generované stochastickým spôsobom podľa referenčného článku [16]. Boli vygenerované štyri balíky stochastických filtrov, ktoré boli prezdieľané medzi jednotlivými LBC vrstvami. Filtre boli generované s hustotou 0.5, ktorá bola stanovená v článku [16] ako dobrá štandardná hodnota.

Okrem toho sme experimentovali aj s LBCNN sieťou s deterministickými filtrami, kde základňu filtrov tvorili originálne LBC filtre a Previttove filtre (hranové filtre). Takýmto spôsobom sme získali 12 fixných deterministických filtrov.



Obr. 2.1: Báza deterministických filtrov v LBCNN [24].

Pre zvyšovanie počtu deterministických filtrov sa použila aj metóda výmeny prvkov +1 a -1 vo filtroch, ktorá nám zdvojnásobila počet filtrov z 12 na 24. Takáto sieť mala menej trénovateľných parametrov, čo je forma regularizácie, t. j. prevencia proti preučeniu a zároveň takúto sieť je možné natrénovať s menším počtom obrazov.

2.1.1 Počty trénovateľných parametrov

Hlavnou výhodou aplikácie vrstiev LBC je zníženie počtu trénovateľných parametrov pri zachovaní porovnateľnej klasifikačnej schopnosti. Počet trénovateľných parametrov pre jednotlivé siete v našom výskume sú uvedené v Tab. 2.1. Táto tabuľka obsahuje názov modelu a počet trénovateľných parametrov v miliónoch.

Tab. 2.1: Počet trénovateľných parametrov (skratky: sto. – stochastický/-é, det. – deterministický/-é).

Model	Parametre [milión]		
Štandardná CNN – ResNet18	11.178		
	12 filtrov	24 filtrov	72 filtrov
LBCNN – ResNet18 sto.	–	0.288	0.472
LBCNN – ResNet18 det.	0.242	0.288	–

2.1.2 Pamäťové nároky

Deterministický spôsob generovania filtrov má výhodu v šetrení pamäte v porovnaní so stochastickým generovaním, ako sme popísali vyššie, pretože ich nie je potrebné ukladať. To znamená, že alternatívne by sme ich mohli generovať programovo v preddefinovanom poradí. Stačí uložiť len učiteľné časti modelu, čo sú bodovo konvolučné vrstvy. V prípade generovania stochastických filtrov je však dôležité uložiť pevné filtre, inak nie je možné

opätovné použitie modelu. Pre porovnanie pamäťovej náročnosti týchto modelov, vo frameworku PyTorch [15] sme siete uložili vo formáte *.ckpt, v ktorom si môžeme uložiť natrénované parametre a fixné filtre pre opätovné použitie. Toto porovnanie je uvedené v Tab. 2.2. Obsahuje požiadavky na veľkosť pamäte pre štandardnú referenčnú CNN ResNet18 a každé nastavenie LBCNN. Treba však poznamenať, že špecifická veľkosť pamäte sa môže líšiť v závislosti od rôznych hardvérových a softvérových faktorov.

Tab. 2.2: Rozdiel v požadovanej veľkosti pamäte (skratky: sto. – stochastický/-é, det. – deterministický/-é).

Model	Veľkosť [KB]		
Štandardná CNN – ResNet18	131 106		
	12 filtrov	24 filtrov	72 filtrov
LBCNN – ResNet18 sto.	–	4 325	8 105
LBCNN – ResNet18 det.	2 972	3 512	–

2.2 Materiály a metódy

2.2.1 Použité databázy obrazov očného pozadia

Pred samotným trénovaním CNN algoritmu, dôležitým krokom je príprava dát. Experimenty boli vykonané pre dve voľne dostupné databázy očného pozadia EyePACS [25] a APTOS [26].

Kaggle EyePACS [25] je v súčasnosti najpoužívanejšia a najväčšia verejne dostupná databáza fundusových obrazov pre klasifikáciu DR [14], ktorá obsahuje 88 702 obrazov zaradené podľa stupnice ICDRDSS. Táto databáza bola zverejnená v roku 2015 na webovej stránke kaggle [25] pre súťaž, ktorej cieľom bolo vyvinúť čo najlepší systém pre automatizovanú detekciu DR. V rámci tejto súťaže označenia boli poskytnuté pre 35 126 obrazov, zvyšných 53 576 obrazov v databáze sa nachádza bez označení, nakoľko súťažiaci mali za úlohu klasifikovať pravé tieto obrázky. Databáza obsahuje ľavú a aj pravú sietnicu pacientov s vysokým rozlíšením, ktoré boli zachytené za rôznych svetelných podmienok a s rôznymi zariadeniami, čoho následkom je nejednotné rozlíšenie obrazov naprieč celej databázy. Táto databáza obsahuje veľké množstvo dát, čo je bezpochyby veľkou výhodou tejto databázy. Na druhej strane má aj niekoľko nedostatkov, ako napr. zlá kvalita niektorých obrazov ako napr. Obr. 3.3 (touto problematikou sa budeme zaoberať v nasledujúcej kapitole), či fakt, že označenia vytváral jediný lekár, čo potenciálne mohlo viesť k chybným označeniam. Tab. 2.3 obsahuje pôvodné rozdelenie tried tejto databázy. Z dôvodu malého počtu obrazov v triedach 3 a 4 (veľmi pokročilá a Proliferatívna DR), ktoré indikujú veľkú

mieru nerovnováhy medzi triedami, sme túto časť databázy rozšírili obrazov z testovacieho množiny EyePACS, podobne ako Kajan a kol. [27].

Databáza APTOS [26] bola predstavená v roku 2019 v rámci kaggle súťaže, ktorá mala za účel vybudovať nástroj na automatickú diagnostiku DR a zároveň zlepšiť schopnosť nemocníc identifikovať potenciálnych pacientov. Verejne dostupná časť tejto databázy obsahuje 3 662 fundusových obrazov, ktoré sú označené podľa stupnice ICDRDSS. Podobne ako pri databáze Kaggle EyePACS, dáta boli zbierané počas vyšetrení v reálnom svete, kvôli čomu databáza vykazuje heterogenitu obrazov vďaka rôznym nastaveniam fundusovej kamery. Nedostatkom tejto databázy je veľká nerovnováha medzi jednotlivými triedami, najmä pre veľmi pokročilú NPDR, ktorá má len 193 obrazov pričom najpočetnejšia trieda bez ochorenia obsahuje 1 805 obrazov. Tab. 2.3 obsahuje pôvodné rozdelenie tried tejto databázy. V kontexte našej binárnej klasifikácie po zlúčení obrazov na ktorých je prítomná DR v nejakej forme, sme získali rozloženie 1 805 obrazov pre triedu bez DR a 1 857 obrazov s prítomnosťou DR.

Tab. 2.3: Rozloženie počtov obrazov v jednotlivých triedach pre EyePACS a APTOS.

Databáza	Podmnožina	Triedy					Celkovo
		0	1	2	3	4	
EyePACS	Trénovacia	25 810	2 443	5 292	873	708	35 126
APTOS	Trénovacia	1 805	370	999	193	295	3 662

2.2.2 Vyhodnocovacie metriky

Metriky pre meranie výkonu klasifikačných algoritmov, sú veľmi dôležité pri algoritmoch hlbokého učenia pre získanie spätnej väzby o účinnosti algoritmu. Obzvlášť to platí pri riešení medicínskych úloh, kde takýto systém môže rozhodovať o zdraví pacientov. V tejto časti si zdefinujeme štatistické metriky, ktoré sa bežne používajú na vyhodnotenie úspešnosti algoritmov pre klasifikáciu DR. Sú to metriky ako: celková správnosť, citlivosť (senzitivita), špecificita, presnosť. Tieto metriky sú vypočítané pomocou tzv. kontingenčnej tabuľky (Tab. 2.4).

Kontingenčná tabuľka – Mnohé metriky sú založené na kontingenčnej tabuľke (angl. Confusion Matrix), pretože obsahuje všetky relevantné informácie o klasifikačnej schopnosti testovaného algoritmu.

Tab. 2.4: Kontingenčná tabuľka pre binárnu klasifikačnú úlohu.

		Skutočné		
		Trieda	Negatívne	Pozitívne
Predikované	Negatívne	(TN)	(FN)	rm_1 NPV
	Pozitívne	(FP)	(TP)	rm_2 PPV
		cm_1	cm_2	n
		Špecificita	Senzitivita	Acc

- TN (z angl. True Negative) – Negatívna vzorka, ktorá bola správne klasifikovaná ako negatívna
- TP (z angl. True Positive) – Pozitívna vzorka, ktorá bola správne klasifikovaná ako pozitívna
- FP (z angl. False Positive) – Negatívna vzorka, ktorá bola nesprávne klasifikovaná ako pozitívna
- FN (z angl. False Negative) – Pozitívna vzorka, ktorá bola nesprávne klasifikovaná ako negatívna

Veličiny cm_1 a cm_2 vyjadrujú počty negatívnych, resp. pozitívnych vzoriek, ktoré sú zahrnuté do testovania. Veličiny rm_1 a rm_2 vyjadrujú počty negatívnych, resp. pozitívnych vzoriek, ktoré klasifikátor predikoval, pričom n je celkový počet vzoriek, ktoré sú zahrnuté do testovania.

Celková správnosť – Úplne základnou metrikou je celková správnosť (angl. accuracy – acc). Táto metrika je definovaná ako pomer správne klasifikovaných inštancií oproti celej množine n . Formálne je definovaná nasledovne:

$$Acc = \frac{TP + TN}{n} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Aj keď je táto metrika často užitočná, môže byť skreslená v klasifikáciách, kde sa stretávame s nevyváženými triedami, keďže výslednú hodnotu najviac ovplyvní presnosť klasifikácie najpočetnejšej triedy.

Pre tieto prípady existujú ďalšie metriky, ktoré vyjadrujú výkonnosť klasifikátora viac objektívne.

Špecificita – vyjadruje schopnosť klasifikátora, správne klasifikovať negatívne vzorky (zdravé).

$$špecificita = \frac{TN}{cm_1} = \frac{TN}{TN + FP} \quad (2)$$

Senzitivita (angl. recall) – vyjadruje schopnosť klasifikátora, správne klasifikovať pozitívne vzorky (choré).

$$\text{senzitivita} = \frac{TP}{cm_2} = \frac{TP}{TP + FN} \quad (3)$$

Negatívna prediktívna hodnota (NPV) – presnosť klasifikácie pre negatívne vzorky.

$$NPV = \frac{TN}{rm_1} = \frac{TN}{TN + FN} \quad (4)$$

Pozitívna prediktívna hodnota (PPV)/ Presnosť – presnosť klasifikácie pre pozitívne vzorky.

$$PPV = \frac{TP}{rm_2} = \frac{TP}{TP + FP} \quad (5)$$

2.3 Výsledky

2.3.1 Náhrada konvolučných vrstiev LBC vrstvami

V tejto časti sú uvedené výsledky získané z dvoch databáz. Porovnávali sme štandardnú CNN sieť ResNet18 a jej LBCNN alternatívy – LBCNN so 24 a 72 stochastickými filtrami a LBCNN s 12 a 24 deterministickými filtrami. Výsledky vykonaných experimentov pre databázu APTOS sú uvedené v Tab. 2.5 a pre databázu EyePACS v Tab. 2.6. V stĺpcoch sa nachádzajú jednotlivé modely. V prípade LBCNN siete s jednotlivými nastaveniami, kde sto. sú stochastické a det. sú deterministické filtre. Číslo za skratkou vyjadruje počet filtrov (12f, 24f atď.). V riadkoch sú uvedené metriky ako, priemerná správnosť, štandardná odchýlka, senzitivita, špecificita a prediktívne hodnoty. Tieto výsledky boli vypočítané z 30-ich pokusov tréovania/ testovania. Snažili sme sa týmto porovnávaním zistiť výkon, najmä celkovú správnosť LBCNN s deterministickými v porovnaní so štandardnou referenčnou CNN sieťou a so stochastickým spôsobom generovania filtrov LBCNN, predstavenú Juefei-Xu a kol. [28]. V neposlednom rade sme sa snažili zistiť pomocou celkovej správnosti ich vzájomný celkový výkon v prípade tréovania na menšej a väčšej databázy.

Tab. 2.5: Výsledky na databáze Kaggle APTOS.

Model	CNN ResNet18	LBCNN (sto. 24f)	LBCNN (sto. 72f)	LBCNN (det. 12f)	LBCNN (det. 24f)
Acc [%]	95.59	95.57	95.44	95.89	96.58
std	0.556	0.462	0.362	0.383	0.402
spec[%]	95.94	96.01	95.74	95.96	96.59
sens[%]	93.77	93.67	93.22	94.03	94.63
NPV[%]	93.95	93.56	93.39	94.05	94.35
PPV[%]	95.71	95.83	95.75	96.08	96.73

Tab. 2.6: Výsledky na databáze Kaggle EyePACS.

Model	CNN ResNet18	LBCNN (sto. 24f)	LBCNN (sto. 72f)	LBCNN (det. 12f)	LBCNN (det. 24f)
Acc [%]	91.12	90.22	90.40	88.73	89.71
std	0.183	0.248	0.252	0.370	0.248
spec[%]	93.32	93.06	93.41	92.23	93.08
sens[%]	87.82	86.27	86.72	84.56	85.78
NPV[%]	89.34	88.14	88.50	86.68	87.65
PPV[%]	92.22	92.05	92.28	90.79	91.91

2.3.2 Porovnanie LBCNN s inými „Lightweight“ architektúrami

Na menšej databáze APTOS sme našu najvýkonnejšiu LBCNN sieť s deterministickými filtrami porovnali s inými populárnymi „Lightweight“ architektúrami. Tieto experimenty neboli publikované v našom článku [24] – Local binary CNN for diabetic retinopathy classification on fundus images. Boli vykonané neskôr ako doplnkové experimenty pre získanie referenčných výsledkov k porovnávaniu s inými všeobecne účinnými architektúrami, ktoré boli vyvinuté pre zariadenia s obmedzenými výpočtovými zdrojmi. Snažili sme sa týmto porovnávaním zistiť účinnosť resp. výkon ResNetLBCNN18_det_24f, v porovnaní s týmito architektúrami. Do Tab. 2.7 sme vyčíslili pre všetky Lightweight modely, t. j. MobileNetV2, MobileNetV3_small, ShuffleNetV2, SqueezeNet a ResNetLBCNN18_det_24f – príslušný počet parametrov, požadovanú veľkosť pamäte a klasifikačnú správnosť (Acc) ± štandardná odchýlka (std).

Tab. 2.7: Porovnanie „Lightweight“ architektúr. Výsledky získané na databáze APTOS.

Model	Počet parametrov [milión]	Veľkosť [KB]	Acc±std [%]
MobileNetV2	3,504	41 405	95.28±0.39
MobileNetV3_small	2,543	30 012	94.72±0.40
ShuffleNetV2	1,256	14 978	95.29±0.60
SqueezeNet	0,736	5 788	95.17±0.36
ResNetLBCNN18_det_24f	0,288	3 512	96.58±0.40

2.4 Diskusia

V tejto práci sme experimentovali s alternatívnou konvolučnou vrstvou LBC. Porovnávali sme štandardnú referenčnú CNN sieť so sieťami, ktoré obsahujú LBC vrstvy – sieťami LBCNN. Na základe našich experimentov uvedených v Tab. 2.5 a Tab. 2.6, ktoré sme vykonali na fundusových databázach, môžeme konštatovať, že LBCNN s oboma stratégiami generovania filtrov – stochastickou a deterministickou, sa dokáže priblížiť výkonu štandardnej referenčnej CNN pri riešení úlohy binárnej klasifikácie DR. Navyše, významne sa zníži počet trénovateľných parametrov a nároky na pamäť. Konkrétne

štandardná referenčná CNN v našich experimentoch mala 11.178 mil. parametrov, pričom LBCNN siete mali 0.288 mil. resp. 0.244 mil. parametrov.

Pri experimentoch s menším počtom tréovacích obrazov (databáza APTOS – Tab. 2.5), výkon LBCNN s 24 deterministickými filtrami dosiahol najlepšie výsledky. Priemerná celková správnosť v tomto prípade bola 96.58 %, pričom štandardná referenčná CNN dosiahla 95.59 %. V prípade väčšieho počtu obrazov (databáza EyePACS – Tab. 2.6), boli výsledky LBCNN s 24 deterministickými filtrami, tak ako sme očakávali, o niečo horšie z dôvodu nízkeho počtu parametrov. V tomto prípade dosiahla najlepšie klasifikačné výsledky referenčná hlboká CNN – ResNet18. Avšak aj v takomto prípade LBCNN ponúka kompromisné riešenie medzi klasifikačným výkonom a pamäťovými nárokmi. Konkrétne referenčná CNN ResNet18 dosiahla celkovú správnosť 91.12 % pričom naša LBCNN s deterministickými filtrami dosiahla 89.71 %. Avšak na dosiahnutie tohto výsledku potrebovala približne 37-krát menší pamäťový priestor. V prípade dostupnosti väčšieho množstva dát, ale výpočtovo limitovaného zariadenia alternatívnou voľbou by mohla byť LBCNN so zvýšeným počtom stochastických filtrov. Potvrdením úspešnosti takéhoto nastavenia je LBCNN so 72 stochastickými filtrami s celkovou správnosťou 90.40 %. V prípade dostupnosti väčšieho množstva tréovacích dát pochopiteľne vyššie množstvo parametrov nie je na škodu. Preto aj očakávane, výkon na väčšej databáze bol vyšší pre modely s najvyšším počtom parametrov, t. j. pre referenčnú CNN a pre LBCNN so 72 filtrami. Tu ale musíme pripomenúť aj jednu nevýhodu deterministického spôsobu generovania filtrov. V prípade, že nám výpočtové možnosti a veľkosť databázy umožňujú použiť väčší počet parametrov, ďalšie fixné filtre je možné pridať len ručne. Vo všeobecnosti výber balíka deterministických filtrov môže byť náročný. V prípade, že vybrané filtre nie sú optimalizované pre danú klasifikačnú úlohu, môže byť výkon tohto LBCNN aj horší, než výkon referenčnej CNN. Na druhej strane generované filtre môžeme ľubovoľne prispôbovať k danej úlohe – napr. odobraním, alebo aj pridaním nejakých nových filtrov. V našej práci boli takto pridané Prewittove filtre a bol počet filtrov zdvojnásobený kombináciami hodnôt +1 a -1.

Našu najvýkonnejšiu LBCNN sieť s deterministickými filtrami sme porovnali na databáze APTOS s existujúcimi tzv. „Lightweight“ architektúrami MobileNetV2, MobileNetV3_small, ShuffleNetV2, SqueezeNet – ktoré sú známe tým, že boli vyvinuté pre zariadenia s limitovanými výpočtovými zdrojmi. Toto porovnanie je prezentované v Tab.

2.7, v ktorej je možné vidieť, že LBCNN pracuje s najmenším počtom trénovateľných parametrov, má najnižšie pamäťové nároky a pritom dosahuje najvyššiu priemernú správnosť. Najmenšia sieť okrem našej LBCNN s deterministickými filtrami, SqueezeNet mala 0.736 mil. parametrov, s nárokom na pamäťový priestor 5 788 KB, pričom dosiahla celkovú priemernú správnosť 95.17 %. Na druhej strane naša LBCNN, mala 0.288 mil. parametrov a s nárokom na pamäť 3 512 KB dosiahla 96.58 %.

Vyššie uvedené pozorovania naznačujú, že používanie LBCNN s deterministickými filtrami z pohľadu absolútneho klasifikačného výkonu je viac výhodné pre klasifikačné úlohy, kde je k dispozícii len malé množstvo trénovacích dát. Avšak v prípade výpočtovo výrazne limitovaných zariadení ponúka kompromisné riešenie aj v prípade dostupnosti väčšieho množstva dát pri trénovaní.

3 Zabezpečenie diverzity v skupinovom modeli – viacriedna klasifikácia

Ďalšia riešená úloha je viacriedna klasifikácia na úrovni celého obrazu. Podstata použitých klasifikačných algoritmov je založená na skupinovom učení. Základná myšlienka spočíva vo využívaní rôznych metód predspracovania, t. j. tréovanie zvolenej CNN architektúry prebieha viackrát, s rozdielom, že na vstupe, sú dáta vždy predspracované inou metódou. Predikcie týchto nezávisle tréovaných sietí sú kombinované väčšinovým hlasovaním, resp. pomocou výsledných predikovaných pravdepodobností.


Inšpiráciou pri zrode tohto návrhu boli ďalšie vedecké práce, v ktorých sa autori snažili pri riešení iných medicínskych úloh vylepšiť celkový klasifikačný výkon, pričom diverzitu modelov zabezpečili pomocou rôznych zobrazovacích modalít. Príkladom takéhoto riešenia je práca [29], v ktorej autori vylepšili klasifikáciu ochorenia COVID-19, pomocou kombinácie CT, MR, a RTG obrazov pľúc. Základná myšlienka bola, že „iný“ pohľad na tie isté dáta poskytne širšie spektrum informácií, t. j. čo je možné spozorovať na jednej zobrazovacej metóde, nemusí byť na druhej a opačne.

Táto časť práce reflektuje na mierne zaostávajúcu oblasť výskum uvádzanú v časti 1.2 Výzvy v klasifikácii DR hlbokými sieťami – presnosť viacriednej klasifikácie a detekcia lézií. Touto prácou sme sa snažili k výskumu prispieť vytvorením a overením riešenia, ktoré zlepšuje viacriednu klasifikáciu DR v porovnaní s modelmi, ktoré pracujú samostatne. Pre viacriednu klasifikáciu boli vykonané experimenty pre dve rôzne databázy. Klasifikácia podľa ICDRDSS, t. j. do piatich tried, bola vykonaná pomocou databázy Kaggle APTOS. Ďalšia databáza, ktorá bola použitá, je DRR, pomocou, ktorej bolo možné riešiť šesť triednu klasifikáciu, t. j. päť ICDRDSS štádií a navyše triedu tzv. „neklasifikovateľných“ obrazov, ktoré majú nedostatočnú kvalitu.

3.1 Skupinové hlboké učenie založené na odlišne predspracovaných obrazoch

Táto práca predstavuje nový prístup dosiahnutia diverzity modelov pre klasifikáciu DR. Snahou je poskytnúť tej istej CNN architektúre nový/ iný pohľad na tie isté dáta. Pre zabezpečenie tohto, dáta sú vždy odlišne predspracované pred samotným tréovaním. V súčasnosti neexistuje jedna najlepšia metóda predspracovania pre všetky databázy, typy

obrazov, architektúr atď. Z toho vznikla myšlienka kombinovania viacerých metód predspracovania, aby bol modelom touto cestou dodaný iný pohľad na tie isté dáta. Jednotlivé architektúry resp. modely sa môžu naučiť odhaľovať niečo iné, ak ich natrénujeme na rôzne predspracovaných obrazoch.

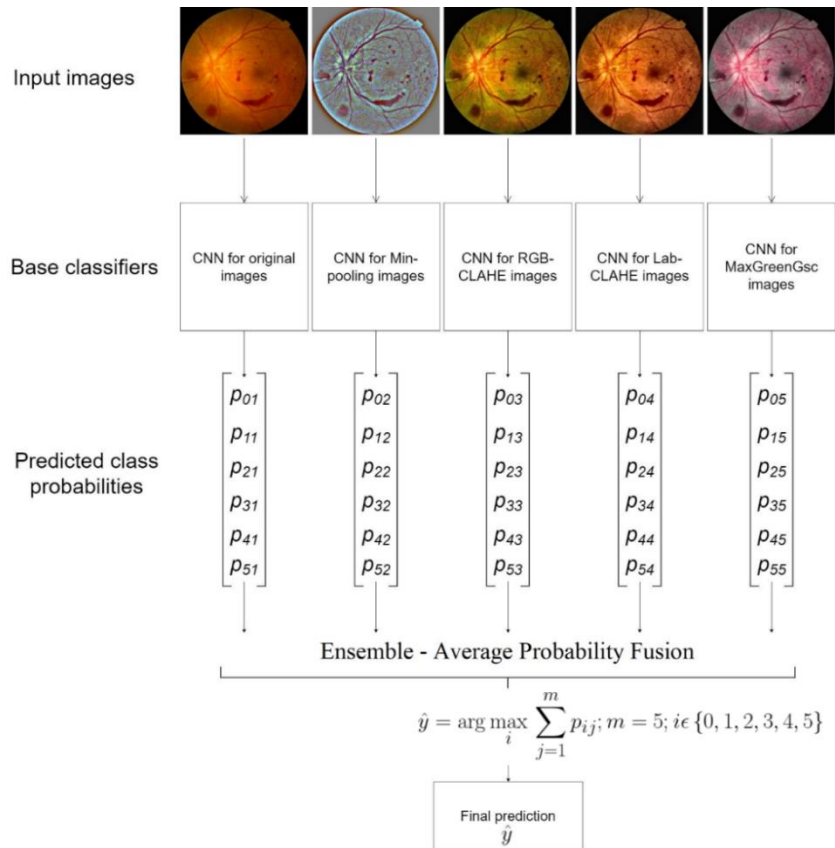


Obr. 3.1: Príklady použitých predspracovacích metód na fundusových obrazoch.

Navrhovaný skupinový model sa skladá z piatich CNN modelov. V rámci jednej skupiny bol použitý jeden typ architektúry, aby bolo možné sledovať výlučne vplyv predspracovacích metód. Do skupiny boli zaradené modely, ktoré boli trénované

- a) na originálnych RGB obrazoch
- b) na obrazoch predspracovaných Grahamovou metódou – Min-pooling
- c) na ekvalizovaných obrazoch aplikáciou CLAHE na RGB
- d) na ekvalizovaných obrazoch aplikáciou CLAHE na jasový kanál v modeli Lab
- e) na nových trojkanálových obrazoch – MaxGreenGsc.

Obr. 3.1 obsahuje príklady fundusových obrazov pre tieto predspracovania. Schéma navrhovaného skupinového modelu s fúziou výsledných pravdepodobností sa nachádza na Obr. 3.2.




Obr. 3.2: Navrhovaný skupinový model s piatimi modelmi s fúziou výsledných pravdepodobností.

3.2 Materiály a metódy

3.2.1 Použité databázy obrazov očného pozadia

Experimenty boli vykonané pre dve rôzne databázy očného pozadia – DDR [30] a APTOS [26].

Databáza DDR je v súčasnosti druhá najväčšia voľne dostupná databáza obsahujúca fundusové obrázky s označeniami DR na úrovni celého obrazu. Veľkou výhodou tejto databázy je, že bola zavedená aj šiesta trieda označenia, do ktorej boli zatriedené obrázky zlej kvality. Prítomnosť tejto triedy umožňuje natréňovať takú sieť, ktorá bude schopná klasifikovať problémové obrázky, aké sú napr. na Obr. 3.3. Nevýhodou tejto databázy je veľká nerovnováha medzi triedami – zdravá a stredne pokročilá sú oveľa viac zastúpené ako zvyšné, t. j. mierna, veľmi pokročilá a proliferatívna DR. Avšak takáto nevyváženosť ako sme si to už spomenuli je bežný problém pre medicínske databázy. Tab. 3.1 obsahuje rozdelenie tried databázy DDR.



Obr. 3.3: Vzorové obrazy z Kaggle EyePaACS. Tieto dva obrazy sú neklasifikovateľné kvôli zlej kvalite, avšak sú zaradené do zdravej skupiny. Týmto podobné obrazy sú v DDR zaradené do šiestej triedy, t. j. neklasifikovateľných obrazov.

Tab. 3.1: Rozdelenie tried databázy DDR.

	Trieda	Závažnosť DR	Trénovacia	Validačná	Testovacia	Celkovo
Bez DR	0	Bez DR	3133	1253	1880	6266
NPDR	1	Mierna	315	126	189	630
	2	Stredne pokročilá	2238	895	1344	4477
PDR	3	Veľmi pokročilá	118	47	71	236
	4	Proliferatívna	456	182	275	913
Neklasifikovateľné	5	Neklasifikovateľné	575	230	346	1151
		Celkovo	6835	2733	4105	13,673

Databáza APTOS na rozdiel od DDR, neobsahuje samostatnú triedu s obrazmi ktoré sa považujú za „neklasifikovateľné“. Absencia označení tejto triedy z nej robí dobrú alternatívu na meranie a hodnotenie výkonu navrhovaného postupu pre päť triednu situáciu, ktorá je v súčasnosti viac rozšírená pri voľne dostupných fundusových databázach. Keďže APTOS nemá vopred definované rozdelenie tried, pre experimenty bola rozdelená spôsobom náhodného výberu na tréningové a testovacie dáta v pomere 80:20. Tab. 3.2 obsahuje rozdelenie tried databázy APTOS. Ostatné vlastnosti databázy APTOS sme si už pri predošlej časti práce v sekcii 2.2.1 zhrnuli.

Tab. 3.2: Náhodné rozdelenie tried databázy APTOS v pomere 80:20.

	Trieda	Závažnosť	Trénovacia	Validačná	Testovacia	Celkovo
Bez DR	0	Bez DR	1419	–	386	1805
NPDR	1	Mierna	296	–	74	370
	2	Stredne pokročilá	816	–	183	999
PDR	3	Veľmi pokročilá	157	–	36	193
	4	Proliferatívna	241	–	54	295
		Celkovo	2929	–	733	3662

3.2.2 Vyhodnocovacie metriky

Pre vyhodnotenie experimentov boli použité podobné štatistické metriky ako aj v predošlej kapitole, prezentované pre binárnu úlohu v sekcii 2.2.2. Zovšeobecnenie týchto metrick pre prípad viactriednej klasifikácie je možné vykonať pomocou kontingenčnej

tabuľky, ktorá je znázornená v Tab. 3.3. Tabuľka znázorňuje množiny TN, FN, TP, FP pre k -tú triedu c_k .

Tab. 3.3: Kontingenčná tabuľka pre viactriednu klasifikačnú úlohu – príklad pre k -tú triedu c_k .

		Skutočné			
		Trieda	$c_1 \dots c_{k-1}$	c_k	$c_{k+1} \dots c_m$
Predikované	$c_1 \dots c_{k-1}$		TN	FN	TN
	c_k		FP	TP_k	FP
	$c_{k+1} \dots c_m$		TN	FN	TN

V tejto tabuľke je možné spozorovať, že niektoré časti množín TN, FP, FN sú oddelené. Pre získanie výsledných TN_k , FP_k , FN_k tieto oddelené časti samozrejme musíme sčítať.

V prípade viactriednej klasifikácie sa používajú metriky senzitivita (alebo triedna správnosť) a presnosť, najmä vzhľadom na dané triedy oddelene. Formálne ich môžeme definovať pomocou vyššie uvedenej zovšeobecnenej kontingenčnej tabuľky nasledovne:

$$recall_k = \frac{TP_k}{TP_k + FN_k} \quad (6)$$

$$PPV_k = \frac{TP_k}{TP_k + FP_k} \quad (7)$$

Kappa koeficient – V oblasti hlbokého učenia pri klasifikácii medicínskych obrazov viacerých tried, hodnotenie výkonnosti modelov je kritickou úlohou. Tradičná metrika „celková správnosť“ je síce populárny ukazovateľ, avšak môže byť zavádzajúci, najmä v prípadoch nevyváženého rozdelenia tried, ktoré bežne postihuje databázy obsahujúce medicínske dáta. Tu vstupuje do hry tzv. kappa koeficient (alebo Cohenovo kappa) [31], ktorý vyjadruje mieru zhody medzi dvoma vyhodnocovacími subjektami, t. j. v našom prípade medzi referenčnými a klasifikátorom predikovanými označeniami. Celková správnosť sa zameriava výlučne na podiel správnych predikcií – nezohľadňuje potenciálny náhodný výskyt správnych predikcií čo je problém najmä ak sú triedy nevyvážené v používanej databáze. Na druhej strane kappa koeficient poskytuje spôsob posúdenia celkovej správnosti klasifikácie so zohľadnením náhodnej zhody, čím sa zvyšuje spoľahlivosť procesu vyhodnotenia. Formálne ju definujeme nasledovne:

$$\kappa = \frac{Acc - p_e}{1 - p_e} = 1 - \frac{1 - Acc}{1 - p_e} \quad (8)$$

kde Acc je celková správnosť, a p_e je pravdepodobnosť na nezhodu medzi predikovanými a skutočnými hodnotami [32]. Hodnotu p_e definujeme nasledovne:

$$p_e = \sum_{i=1}^n \frac{cm_i \times rm_i}{n^2} \quad (9)$$

kde cm_i je celkový počet vzoriek z i -tej triedy, rm_i je počet predikovaných vzoriek do i -tej triedy a n je celkový počet zahrnutých vzoriek do testu.

Variantom kappa koeficientu je **kvadraticky vážený kappa koeficient** [33–35], ktorý na rozdiel od pôvodnej berie do úvahy aj poradový vzťah medzi hodnotenými kategóriami. Vážená kapa sa definuje nasledovne:

$$\kappa_w = \frac{p_{ow} - p_{ew}}{1 - p_{ew}} \quad (10)$$

kde

$$p_{ow} = \sum_{i=1}^k \sum_{j=1}^k w_{ij} p_{ij} \quad a \quad p_{ew} = \sum_{i=1}^k \sum_{j=1}^k w_{ij} p_i q_j$$

$$p_i = \sum_{j=1}^k p_{ij} \quad a \quad q_j = \sum_{i=1}^k p_{ij}$$

Výpočet sa vykonáva pomocou kontingenčnej tabuľky, kde $p_{ij} = t_{ij}/n$. n je celkový počet vzoriek, pričom t_{ij} ($i, j \in \{1, 2, \dots, k\}$), označuje počet vzoriek zaradených do kategórie i -tej triedy prvým a do j -tej triedy druhým klasifikátorom. t_{ij} , kde $i \neq j$ sú nezhody.

Kvadratické váhy sú definované nasledovne:

$$w_{ij}^Q = 1 - \frac{|i - j|^2}{(k - 1)^2} \quad (11)$$

Obidve, „klasická“ a kvadraticky vážená kapa sú zaužívané ukazovatele v skúmanej oblasti. Avšak medzi jednotlivými štúdiami sa jeho použitie vyskytuje striedavo, preto v tejto práci prezentujeme obidve varianty.

3.3 Výsledky

3.3.1 Klasifikácia podľa stupnice ICDRDSS

Podmienkou potvrdenia prínosu skupinového modelu je, aby bola skupina ako celok viac účinná ako najlepší jednotlivec. Aby sme si toto overili, vykonali sme experimenty pre viactriednu klasifikáciu pre dve rôzne databázy a modely. Výsledky a porovnanie týchto experimentov sú uvedené v Tab. 3.4 a Tab. 3.5. Porovnanie obsahuje v riadkoch výsledky pre jednotlivé modely, ktoré boli tréňované na jednotlivých predspracovaniach a aj pre

navrhované skupinové modely. V stĺpcoch sa nachádzajú metriky ako celková správnosť, kappa a vážená kappa. Výsledky sú uvedené ako priemerné hodnoty troch opakovaných behov experimentov \pm štandardná odchýlka. Tieto výsledky boli dosiahnuté na testovacích množinách jednotlivých databáz.

Tab. 3.4: Porovnanie navrhovaných skupinových modelov s jednotlivými modelmi na databázach APTOS a DDR – Model Xception. Výsledky sú uvedené ako priemerné hodnoty troch opakovaných behov experimentov \pm štandardná odchýlka. Acc – Celková správnosť, κ – Cohenov kappa, κ_w – Cohenov kvadraticky vážená kappa. V a P sú označenia pre fúzováciu metódu. V – väčšinové hlasovanie a P – výsledné pravdepodobnosti.

Typ obrazu	APTOS			DDR		
	Mean Acc [%]	Mean κ	Mean κ_w	Mean Acc [%]	Mean κ	Mean κ_w
Original	86.40 \pm 0.06	0.786 \pm 0.002	0.891 \pm 0.013	78.36 \pm 0.25	0.667 \pm 0.003	0.863 \pm 0.003
Min-pooling	86.68 \pm 0.23	0.790 \pm 0.003	0.899 \pm 0.001	78.17 \pm 0.26	0.662 \pm 0.003	0.859 \pm 0.002
RGB-CLAHE	86.81 \pm 0.32	0.792 \pm 0.005	0.901 \pm 0.002	79.50 \pm 0.27	0.686 \pm 0.006	0.868 \pm 0.008
Lab-CLAHE	86.58 \pm 0.28	0.788 \pm 0.004	0.908 \pm 0.004	78.88 \pm 0.41	0.674 \pm 0.005	0.864 \pm 0.005
MaxGreenGsc-CLAHE	86.54 \pm 0.17	0.787 \pm 0.003	0.907 \pm 0.003	79.21 \pm 0.31	0.681 \pm 0.007	0.869 \pm 0.004
Ensemble A V	88.27 \pm 0.68	0.814 \pm 0.012	0.9102 \pm 0.009	81.37 \pm 0.45	0.711 \pm 0.007	0.880 \pm 0.005
Ensemble A P	88.36 \pm 0.50	0.816 \pm 0.008	0.9103 \pm 0.007	81.67 \pm 0.70	0.716 \pm 0.012	0.884 \pm 0.006

Tab. 3.5: Porovnanie navrhovaných skupinových modelov s jednotlivými modelmi na databázach APTOS a DDR – Model EfficientNetB4. Výsledky sú uvedené ako priemerné hodnoty troch opakovaných behov experimentov \pm štandardná odchýlka. Acc – Celková správnosť, κ – Cohenov kappa, κ_w – Cohenov kvadraticky vážená kappa. V a P sú označenia pre fúzováciu metódu. V – väčšinové hlasovanie a P – výsledné pravdepodobnosti.

Typ obrazu	APTOS			DDR		
	Mean Acc [%]	Mean κ	Mean κ_w	Mean Acc [%]	Mean κ	Mean κ_w
Original	87.95 \pm 0.23	0.810 \pm 0.004	0.912 \pm 0.0003	79.32 \pm 0.52	0.678 \pm 0.008	0.870 \pm 0.005
Min-pooling	88.18 \pm 0.17	0.814 \pm 0.003	0.913 \pm 0.005	79.53 \pm 0.25	0.683 \pm 0.003	0.873 \pm 0.001
RGB-CLAHE	88.04 \pm 0.23	0.812 \pm 0.004	0.901 \pm 0.001	81.14 \pm 0.29	0.710 \pm 0.007	0.886 \pm 0.008
Lab-CLAHE	87.95 \pm 0.23	0.810 \pm 0.004	0.912 \pm 0.002	80.28 \pm 0.51	0.695 \pm 0.008	0.876 \pm 0.004
MaxGreenGsc-CLAHE	88.09 \pm 0.28	0.812 \pm 0.005	0.913 \pm 0.004	80.46 \pm 0.64	0.699 \pm 0.009	0.881 \pm 0.004
Ensemble B V	89.90 \pm 0.40	0.841 \pm 0.006	0.917 \pm 0.004	82.05 \pm 0.36	0.721 \pm 0.006	0.896 \pm 0.005
Ensemble B P	89.63 \pm 0.22	0.836 \pm 0.003	0.916 \pm 0.002	82.41 \pm 0.49	0.726 \pm 0.008	0.895 \pm 0.004

3.3.2 Porovnanie s referenčnými prácami

Aby bolo možné porovnať dosiahnuté výsledky so súčasnou úrovňou vedy (angl. state of the art), v tejto časti uvádzame tabuľky, ktoré obsahujú výsledky referenčných prác prevzaté od pôvodných autorov a výsledky dosiahnuté pomocou nami navrhnutých skupinových modelov. Toto porovnanie je len orientačné, keďže sa jednotlivé práce mierne líšia v experimentálnych nastaveniach. Návrhy a výsledky však boli realizované na rovnakých databázach (DDR [30] a APTOS [26]) a vo väčšine prípadov sa zhodoval aj evaluačný protokol. Tab. 3.6 obsahuje výsledky získané na testovacej sade databázy DDR. Obsahuje správnosť pre jednotlivé stupne ochorenia, celkovú správnosť a kappa koeficienty.

Tab. 3.6: Porovnanie navrhnutých skupinových modelov so súčasťou úrovňou vedy na testovacej sade DDR. Model A – Xception Ensemble; Model B – EfficientNetB4 ensemble. V a P znamenajú: hlasovacia (z angl. Voting) a pravdepodobnostná (z angl. Probability) fúzia. Uvedené výsledky pre navrhnuté skupinové modely sú priemery z troch opakovaní \pm štandardná odchýlka.

Model	No DR [%]	Mild [%]	Moderate [%]	Severe [%]	Proliferative [%]	Ungradable [%]	Acc [%]	\mathcal{K}	\mathcal{K}_w
VGG-16 [30]	95.37	4.23	56.25	39.44	64.36	94.22	75.20	0.623	–
ResNet-18 [30]	95.48	5.82	62.20	36.62	58.18	91.33	76.59	0.650	–
GoogLeNet [30]	95.74	2.65	57.59	33.80	57.82	91.62	74.98	0.626	–
DenseNet-121 [30]	89.30	22.75	57.51	40.85	63.64	93.06	73.57	0.605	–
SE-BN-Inception [30]	94.52	4.76	64.58	12.68	58.18	90.46	76.39	0.647	–
CABNet [36]	–	–	–	–	–	–	78.98	–	0.786
Model A V [ours]	97.89 ± 0.12	7.23 ± 3.44	70.39 ± 1.97	39.91 ± 2.15	66.30 ± 0.84	95.09 ± 1.26	81.37 ± 0.45	0.711 ± 0.01	0.88 ± 0.01
Model A P [ours]	97.94 ± 0.26	6.00 ± 3.10	70.91 ± 2.73	39.91 ± 4.30	67.88 ± 1.79	95.86 ± 1.69	81.67 ± 0.70	0.716 ± 0.01	0.884 ± 0.01
Model B V [ours]	99.01 ± 0.26	7.76 ± 2.00	70.78 ± 0.11	27.70 ± 5.69	69.58 ± 2.75	95.38 ± 0.87	82.05 ± 0.36	0.721 ± 0.01	0.896 ± 0.01
Model B P [ours]	99.11 ± 0.19	7.58 ± 3.10	71.6 ± 0.93	27.23 ± 7.76	69.82 ± 2.02	95.86 ± 0.44	82.41 ± 0.49	0.726 ± 0.01	0.895 ± 0.00

Navrhnuté modely skupinového učenia prekonal referenčné modely v prípade triednych správností Bez DR, proliferatívnej DR, neklasifikovateľných obrazov, celkovej správnosti (Acc) a kapa koeficientu. Skupinové modely nedosiahli najvyššie hodnoty v prípade troch stupňov a to v prípade mierneho, stredného a veľmi pokročilej DR. Avšak aj v týchto prípadoch boli naše skupinové modely v porovnaní s referenčnými modelmi druhé alebo v najhoršom prípade tretie najúčinnejšie.

Porovnanie získaných výsledkov s referenčnými prácami pre databázu APTOS je prezentované v Tab. 3.7. Z dôvodu, že sa mierne líšia evaluačné protokoly pri niektorých prácach, a najmä, že v mnohých absentuje vyčíslenie klasifikačnej správnosti pre jednotlivé stupne, do tabuľky tieto ukazovatele neboli zaradené. Obsahujú však celkovú správnosť a jednotlivé kapa koeficienty.

Tab. 3.7: Porovnanie navrhnutých skupinových modelov so súčasťou úrovňou vedy pre databázu APTOS. Model A – Xception Ensemble; Model B – EfficientNetB4 ensemble. V a P znamenajú: hlasovacia (z angl. Voting) a pravdepodobnostná (z angl. Probability) fúzia. Uvedené výsledky pre navrhnuté skupinové modely sú priemery z troch opakovaní \pm štandardná odchýlka.

	Rok	Evaluácia	Acc [%]	CK	CQK
Kassani et al. [37]	2019	70:20:10 hold-out	83.09	f	–
Taufiqurrahman et al. [38]	2020	10-fold cross validation	79.00	–	0.88
Bodapati et al. [39]	2020	80:20 hold-out	80.96	0.71	–
Majumder et al. [40]	2021	90:10 hold-out	86.00	–	0.90
Kobat et al. [41]	2022	80:20 hold-out	85.93	0.7837	–
Mondal et al. [42]	2023	80:20 hold-out	86.06	–	–
Ensemble A V [ours]	2023	80:20 hold-out	88.27 \pm 0.68	0.814 \pm 0.011	0.910 \pm 0.009
Ensemble A P [ours]	2023	80:20 hold-out	88.36 \pm 0.50	0.816 \pm 0.008	0.910 \pm 0.007
Ensemble B V [ours]	2023	80:20 hold-out	89.90 \pm 0.40	0.841 \pm 0.006	0.917 \pm 0.004
Ensemble B P [ours]	2023	80:20 hold-out	89.63 \pm 0.22	0.836 \pm 0.003	0.916 \pm 0.002

V tomto prípade navrhnuté modely skupinového učenia prekonal referenčné modely vo všetkých uvedených ukazovateľoch.

3.4 Diskusia

Existuje mnoho prístupov zvyšovania výkonnosti hlbokých sietí. Jedným z nich je skupinové učenie, ktoré v mnohých úlohách bolo schopné zvýšiť celkový klasifikačný výkon využitím znalostí viacerých modelov. Zlúčením viacerých modelov do skupiny môžeme dosiahnuť aj vyššiu robustnosť celkového modelu, čo však zvyčajne so sebou prináša aj technologické výzvy. Skupinu modelov je náročné trénovať. Navyše, nesprávny výber modelu môže v určitých prípadoch viesť k ešte nižšej presnosti predikcie. Nevýhodou tohto prístupu sú aj vyššie pamäťové a výpočtové náklady spojené s vývojom a nasadením vytvoreného modelu, ako aj zvýšená náročnosť interpretovateľnosti v dôsledku zvýšenej zložitosti celej architektúry.

Ďalšou možnosťou na zlepšenie klasifikačného výkonu pri DR, je aplikácia pedspracovacích metód na použitej množine obrazov. Rôzne metódy pedspracovania môžu zvýšiť viditeľnosť rôznych prejavov ochorenia očného pozadia. Mnohé z týchto metód pedspracovania obrazu už úspešne boli aplikované v oblasti diagnostiky DR pri klasifikačných modeloch založených na hlbokých neurónových sieťach. Vo všeobecnosti pri klasifikácii DR je náročné určiť najúčinnjšiu metódu pedspracovania. Každá metóda má svoje výhody a nevýhody v závislosti od viacerých vlastností, akými sú rôzne prejavy ochorenia v rôznych štádiách, použitá architektúra CNN, kvalita obrazov v procese učenia – ktorú ovplyvňujú rôzne faktory, ako napr. použitie iného nastavenia fundus kamery, rozlíšenia, meniace sa svetelné podmienky atď. Tento výskum kombinuje tieto dva princípy,

t. j. skupinové učenie a predspracovanie obrazov. Snažili sme sa pomocou nich vylepšiť viacriedny klasifikačný výkon v porovnaní s používaním jedného modelu.

Keďže sme pracovali s viacerými vyhodnocovacími metrikami, naše výsledky ukazujú, že niektoré jednotlivé modely fungovali lepšie v niektorých aspektoch, presnejšie pre správnosti niektorých tried. Ide však o očakávaný výsledok. Výhodou skupinového učenia je, že prináša možnosť nájdania kompromisného riešenia medzi jednotlivými modelmi. Súčasne sa snaží využiť silné stránky jednotlivých modelov a vytvoriť všeobecne silnejší klasifikátor. Z tohto dôvodu z pohľadu nášho výskumu považujeme za najdôležitejšiu výkonnostnú metriku Cohenov kapa koeficient, ktorý vyjadruje celkovú silu klasifikátora v jednej hodnote – pričom zohľadňuje správnosť jednotlivých tried a aj problém nevyváženosti tried. Nami navrhovaný prístup sme overili použitím dvoch architektúr. Vytvorili sme jeden skupinový model založený na architektúre Xception a jeden založený na EfficientNetB4. Obidva boli trénované na piatich rozlične predspracovaných množinách obrazov. Ako techniku fúzie sme použili väčšinové hlasovanie a fúziu založenú na priemernej pravdepodobnosti. Tieto fúzovacie prístupy fungovali veľmi podobne a oba priniesli lepšie výsledky z hľadiska celkovej správnosti a kapa koeficientu v porovnaní s jednotlivými modelmi. Vo väčšine prípadov však fúzia založená na pravdepodobnosti dosiahla lepšie výsledky. Pokiaľ ide o zvolené architektúry, hlavnými rozdielmi boli robustnosť a výpočtová náročnosť. EfficientNetB4 je v porovnaní s Xception hlbší, čo má za následok zvýšenú výpočtovú náročnosť, na druhej strane je vo všeobecnosti považovaný za robustnejší. Avšak, môže sa to líšiť pre iné databázy, iné úlohy. Výber architektúr bol uskutočnený tak, aby bola zachovaná homogenita základnej architektúry v rámci jednej skupiny. Urobili sme to tak preto, aby sme zabezpečili rovnaké podmienky individuálnych modelov pre jednoduchšiu demonštráciu toho, že rozmanitosť a zvýšenú výkonnosť je možné dosiahnuť aj manipuláciou vstupných údajov vo forme predspracovacích metód. Avšak architektúry môžu byť v prípade potreby nahradené inými špecifickými architektúrami podľa individuálnych požiadaviek, napr. veľkosti používanej databázy údajov, dostupnosti výpočtového výkonu a podobne.

Naše skupinové modely prekonali všetky individuálne modely v rámci danej skupiny vzhľadom na Cohenov kapa koeficient. Výsledky porovnania výkonnosti modelov kde základnou architektúrou bola Xception, sa nachádzajú v Tab. 3.4. V prípade databázy APTOS najlepší skupinový model dosiahol priemernú celkovú správnosť 88.36 % a kapa

hodnotu 0.816. Najlepší jedinec skupiny trénovaný na obrazoch RGB-CLAHE, priemerné hodnoty 86.81 % a 0.792. V prípade databázy DDR najlepší skupinový model dosiahol priemernú celkovú správnosť 81.67 % a kappa hodnotu 0.716. Najlepší jedinec skupiny trénovaný na obrazoch, priemerné hodnoty 79.50 % a 0.686. V prípade EfficientNetB4 architektúry, výsledky sa nachádzajú v Tab. 3.5. V prípade databázy APTOS najlepší skupinový model dosiahol priemernú celkovú správnosť 89.90 % a kappa hodnotu 0.841. Najlepší jedinec skupiny trénovaný na obrazoch min-pooling, priemerné hodnoty 88.18 % a 0.814. V prípade databázy DDR najlepší skupinový model dosiahol priemernú celkovú správnosť 82.41 % a kappa hodnotu 0.726. Najlepší jedinec skupiny trénovaný na obrazoch RGB-CLAHE, priemerné hodnoty 81.14 % a 0.710. Tieto výsledky nám naznačujú, že nami navrhovaný skupinový prístup, ktorý kombinuje viaceré metódy predspracovania obrazov je schopný posilniť celkovú klasifikačnú schopnosť modelu. Ak porovnáваме modely z hľadiska použitej architektúry, tak práve EfficientNetB4 bola účinnejšia než Xception – čo bolo v súlade s očakávaniami. Okrem toho McNemarov a McNemar-Bowkerov test nám ukázali, že zlepšenia dosiahnuté navrhovaným skupinovým prístupom sú štatisticky významné, obzvlášť v prípade databázy DDR. V prípade APTOS niektoré testy zlyhali. Tento slabší výkon testov na APTOS v porovnaní s testami na DDR je pravdepodobne spôsobený menším počtom obrazov v databáze APTOS, keďže s menším počtom vzoriek je menšia štatistická sila na zistenie významných rozdielov medzi klasifikátormi. Na druhej strane, aj v tomto prípade bol Cohenov kappa koeficient vyšší v porovnaní s jednotlivcami, čo naznačuje, že náš skupinový model je z celkového hľadiska silnejším klasifikátorom.

Napriek sľubným výsledkom našich skupinových modelov je dôležité poznamenať, že vo všeobecnosti sú výpočtovo nákladné, najmä pri použití viacerých modelov s veľkými architektúrami CNN. Trénovanie takéhoto modelu na pomerne veľkom počte obrazov je časovo náročné, ako nám to ukazujú aj skúsenosti s trénovaním na databáze DDR. Toto obmedzenie sa však dá vyriešiť použitím výkonného hardvéru.

4 Zhodnotenie

V tejto práci sme sa zaoberali hlbokými neurónovými sieťami, ktoré umožňujú automatizovanú klasifikáciu očného ochorenia diabetickej retinopatie. Je to oblasť, ktorej je v súčasnosti venovaná veľká pozornosť vo vedeckej komunite. Ako každá rozvíjajúca sa oblasť, aj táto má svoje medzery a nedostatky na ktorých je možné pracovať a navrhovať lepšie, prípadne alternatívne spôsoby riešenia týchto problémov. Po získaní prehľadu súčasného stavu sme sa rozhodli vytvoriť riešenie pre problém malého množstva dát, ktorý sa často objavuje v prípade medicínskych databáz a zároveň poskytnúť alternatívu klasifikačného nástroja pre mobilné zariadenia. Ako sme si už pripomenuli v sekcii 1.2 Výzvy v klasifikácii DR hlbokými sieťami, problém nedostatku medicínskych dát je možné riešiť alternatívne aj navrhnutím nového CNN modelu, ktorý je vysoko účinný, ale na druhej strane používa menší počet trénovateľných parametrov, čo umožňuje trénovanie na menšom počte dát bez preučenia. Tento cieľ sme splnili pomocou LBCNN siete, ktorá zároveň znižuje pamäťové nároky, čo je veľká výhoda pri výpočtovo limitovaných zariadeniach, akými sú aj mobilné zariadenia. Vývoj skrínigového systému, ktorý vykonáva spoľahlivý skrínig pomocou mobilných zariadení, by tiež predstavovalo posun pre danú oblasť. Je to z toho dôvodu, že súčasný spôsob skrínigu je časovo a finančne náročný, nakoľko štandardne sa vykonáva pomocou stolných fundusových kamier v ordináciách. Tieto kamery sú veľké, drahé a ich premiestnenie nie je jednoduché. Skrínig pomocou mobilných zariadení by na druhej strane umožnil zrýchliť proces snímania a automatizovaný proces vyhodnocovania. V prípade, že je k dispozícii menšia výpočtová sila, LBCNN ponúka kompromisné riešenie.

V druhej časti práce sme sa snažili nájsť spôsob, ktorý je schopný zlepšiť viacriednu klasifikáciu. Z prehľadu sme zistili, že takýchto riešení je nedostatok, a preto sme sa v rámci výskumu snažili vytvoriť riešenie. Náš návrh je založený na skupinovom učení, ktorým sme sa snažili napodobniť efektívnosť tímovej práce ľudí. Treba však poznamenať, že toto riešenie je opakom predchádzajúcej z pohľadu požiadaviek na výpočtovú kapacitu. Z tohto dôvodu, takéto riešenie je vhodné vtedy, ak sa snažíme získať čo najlepšie celkové klasifikačné výsledky, ale výpočtová sila nie je obmedzením – napr. je dostupný na vykonávanie výpočtov server so silnými grafickými kartami. Nami navrhovaný skupinový model je založený na rôznych metódach predspracovania. Týmto spôsobom zabezpečujeme,

aby každý jednotlivý model mal iný pohľad na tie isté dáta. Následne sa ich jednotlivé „názory“ kombinujú, čím získame širokospektrálny pohľad na dáta a následne vyššiu generalizačnú schopnosť. Takýto skupinový model bol schopný prekonať porovnávané klasifikačné modely. Naše experimenty potvrdzujú, že táto metóda je schopná zlepšiť celkovú viactriednu klasifikáciu DR, ktorá je rozhodujúcim krokom pri nasadení účinného skrínového systému pre plánovanie liečby DR a pri hodnotení rizika. V neposlednom rade ponúka riešenie aj pre klasifikovanie obrazov, ktoré boli nekvalitne nasnímané v podobe šiestej klasifikačnej triedy. Tieto obrazy sú veľmi často nesprávne zaradené do zdravej skupiny, čím môžu narušiť proces učenia. Tým, že klasifikátor je schopný triediť aj tieto obrazy, vo finálnej aplikácii je možné odporučiť aj opätovné snímanie z dôvodu „neklasifikovateľnosti“. Tým by sa proces skríningu mohol zjednodušiť aj o tento krok.

4.1 Prínosy dizertačnej práce

- ❖ riešenie problému malého počtu dát na trénovanie CNN
 - návrh a implementácia metódy binárnej klasifikácie s fixnými filtrami na báze LBP a CNN, ktorá významným spôsobom znižuje počet trénovateľných parametrov a tým zlepšuje schopnosť modelu učiť sa z obmedzeného množstva dát
 - zníženie výpočtovej náročnosti znížením počtu trénovateľných parametrov pri zachovaní porovnateľnej klasifikačnej úspešnosti v prípade menších databáz
 - aplikácia a experimentálne overenie funkčnosti LBCNN na klasifikácii ochorenia očného pozadia
 - aplikácia metódy na binárnu klasifikáciu diabetickej retinopatie na obrazoch sietnice s lepšou alebo porovnateľnou úspešnosťou ako súčasné metódy pri výraznom znížení výpočtovej náročnosti
- ❖ výskum metód skupinového učenia pre viactriednu klasifikáciu založených na CNN
 - návrh novej metodiky na zabezpečenie diverzity modelov v skupine; diverzita sa dosahuje trénovaním CNN na obrazoch, ktoré boli predspracované rozličnými metódami
 - návrh a realizácia modelu skupinového učenia novou metodikou a jeho aplikácia na klasifikáciu štádií DR
 - 5-triedna klasifikácia DR podľa ICDRDSS

- 6-triedna klasifikácia DR podľa ICDRDSS s pridaním samostatnej triedy pre nekvalitne nasnímané obrazy
- 3-triedna klasifikácia štandardne používaná lekármi

Vo všetkých prípadoch dosiahli modely skupinového učenia lepšie výsledky v porovnaní s jednotlivými metódami

- návrh a realizácia modelu skupinového učenia dvomi rozdielnymi fúzovacími metódami
 - väčšinové hlasovanie (Hard voting)
 - spájanie výsledných pravdepodobností (Soft voting)

Zoznam použitej literatúry

- [1] JENKINS, Alicia J., Mugdha V. JOGLEKAR, Anandwardhan A. HARDIKAR, Anthony C. KEECH, David N. O'NEAL a Andrzej S. JANUSZEWSKI. Biomarkers in Diabetic Retinopathy. *The Review of Diabetic Studies : RDS* [online]. 2015, **12**(1–2), 159–195. ISSN 1613-6071. Dostupné z: doi:10.1900/RDS.2015.12.159
- [2] FERRIS, F. Early photocoagulation in patients with either type I or type II diabetes. *Transactions of the American Ophthalmological Society*. 1996, **94**, 505–537. ISSN 0065-9533.
- [3] GROSS, Jeffrey G., Adam R. GLASSMAN, Lee M. JAMPOL, Seidu INUSAH, Lloyd Paul AIELLO, Andrew N. ANTOSZYK, Carl W. BAKER, Brian B. BERGER, Neil M. BRESSLER, David BROWNING, Michael J. ELMAN, Frederick L. FERRIS, Scott M. FRIEDMAN, Dennis M. MARCUS, Michele MELIA, Cynthia R. STOCKDALE, Jennifer K. SUN a Roy W. BECK. Panretinal Photocoagulation vs Intravitreal Ranibizumab for Proliferative Diabetic Retinopathy: A Randomized Clinical Trial. *JAMA* [online]. 2015, **314**(20), 2137–2146. ISSN 1538-3598. Dostupné z: doi:10.1001/jama.2015.15217
- [4] CHEW, Emily Y., Walter T. AMBROSIUS, Matthew D. DAVIS, Ronald P. DANIS, Sapna GANGAPUTRA, Craig M. GREVEN, Larry HUBBARD, Barbara A. ESSER, James F. LOVATO, Letitia H. PERDUE, David C. GOFF, William C. CUSHMAN, Henry N. GINSBERG, Marshall B. ELAM, Saul GENUTH, Hertzell C. GERSTEIN, Ulrich SCHUBART a Lawrence J. FINE. Effects of medical therapies on retinopathy progression in type 2 diabetes. *The New England Journal of Medicine* [online]. 2010, **363**(3), 233–244. ISSN 1533-4406. Dostupné z: doi:10.1056/NEJMoa1001288
- [5] BRESSLER, Susan B., Haijing QIN, Michele MELIA, Neil M. BRESSLER, Roy W. BECK, Clement K. CHAN, Sandeep GROVER, David G. MILLER, a DIABETIC RETINOPATHY CLINICAL RESEARCH NETWORK. Exploratory analysis of the effect of intravitreal ranibizumab or triamcinolone on worsening of diabetic retinopathy in a randomized clinical trial. *JAMA ophthalmology* [online]. 2013, **131**(8), 1033–1040. ISSN 2168-6173. Dostupné z: doi:10.1001/jamaophthalmol.2013.4154
- [6] KROPP, Martina, Olga GOLUBNITSCHAJA, Alena MAZURAKOVA, Lenka KOKLESOVA, Nafiseh SARGHEINI, Trong-Tin Kevin Steve VO, Eline DE CLERCK, Jiri POLIVKA, Pavel POTUZNÍK, Jiri POLIVKA, Ivana STETKAROVA, Peter KUBATKA a Gabriele THUMANN. Diabetic retinopathy as the leading cause of blindness and early predictor of cascading complications—risks and mitigation. *The EPMA Journal* [online]. 2023, **14**(1), 21–42. ISSN 1878-5077. Dostupné z: doi:10.1007/s13167-023-00314-8
- [7] ZACHARIAH, Sonia, William WYKES a David YORSTON. Grading diabetic retinopathy (DR) using the Scottish grading protocol. *Community Eye Health*. 2015, **28**(92), 72–73. ISSN 0953-6833.
- [8] SOLOMON, Sharon D., Emily CHEW, Elia J. DUH, Lucia SOBRIN, Jennifer K. SUN, Brian L. VANDERBEEK, Charles C. WYKOFF a Thomas W. GARDNER. Diabetic Retinopathy: A Position Statement by the American Diabetes Association.

- Diabetes Care* [online]. 2017, **40**(3), 412–418. ISSN 0149-5992. Dostupné z: doi:10.2337/dc16-2641
- [9] AMERICAN ACADEMY OF OPHTHALMOLOGY. *International clinical diabetic retinopathy disease severity scale*. [online]. 2002 [vid. 2021-10-01]. Dostupné z: <http://www.icoph.org/downloads/Diabetic-Retinopathy-Scale.pdf>
- [10] INTERNATIONAL COUNCIL OF OPHTHALMOLOGY. *ICO Guidelines for Diabetic Eye Care*. 2017, 40.
- [11] ALGHADYAN, Abdulrahman A. Diabetic retinopathy – An update. *Saudi Journal of Ophthalmology* [online]. 2011, **25**(2), 99–111. ISSN 1319-4534. Dostupné z: doi:10.1016/j.sjopt.2011.01.009
- [12] ASIRI, Norah, Muhammad HUSSAIN, Fadwa AL ADEL a Nazih ALZAIDI. Deep learning based computer-aided diagnosis systems for diabetic retinopathy: A survey. *Artificial Intelligence in Medicine* [online]. 2019, **99**, 101701. ISSN 0933-3657. Dostupné z: doi:10.1016/j.artmed.2019.07.009
- [13] ALYOUBI, Wejdan L., Wafaa M. SHALASH a Maysoon F. ABULKHAIR. Diabetic retinopathy detection through deep learning techniques: A review. *Informatics in Medicine Unlocked* [online]. 2020, **20**, 100377. ISSN 2352-9148. Dostupné z: doi:10.1016/j.imu.2020.100377
- [14] TSIKNAKIS, Nikos, Dimitris THEODOROPOULOS, Georgios MANIKIS, Emmanouil KTISTAKIS, Ourania BOUTSORA, Alexa BERTO, Fabio SCARPA, Alberto SCARPA, Dimitrios I. FOTIADIS a Kostas MARIAS. Deep learning for diabetic retinopathy detection and classification based on fundus images: A review. *Computers in Biology and Medicine* [online]. 2021, **135**, 104599. ISSN 0010-4825. Dostupné z: doi:10.1016/j.combiomed.2021.104599
- [15] M, Aleesha a LASEENA. *MQTT Protocol for Resource Constrained IoT Applications : A Review* [online]. SSRN Scholarly Paper. 2022 [vid. 2023-11-12]. Dostupné z: doi:10.2139/ssrn.4299372
- [16] JUEFEI-XU, Felix, Vishnu Naresh BODDETI a Marios SAVVIDES. Local binary convolutional neural networks. In: *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017* [online]. 2017. ISBN 978-1-5386-0457-1. Dostupné z: doi:10.1109/CVPR.2017.456
- [17] IGNATOV, Andrey, Radu TIMOFTE, Andrei KULIK, Seungsoo YANG, Ke WANG, Felix BAUM, Max WU, Lirong XU a Luc VAN GOOL. AI Benchmark: All About Deep Learning on Smartphones in 2019. *arXiv:1910.06663 [cs]* [online]. 2019 [vid. 2021-11-27]. Dostupné z: <http://arxiv.org/abs/1910.06663>
- [18] TAN, Choon Han, Bhone Myint KYAW, Helen SMITH, Colin S TAN a Loraine TUDOR CAR. Use of Smartphones to Detect Diabetic Retinopathy: Scoping Review and Meta-Analysis of Diagnostic Test Accuracy Studies. *Journal of Medical Internet Research* [online]. 2020, **22**(5), e16658. ISSN 1439-4456. Dostupné z: doi:10.2196/16658
- [19] WINTERGERST, Maximilian W. M., Divyansh K. MISHRA, Laura HARTMANN, Payal SHAH, Vinaya K. KONANA, Pradeep SAGAR, Moritz BERGER, Kaushik MURALI, Frank G. HOLZ, Mahesh P. SHANMUGAM a Robert P. FINGER.

- Diabetic Retinopathy Screening Using Smartphone-Based Fundus Imaging in India. *Ophthalmology* [online]. 2020, **127**(11), 1529–1538. ISSN 1549-4713. Dostupné z: doi:10.1016/j.ophtha.2020.05.025
- [20] RAJALAKSHMI, Ramachandran, Subramanian ARULMALAR, Manoharan USHA, Vijayaraghavan PRATHIBA, Khaji Syed KAREEMUDDIN, Ranjit Mohan ANJANA a Viswanathan MOHAN. Validation of Smartphone Based Retinal Photography for Diabetic Retinopathy Screening. *PLOS ONE* [online]. 2015, **10**(9), e0138285. ISSN 1932-6203. Dostupné z: doi:10.1371/journal.pone.0138285
- [21] HOWARD, Andrew G., Menglong ZHU, Bo CHEN, Dmitry KALENICHENKO, Weijun WANG, Tobias WEYAND, Marco ANDREETTO a Hartwig ADAM. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv:1704.04861 [cs]* [online]. 2017 [vid. 2021-12-10]. Dostupné z: <http://arxiv.org/abs/1704.04861>
- [22] ZHANG, Xiangyu, Xinyu ZHOU, Mengxiao LIN a Jian SUN. *ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices* [online]. arXiv: 1707.01083. 2017 [vid. 2023-10-11]. Dostupné z: doi:10.48550/arXiv.1707.01083
- [23] IANDOLA, Forrest N., Song HAN, Matthew W. MOSKEWICZ, Khalid ASHRAF, William J. DALLY a Kurt KEUTZER. *SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size* [online]. arXiv: 1602.07360. 2016 [vid. 2023-10-11]. Dostupné z: doi:10.48550/arXiv.1602.07360
- [24] MACSIK, Peter, Jarmila PAVLOVICOVA, Jozef GOGA a Slavomir KAJAN. Local Binary CNN for Diabetic Retinopathy Classification on Fundus Images. *Acta Polytechnica Hungarica* [online]. 2022, **19**(7), 27–45. ISSN 17858860, 20642687. Dostupné z: doi:10.12700/APH.19.7.2022.7.2
- [25] EYEPACS. *Diabetic Retinopathy Detection - Kaggle* [online]. 2015 [vid. 2021-01-27]. Dostupné z: <https://www.kaggle.com/c/diabetic-retinopathy-detection>
- [26] ARAVIND EYE HOSPITAL. *APTOS 2019 Blindness Detection* [online]. [vid. 2021-09-18]. Dostupné z: <https://kaggle.com/c/aptos2019-blindness-detection>
- [27] KAJAN, Slavomír, Jozef GOGA, Kristián LACKO a Jarmila PAVLOVIČOVÁ. Detection of Diabetic Retinopathy Using Pretrained Deep Neural Networks. 2020.
- [28] JUEFEI-XU, Felix a Marios SAVVIDES. Weight-Optimal Local Binary Patterns. In: Lourdes AGAPITO, Michael M. BRONSTEIN a Carsten ROTHER, ed. *Computer Vision - ECCV 2014 Workshops* [online]. Cham: Springer International Publishing, 2015, s. 148–159. Lecture Notes in Computer Science. ISBN 978-3-319-16181-5. Dostupné z: doi:10.1007/978-3-319-16181-5_11
- [29] YANG, Dandi, Cristhian MARTINEZ, Lara VISUÑA, Hardev KHANDHAR, Chintan BHATT a Jesus CARRETERO. Detection and analysis of COVID-19 in medical images using deep learning techniques. *Scientific Reports* [online]. 2021, **11**(1), 19638. ISSN 2045-2322. Dostupné z: doi:10.1038/s41598-021-99015-3
- [30] LI, Tao, Yingqi GAO, Kai WANG, Song GUO, Hanruo LIU a Hong KANG. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening.

- Information Sciences* [online]. 2019, **501**, 511–522. ISSN 0020-0255. Dostupné z: doi:10.1016/j.ins.2019.06.011
- [31] COHEN, Jacob. A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement* [online]. 1960, **20**(1), 37–46. ISSN 0013-1644, 1552-3888. Dostupné z: doi:10.1177/001316446002000104
- [32] MCHUGH, Mary. Interrater reliability: The kappa statistic. *Biochemia medica : časopis Hrvatskoga društva medicinskih biokemičara / HDMB* [online]. 2012, **22**, 276–82. Dostupné z: doi:10.11613/BM.2012.031
- [33] FLEISS, Joseph L. a Jacob COHEN. The equivalence of weighted kappa and the intraclass correlation coefficient as measures of reliability. *Educational and Psychological Measurement* [online]. 1973, **33**(3), 613–619. ISSN 1552-3888. Dostupné z: doi:10.1177/001316447303300309
- [34] COHEN, Jacob. Weighted kappa: Nominal scale agreement provision for scaled disagreement or partial credit. *Psychological Bulletin* [online]. 1968, **70**(4), 213–220. ISSN 1939-1455, 0033-2909. Dostupné z: doi:10.1037/h0026256
- [35] WARRENS, Matthijs J. Weighted kappa is higher than Cohen's kappa for tridiagonal agreement tables. *Statistical Methodology* [online]. 2011, **8**(2), 268–272. ISSN 1572-3127. Dostupné z: doi:10.1016/j.stamet.2010.09.004
- [36] HE, Along, Tao LI, Ning LI, Kai WANG a Huazhu FU. CABNet: Category Attention Block for Imbalanced Diabetic Retinopathy Grading. *IEEE Transactions on Medical Imaging* [online]. 2021, **40**(1), 143–153. ISSN 1558-254X. Dostupné z: doi:10.1109/TMI.2020.3023463
- [37] KASSANI, Sara Hosseinzadeh, Peyman Hosseinzadeh KASSANI, Reza KHAZAEINEZHAD, Michal J. WESOLOWSKI, Kevin A. SCHNEIDER a Ralph DETERS. Diabetic Retinopathy Classification Using a Modified Xception Architecture. In: *2019 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT): 2019 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)* [online]. 2019, s. 1–6. ISSN 2641-5542. Dostupné z: doi:10.1109/ISSPIT47144.2019.9001846
- [38] TAUFIQURRAHMAN, Shidqie, Astri HANDAYANI, Beni Rio HERMANTO a Tati Latifah Erawati Rajab MENGKO. Diabetic Retinopathy Classification Using A Hybrid and Efficient MobileNetV2-SVM Model. *2020 IEEE Region 10 International Conference (TENCON)* [online]. 2020, 235–240. Dostupné z: doi:10.1109/TENCON50793.2020.9293739
- [39] BODAPATI, Jyostna Devi, Veeranjanyulu NARALASETTI, Shaik Nagur SHAREEF, Saqib HAKAK, Muhammad BILAL, Praveen Kumar Reddy MADDIKUNTA a Ohyun JO. Blended Multi-Modal Deep ConvNet Features for Diabetic Retinopathy Severity Prediction. *Electronics* [online]. 2020, **9**(6), 914. Dostupné z: doi:10.3390/electronics9060914
- [40] MAJUMDER, Sharmin a Nasser KEHTARNAVAZ. Multitasking Deep Learning Model for Detection of Five Stages of Diabetic Retinopathy. *IEEE Access* [online]. 2021, **9**, 123220–123230. ISSN 2169-3536. Dostupné z: doi:10.1109/ACCESS.2021.3109240

- [41] KOBAT, Sabiha Gungor, Nursena BAYGIN, Elif YUSUFOGLU, Mehmet BAYGIN, Prabal Datta BARUA, Sengul DOGAN, Orhan YAMAN, Ulku CELIKER, Hakan YILDIRIM, Ru-San TAN, Turker TUNCER, Nazrul ISLAM a U. Rajendra ACHARYA. Automated Diabetic Retinopathy Detection Using Horizontal and Vertical Patch Division-Based Pre-Trained DenseNET with Digital Fundus Images. *Diagnostics (Basel, Switzerland)* [online]. 2022, **12**(8), 1975. ISSN 2075-4418. Dostupné z: doi:10.3390/diagnostics12081975
- [42] MONDAL, Sambit S., Nirupama MANDAL, Krishna Kant SINGH, Akansha SINGH a Ivan IZONIN. EDLDR: An Ensemble Deep Learning Technique for Detection and Classification of Diabetic Retinopathy. *Diagnostics* [online]. 2023, **13**(1), 124. ISSN 2075-4418. Dostupné z: doi:10.3390/diagnostics13010124

Príloha A: Účasť na projektoch

- AI4EYE – Podpora diagnostiky v oftalmológii metódami umelej inteligencie / AI4EYE AI Supported Diagnostics in Ophthalmology, grant APVV-22-0606
- AIDabiomeDIA – Umelá inteligencia vo vývoji pokročilých metód biometrie a medicínskej diagnostiky (AIDabiomeDIA – AI in Development of Advanced Biometrics and Medicine Diagnostics), grant of the Slovak scientific grant agency VEGA 1/0202/23, 2023-2025
- Artificial Intelligence in Medicine and Digital Cultures (AIMeDiC) – Internal FEI STU project to support young excellent research teams, 2022-23-04
- Medzinárodné centrum excelentnosti pre výskum inteligentných a bezpečných informačno-komunikačných technológií a systémov – II. etapa, Kód ITMS: 313021W404, spolufinancovaný zo zdrojov Európskeho fondu regionálneho rozvoja, 2019-2023 / International Center of Excellence for Research on Intelligent and Secure Information and Communication Technologies and Systems – II. stage, ITMS code: 313021W404, co-financed by the European Regional Development Fund, 2019-2023

Príloha B: Zoznam publikácií autora

MÁCSIK, Péter – PAVLOVIČOVÁ, Jarmila – GOGA, Jozef – KAJAN, Slavomír. Local binary CNN for diabetic retinopathy classification on fundus images. In Acta Polytechnica Hungarica. Vol. 19, no. 7 (2022), s. 27-45. ISSN 1785-8860. <https://doi.org/10.12700/APH.19.7.2022.7.2> (2021: 1.711 – IF, Q3 – JCR Best Q, 0.353 – SJR, Q2 – SJR Best Q). V databáze: SCOPUS: 2-s2.0-85134760810.

Počet citácií: Google Scholar – 12, SJR – 10

MÁCSIK, Péter – PAVLOVIČOVÁ, Jarmila – GOGA, Jozef – KAJAN, Slavomír – KURILOVÁ, Veronika. Image Preprocessing Based Ensemble Deep Learning Classification of Diabetic Retinopathy. In IET Image Processing. 00, 1-22 (2023). ISSN 1751-9659. <https://doi.org/10.1049/ipr2.12987> (2022: 2.3 – IF, Q3 – JCR Best Q, 0.514 – SJR, Q2 – SJR Best Q).

(Článok prijatý na publikovanie)

KAJAN, Slavomír – MÁCSIK, Péter – KÖRÖSI, Ladislav – GOGA, Jozef – PAVLOVIČOVÁ, Jarmila. Comparison of neural models for modeling dynamic changes in microgrids. In 2022 Cybernetics & Informatics (K&I) [elektronický zdroj] : Proceedings ; 31st International Conference; 11-14 September 2022 Visegrád, Maďarsko. 1. vydanie. Danvers, Massachusetts, USA : IEEE, 2022, [5] s. ISBN 978-1-6654-8774-0.

GOGA, Jozef – PAVLOVIČOVÁ, Jarmila – ORAVEC, Miloš – RÁBEKOVÁ, Zuzana – MÁCSIK, Péter. Laserové podpovrchové gravírovanie trojrozmernej sochy do krištáľového skla rozložením referenčného obrazu na základné geometrické tvary: prihláška úžitkového vzoru č. 50012-2023, dátum podania prihlášky: 23.02.2023, dátum zverejnenia prihlášky: 14. 6. 2023, Úžitkový vzor č. 9876, dátum oznámenia o sprístupnení dokumentu: 11. 10. 2023, Vestník ÚPV SR č.: 19/2023. Banská Bystrica : Úrad priemyselného vlastníctva SR, 2023. 9 s.