

**Technická univerzita v Košiciach
Fakulta elektrotechniky a informatiky**

**Segmentácia diabetických kožných vredov
využitím plne konvolučnej siete**

Diplomová práca

2023

Bc. Valentín Krigovský

**Technická univerzita v Košiciach
Fakulta elektrotechniky a informatiky**

**Segmentácia diabetických kožných vredov
využitím plne konvolučnej siete**

Diplomová práca

Študijný program: Informatika
Študijný odbor: 9.2.1. Informatika
Školiace pracovisko: Katedra počítačov a informatiky (KPI)
Školiteľ: prof. Ing. Peter Drotár, PhD.

Košice 2023

Bc. Valentín Krigovský

Abstrakt v SJ

Táto diplomová práca sa zaoberá využitím neurónových sietí na segmentáciu rán na fotografiách diabetických kožných vredov. Cieľom práce je najskôr preskúmať problémy spojené s touto chorobou a nájsť spôsoby, ako by segmentácia rán mohla pomôcť s detekciou, sledovaním a liečbou tohto ochorenia. Práca sa potom zameriava na moderné metódy segmentácie, konkrétne na prácu s neurónovou sieťou nnU-Net a porovnávanie jej výhod oproti iným metódam. Taktiež budú analyzované existujúce riešenia na odhalenie úspešných a neúspešných prístupov. V praktickej časti práce budú implementované a porovnané rôzne prístupy na dosiahnutie optimálnej segmentácie. V tejto časti budú detailne popísané použité modely, algoritmy, augmentácie, evalvačné metriky a dáta. Zameriame sa prevažne na vylepšenie neurónovej siete nnU-Net. V záverečnej časti sú obsiahnuté poznatky a nápady na využitie tejto práce do budúcnosti.

Kľúčové slová v SJ

Lekárske snímky, NnU-Net, Diabetické vredy na nohách, Neuronové siete, Sémantická segmentácia

Abstrakt v AJ

This thesis focuses on utilizing neural networks for wound segmentation in diabetic foot ulcer photographs. The aim of this work is to first investigate the issues associated with this disease and find ways in which wound segmentation could aid in its detection, monitoring, and treatment. The work then focuses on modern segmentation methods, specifically working with the nnU-Net neural network and comparing its advantages to other methods. Existing solutions will also be analyzed to reveal successful and unsuccessful approaches. In the practical part of the work, various approaches will be implemented and compared to achieve optimal segmentation. This section will provide detailed descriptions of the models, algorithms, augmentations, evaluation metrics, and data used. We will focus primarily on optimizing neural net called nnU-Net. The final section will contain insights and ideas for the future utilization of this work.

Kľúčové slová v AJ

Medical images, NnU-Net, Diabetic foot ulcers, Neural networks, Semantic segmentation

Bibliografická citácia

KRIGOVSKÝ, Valentín. *Segmentácia diabetických kožných vredov využitím plne konvolučnej siete*. Košice: Technická univerzita v Košiciach, Fakulta elektrotechniky a informatiky, 2023. 51s. Vedúci práce: prof. Ing. Peter Drotár, PhD.

TECHNICKÁ UNIVERZITA V KOŠICIACH
FAKULTA ELEKTROTECHNIKY A INFORMATIKY
Katedra počítačov a informatiky

ZADANIE
DIPLOMOVEJ PRÁCE

Študijný odbor: **Informatika**

Študijný program: **Informatika**

Názov práce:

**Segmentácia diabetických kožných vredov využitím plne
konvolučnej siete**

Diabetic Foot Ulcer Segmentation Based on Fully Convolutional Network

Študent: **Bc. Valentín Krigovský**

Školiteľ: **prof. Ing. Peter Drotár, PhD.**

Školiace pracovisko: **Katedra počítačov a informatiky**

Konzultant práce:

Pracovisko konzultanta:

Pokyny na vypracovanie diplomovej práce:

1. Analyzovať metódy pre sémantickú segmentáciu medicínskych obrazov.
2. Navrhnuť model pre segmentáciu diabetických kožných vredov.
3. Navrhnuť prístupy pre zlepšenie segmentácie na báze attention mechanizmu a pokročilých augmentácií.
4. Experimentálne vyhodnotiť navrhnuté prístupy.

Jazyk, v ktorom sa práca vypracuje: slovenský

Termín pre odovzdanie práce: 21.04.2023

Dátum zadania diplomovej práce: 31.10.2022



prof. Ing. Liberios Vokorokos, PhD.
dekan fakulty

Čestné vyhlásenie

Vyhlasujem, že som záverečnú prácu vypracoval(a) samostatne s použitím uvedenej odbornej literatúry.

Košice, 19.4.2023

.....

Vlastnoručný podpis

Podakovanie

Na tomto mieste by som rád poďakoval svojmu vedúcemu práce prof. Ing. Petrovi Drotárovi, PhD. za jeho čas, odborné vedenie a cenné rady počas riešenia mojej záverečnej práce.

Rovnako by som sa rád poďakoval svojim rodičom a priateľom za ich podporu a povzbudzovanie počas celého môjho štúdia.

Obsah

Úvod	1
1 Diabetické vredy chodidiel: Medicínska perspektíva	3
1.1 Vznik a klasifikácia vredov diabetickej nohy	3
1.2 Prevencia a liečba vredov diabetickej nohy	4
1.3 Vizualne chápanie vredov diabetickej nohy	6
1.4 Výhody segmentácie DFU	7
2 Sémantická segmentácia DFU: Techniky a prístupy	9
2.1 U-Net pre segmentáciu DFU	9
2.2 NnU-Net pre segmentáciu DFU	11
2.3 Mixup Augmentácia pre segmentáciu DFU	14
2.4 Reziduálne spojenia pre segmentáciu DFU	15
2.5 Mechanizmy pozornosti pre segmentáciu DFU	16
2.5.1 Kanálová pozornosť	16
2.5.2 Priestorová pozornosť	17
2.5.3 Zmiešaná pozornosť	18
3 Zlepšenie výkonu siete nnU-Net pomocou architektonických inovácií a dátových augmentácií: Experimenty	20
3.1 Charakteristiky a použitie súborov údajov DFU	20
3.2 Metriky hodnotenia pre segmentáciu DFU	22
3.3 Základný model pre segmentáciu DFU	24
3.3.1 Predspracovanie dát	24
3.3.2 Parametre a postup tréningu	25
3.4 Implementácia pokročilých augmentácií	26
3.5 Implementácia reziduálnych spojení	28
3.6 Implementácia mechanizmov pozornosti	29
3.6.1 Priestorová pozornosť	30
3.6.2 Kanálová pozornosť	30

3.6.3	Zmiešaná pozornosť	32
3.6.4	Porovnanie výkonnosti mechanizmov pozornosti: Experimenty a výsledky	33
3.7	Porovnanie výkonnosti navrhnutých architektúr nnU-Net	33
3.7.1	Krivky učenia pri DFU tréningu	35
3.8	Následné spracovanie výsledkov segmentácie	36
3.9	Hľadanie správnej funkcie chyby	37
3.10	Architektúra najúspešnejšieho modelu	38
4	Záver	44
	Literatúra	46
	Zoznam príloh	52

Zoznam obrázkov

1.1	DFU pred a po odstránení kalusu [7]. Po odstránení tkaniva by sa mal vred presondovať sterilným tupým nástrojom, aby sa určilo postihnutie základných štruktúr, ako sú šľacha, kĺbové puzdro alebo kosť [6]. Mali by sa získať röntgenové snímky, aby sa zistilo, či sa v mäkkých tkanivách nenachádza vzduch alebo cudzie telesá, a aby sa vyhodnotil vred z hľadiska postihnutia kosti, pretože to môže spôsobiť ďalšie vážne komplikácie [6].	6
1.2	Miesta najčastejšieho výskytu DFU [7].	6
1.3	Proces vyrezávania diery do špeciálnej podrážky. Časovo náročné je, ako obkreslenie rany, tak aj jej manuálne vyrezanie	8
2.1	Stratégia prekrývania dlaždíc [14]. Na obrázku je možné vidieť aj doplnené zrkadlenie na okrajovom regióne (región medzi žltou a modrou čiarou), ktoré pomáha doplniť kontext pre predikciu. Vďaka rozdeleniu je možné predikciu spúšťať na obrázkoch rôznych veľkostí	10
2.2	Architektúra siete U-net [14].	11
2.3	Diagram nnU-Netu. Je možné vidieť, že niektoré parametre má zadefinované fixne, iné sú určené automaticky podľa množstva faktorov, ako napr. limit GPU, modalita obrázkov, ich rozmerov atď.	13
2.4	Krátke alebo "reziduálne" preskakované spojenia. Na rozdiel od dlhých sú pripočítavané po vertikálnej ceste siete medzi vrstvami.	15
2.5	Squeeze and excitation blok	17
2.6	Proces výpočtu AG [31]. Príznaky (x_1) z preskakovaných spojení sú vynásobené koeficientmi vypočítanými v AG. Koeficienty AG sú vypočítané súčtom preskakovaných spojení a vstupov z nižšej vrstvy (g), následne aplikovanej ReLU funkcii, konvolúcii a sigmoid funkcii.	18
2.7	Kanálová pozornosť v CBAM moduli [27].	19

2.8	Priestorová pozornosť v CBAM moduli [27].	19
3.1	Príklad pravdepodobne chybných masiek pre snímky FUSeg. Prvé dve zľava podľa masky nemajú vred, no podľa snímky je očividne prítomný. Tretia maska zľava má nesprávne označený ľavý vred.	21
3.2	Štatistiky počtu rán rôznych veľkostí v súbore údajov DFUC2022 [36].	22
3.3	Prehľad niektorých snímkov nového súboru dát. Obsahuje rany každého typu. Zľava idú typy: neuropatický, ischemický a neuraischemický. Úplne napravo je možné vidieť, že niektoré rany je ne-skúseným človekom ťažké rozoznať od zdravej pokožky.	22
3.4	Príklad dynamicky vygenerovaných obrázkov po mixup augmentácii na jednej dávke o veľkosti 10. V tomto prípade bol λ parameter blízko 0.5, pretože je pomerne zreteľne vidno obidva obrázky. Obrázky majú nerealisticky vyzerajúce farby pre ľudské oko, pretože sú už predspacované.	27
3.5	Príklad dynamicky vygenerovaných obrázkov po cutmix augmentácii na jednej dávke o veľkosti 10.	27
3.6	Spriemerované mapy vlastností obrázka v každej vrstve pred pripočítaním reziduálnych spojení (hore), a po pripočítaní reziduálnych spojení (dole).	29
3.7	Vybrané 2 kanály z preskakovaných spojení (vľavo), koeficienty z priestorovej pozornosti (v strede), a výsledok koeficientov priestorovej pozornosti aplikovanej na preskakované spojenia. Z obrázka je možné potvrdiť správne fungovanie mechanizmu, lebo zatiaľ čo zvýrazňuje ranu, potláča okolie.	30
3.8	Vizualizácia niektorých kanálov produkovaných nnU-netom po tretej vrstve kontrakčnej cesty.	32
3.9	Krivky učenia pri 1000 epochách. Vľavo hore nnU-Net Skip CBAM, vpravo hore nnU-Net Skip CBAM mixup, vľavo dole nnU-Net Skip SE down, AG up, a vpravo dole nnU-Net Skip SE down, AG up s mixupom.	36
3.10	Obrázok vľavo, segmentačná maska v strede a segmentačná maska po vyplnení dier vpravo.	37
3.11	Architektúra nami navrhnutého najúspešnejšieho modelu pre DFU.	39
3.12	Porovnanie predikcie modelu s GT s veľmi nízkym DSC	41
3.13	Porovnanie predikcie modelu s DSC skóre v rozmedzí 0.6 - 0.8.	42
3.14	Porovnanie predikcie modelu s DSC skóre väčším, ako 0.9.	43

Zoznam tabuliek

1.1	Porovnanie troch základných typov DFU z hľadiska pôvodu [7]. Z tejto tabuľky je možné vyčítať, že vzhľad DFU môže byť rôznorodý. Pri týchto typoch sa z vizuálneho hľadiska líši farba rany, okolie aj jej umiestnenie.	4
2.1	Fixné parametre nnU-Net, ktoré sa preukázali ako účinné naprieč širokou škálou datasetov. To však neznamená že ich zmenenie nezlepší výsledok na konkrétny dataset.	13
3.1	Parametre dát a modelu pri trénovaní základného modelu.	25
3.2	Augmentácie, ich stručný popis a parametre pri základnom modeli nnUnetTrainerV2	25
3.3	Porovnanie efektivity mixup augmentácii. Z výsledkov je jasné, že experimentovanie s tresholdom je dôležité. Rozdiely v tejto tabuľke vyzerajú ako zanedbateľné, no po natrénovaní na 1000 epoch namiesto 100 a evalvácii na väčšom množstve dát sa tieto rozdiely prehĺbia.	28
3.4	Porovnanie reziduálnych spojení s baseline a mixup modelom. Podľa výsledkov je možné predpokladať, že modelu s reziduálnymi spojeniami signifikantne napomáha aj mixup augmentácia.	29
3.5	Porovnanie efektivity pridaných pozornosťných modulov do architektúry nnU-Netu. Skratka enc. znamená blok pridaný do kontrakčnej časti, a dec. znamená blok pridaný do expanzívnej časti. Dôležité je poznamenať, že tieto výsledky nie je možné porovnávať s inými tabuľkami v tejto práci, pretože modely boli trénované na všetkých trénovacích dátach a testované na inej vzorke dát (oficiálne testovacie dáta pre DFU 2022 segmentation challenge.) . . .	33
3.6	Finálne výsledky najlepších modelov	34
3.7	Porovnanie výsledkov následného spracovania najlepšieho modelu.	37

3.8 Porovnanie funkcií chyby na najlepšom modeli 38

Úvod

Ročný výskyt diabetických vredov na nohách, skratkou nazývaných DFU, bol v roku 2017 odhadovaný na rozmedzí 9,1 až 26,1 milióna prípadov [1]. Skratka DFU z angličtiny znamená Diabetic Foot Ulcers a označuje vrede na nohách pacientov s cukrovkou. Keďže ročne stúpa počet ľudí s cukrovkou, vieme predpokladať, že s týmto číslom bude rásť aj počet pacientov s DFU.

Výskyt DFU môže spôsobiť značné komplikácie vo forme infekcie, amputácií, a v neposlednom rade aj smrti. Čím neskôr je tento problém odhalený, tým viac stúpa časová aj cenová náročnosť liečby. Včasné odhalenie problému je dôležitým spôsobom, ako sa vyhnúť komplikáciám, preto je dôležitá edukácia pacienta a častá preventívna kontrola u lekára.

Sémantická segmentácia DFU má potenciál včasne diagnostikovať ochorenie a mierne znížiť tlak na lekára. Segmentáciou rán by bolo možné nie len odhaliť problém, ale taktiež sledovať vývoj rany napríklad aplikáciou v telefóne, ktorá by mohla každodenne porovnávať obsah rany zo segmentácie. Ďalším možným prínosom môže byť aj napríklad zjednodušenie vyrezávania diery do špeciálnych podrážok zameraných na zníženie tlaku na ranu pri chôdzi, keďže tento proces je v súčasnosti časovo náročný.

Využitie týchto technológií v praxi má potenciál zabrániť eskalácii tohto ochorenia, najmä v krajinách trpiacich nedostatkom lekárov.

Cieľom práce bude navrhnúť metódu na segmentáciu DFU, ktorá bude čo najpresnejšie segmentovať DFU z medicínskych obrazov.

V prvej časti zanalyzujeme problém ochorenia DFU, spôsoby diagnostiky, liečby a prevencie. Nadobudnuté poznatky použijeme na analýzu potenciálu nápomocnosti segmentácie v modernej medicíne. Následne opíšeme teoretické koncepty neurónových sietí určených na sémantickú segmentáciu, analýzu úspešných modifikácií architektúr a postupov na segmentáciu medicínskych obrazov. Dôraz bude kladený na nnU-Net, jednu z najúspešnejších neurónových sietí postavenú na koncepte U-netu, využívanej na širokú škálu medicínskych segmentačných problémov a dát.

V praktickej časti sa zameriame na vylepšenie siete pomocou mechanizmov pozornosti, pokročilých augmentácií a ďalších úprav modelu a výsledky porovnáme so základným, neupraveným nnU-Net modelom za účelom nájsť najlepšiu architektúru na čo najpresnejšiu segmentáciu DFU. Na konci sa zameriame na zisťovanie príčin falošných pozitív a negatív na predikovaných obrázkoch za účelom odhalenia slabých stránok modelu.

1 Diabetické vredy chodidiel: Medi- cínska perspektíva

DFU sú rozšíreným a vážnym problémom pacientov trpiacich cukrovkou (po latinsky diabetes mellitus), a prevažne medzi ľuďmi z chudobnejších pomerov. Vďaka nadobudnutiu bližších poznatkov o tomto ochorení budeme schopní lepšie identifikovať potencionálny prínos tejto práce, a taktiež pochopiť, ako tieto ochorenia vyzerajú, v ktorých prípadoch je klasifikácia DFU náročná, a zamerať sa na riešenie problémových dát.

V roku 2014 bol celosvetový odhad na ľudí trpiacich diabetes 422 miliónov [2]. Toto číslo časom pomerne prudko rastie. Dôkazom je aj zdvojnásobenie globálnej prevalencie pacientov z roku 1980 - 4.7% a 2014 - 8.5% [2]. 6.3% diabetikov trpí DFU. Následky choroby sú veľmi vážne. Pacienti s DFU majú 2.5 krát vyššiu úmrtnosť než diabetici bez DFU [3]. Viac než polovica z týchto rán vyústi do infekcie, a 20% infekcií vyústi do amputácie [4]. V porovnaní s bežným pacientom s cukrovkou je pacientov s DFU viac mužov, za čím môže byť vysoká fyzická záťaž, ktorá môže načať ranu. Náchylnejší sú pacienti s cukrovkou typu 2 než s cukrovkou typu 1, avšak iba o niečo viac než 1%. Ďalším zaujímavým faktom je, že pacienti s DFU majú nižšie priemerné BMI než pacienti bez DFU [5].

1.1 Vznik a klasifikácia vredov diabetickej nohy

Za vznikom DFU môže stáť viacero faktorov. Medzi časté rizikové faktory patrí diabetická neuropatia [6], inak povedané poškodenie nervov, ktoré sa prejavuje stratením citlivosti, a to má za následok neopatrnosť pacienta v danej oblasti a nevšimavosť zranenia. Ďalšou častou príčinou je štrukturálna deformita chodidla [6], ktorá spôsobuje nerovnomerné rozloženie váhy na chodidlo a tým zvyšuje riziko opotrebovania pokožky. V neposlednom rade periférna arteriálna okluzívna choroba [6], ochorenie tepien, ktoré spôsobuje ich zúženie, následkom čoho vznikne nepomer medzi požiadavkou tkanív na dodávku živín a možnosťou tepny

tieto nároky pre zúženie plní. To je jedným z dôvodov, prečo sa rany diabetikov líšia od rán ľudí nepostihnutých týmito ochorením. Nedostatočný prísun krvi a živín rapídne spomaľuje liečbu rany. Rana sa rozširuje skôr než sa stíha hojiť. Nízka citlivosť chodidla napomáha ranu nešetriť. Ak pacient trpí týmito problémami, je pomerne vysoká pravdepodobnosť, že u neho nastane DFU. Ďalšími nápomocnými faktormi môže byť slabá hygiena, slabá starostlivosť o nechty a nepohodlná obuv, ktorá môže spôsobiť zranenie alebo opotrebovanie chodidla alebo zvýšiť riziko infekcie [6].

DFU je možné rozdeliť do troch kategórií z hľadiska príčiny. Neuropatické, ischemické a neuroischemické. Nižšie uvedená tabuľka 1.1 priblíži rozdiely medzi týmito kategóriami.

Charakteristika	Neuropatická	Ischemická	Neuroischemická
Pocit	Strata citlivosti	Bolestivé	Čiastočná strata zmyslov
Kalus/nekróza	Kalus prítomný a často hrubý	Nekróza	Minimálny kalus, náklonnosť k nekróze
Lôžko rany	Ružové a granulované, obklopené kalusom	Bledé a vláčne s chudobnou granuláciou	Slabá granulácia
Teplota chodidla a pulzovanie	Teplé chodidlo a pulzovanie	Chladné chodidlo bez pulzovania	Chladné chodidlo bez pulzovania
Prevalencia	35%	15%	50%
Ďalšie	Suchá a praskajúca pokožka	Oneskorené hojenie	Vysoké riziko infekcie
Miesto výskytu	Zaťažované oblasti chodidiel, ako je metatarzálna hlava, päta a nad chrbtom chodidla pazúrovité prsty na nohách	Končeky prstov na nohách, okraje nechtov, medzi prstami na nohách a bočné okraje chodidla	Okraje chodidla a palcov

Tabuľka 1.1: Porovnanie troch základných typov DFU z hľadiska pôvodu [7]. Z tejto tabuľky je možné vyčítať, že vzhľad DFU môže byť rôznorodý. Pri týchto typoch sa z vizuálneho hľadiska líši farba rany, okolie aj jej umiestnenie.

1.2 Prevencia a liečba vredov diabetickej nohy

Experti sa zhodujú, že liečba DFU je síce veľmi náročná, no prevencia je pomerne jednoduchá. Prvým krokom prevencie je starostlivosť o samotnú cukrovku (správna diéta, pohyb a dávkovanie inzulínu). Druhým krokom je zabránenie poškodeniu

chodidla nosením mäkkej a priedušnej obuvi, opatrnosti pri chôdzi a zabráneniu zafaženia chodidla. V neposlednom rade je potrebné dbať o hygienu chodidla (čistenie, čisté ponožky a korektné strihanie nechtov). Informovanosť lekárov o problémoch s chodidlami u diabetických pacientov, klinické vyšetrenie, pravidelná prehliadka chodidiel, edukácia pacienta, jednoduché hygienické postupy a zabezpečenie vhodnej obuvi v kombinácii s rýchlym ošetrením drobných poranení môžu znížiť výskyt vredov až o 50% [8].

Množstvo zdrojov uvádza, že pacienti by si mali kontrolovať rany na dennej báze. Odborníci by mali prezrieť, či obuv pacienta nemôže zvyšovať riziko tvorby vredu, a v prípade odhalenia rizika, odporučiť pacientovi špeciálnu obuv, ktorá pomáha správne rozložiť tlak na chodidlá [6].

Hlavným cieľom liečby DFU je čo najrýchlejšie uzavretie rany a zabránenie amputácii [9]. Podľa typu a vážnosti DFU sa liečba môže líšiť. Medzi základné liečebné postupy patrí:


1. Pravidelné zbavovanie pacienta poškodeného a odumretého tkaniva v okolí rany, až kým nie je odhalený zdravý, krvácajúci okraj rany [6]. Následkom toho sa zníži tlak na ranu, zvýši intenzita účinkov rôznych liečivých roztokov a pomáha odhaliť ďalšie poškodenia [7].
2. Znižovanie tlaku na chodidlo špeciálnou obuvou alebo podrážkou, prípadne úplne odstránenie tlaku použitím invalidného vozíka.
3. Pri infekciách je dôležitá antibiotická liečba [9].
4. Hyperbarická kyslíková terapia, ktorá spočíva v dýchaní čistého kyslíka v stlačenej komore na urýchlenie hojenia [10].
5. Náhrady kože, ktoré sa môžu aplikovať na vredy na podporu hojenia. Môžu byť vyrobené z živočíšneho alebo ľudského tkaniva alebo syntetických materiálov [11].
6. Operácia: V niektorých prípadoch môže byť potrebný chirurgický zákrok na odstránenie infikovaného tkaniva alebo vo vážnych prípadoch amputácia [9].



Obr. 1.1: DFU pred a po odstránení kalusu [7]. Po odstránení tkaniva by sa mal vred presondovať sterilným tupým nástrojom, aby sa určilo postihnutie základných štruktúr, ako sú šľacha, kĺbové puzdro alebo kosť [6]. Mali by sa získať röntgenové snímky, aby sa zistilo, či sa v mäkkých tkanivách nenachádza vzduch alebo cudzie telesá, a aby sa vyhodnotil vred z hľadiska postihnutia kosti, pretože to môže spôsobiť ďalšie vážne komplikácie [6].

1.3 Vizuálne chápanie vredov diabetickej nohy

Je dôležité si uvedomiť, že DFU sa vyskytuje na miestach, kde je opakovane vyvíjaný tlak na chodidlo. Obrázok 1.2 tieto miesta znázorňuje.



Obr. 1.2: Miesta najčastejšieho výskytu DFU [7].

Pri liečbe rany je potrebné odstrániť odumreté tkanivo, pod ktorým sa vred

nachádza. To znamená, že rana sa po ošetroaní môže zdať väčšia než pred ošetro-
ním.

Tkanivo v ranách môže byť rôznych farieb. Od čierneho, cez sivé, hnedé, žlté
až červené. Od farby tkaniva sa líši vážnosť a následný postup pri liečbe.

Vážnosť rany nezávisí len od jej obsahu, ale aj od hĺbky, sfarbenia, zdravotných
problémov pacienta, blízkosti rany ku kosti a množstva ďalších faktorov. Je však
možné povedať, že postupné znižovanie okrajov rany je jedným z indikátorov
hojenia.

1.4 Výhody segmentácie DFU

Segmentácia DFU má potenciál byť využitá vo viacerých prípadoch. Prvým prí-
padom je jednoduchšie zisťovanie progresu hojenia. Keďže znižovanie rany je
jedným z ukazovateľov hojenia, bolo by možné porovnávať snímky na dennej
báze, a podľa plochy segmentovanej masky by sa dalo vypočítať, či sa rana zväč-
šuje alebo znižuje. V takomto prípade ale netreba zabúdať, že snímok musí byť
vyhotovený z rovnakej vzdialenosti a pod rovnakým uhlom.

V minulosti prebiehali výskumy, ktoré merali priemernú rýchlosť znižova-
nia rany podľa pôvodu DFU a jeho veľkosti. Napríklad pri neuropatických DFU
sa pacientom s ranami s menším obsahom než jeden centimeter znižuje prie-
mer o 0.42 milimetrov týždenne, zatiaľ čo pri obsahu dvoch centimetrov a viac je
to 0.57mm týždenne [12]. Porovnaním výsledkov segmentácie po každom týždni
s týmito priemernými číslami z výskumov by bolo možné vidieť, či hojenie pre-
bieha správnou rýchlosťou. Taktiež by dáta nazbierané z aplikácie mohli pomôcť
budúcim výskumom pri sledovaní rôznych metód liečby a ich efekte na rýchlosť
hojenia rany.

Ďalším prínosom môže byť využitie segmentácie na vyrezanie diery do špe-
ciálnej vložky do topánky, ktorá by zabezpečila prívod vzduchu k rane, a znížila
tlak na ranu. V súčasnosti sa vyrezávanie diery robí manuálne. Väčšinou sa pri-
loží kus priehľadnej latky k rane, obkreslia sa jej okraje a podľa toho sa manuálne
vyreže diera do podrážky. Taktiež prebieha vývoj systému, ktorý vyreže dieru
pomocou laseru, avšak obrys rany sa robí manuálne zo snímky [13]. Segmentá-
cia by mohla tento proces výrazne urýchliť.



Obr. 1.3: Proces vyrezávania diery do špeciálnej podrážky. Časovo náročné je, ako obkreslenie rany, tak aj jej manuálne vyrezanie

2 Sémantická segmentácia DFU: Techniky a prístupy


V tejto kapitole urobíme prieskum aktuálnych technológií a postupov. Segmentácia je pomerne moderný problém, pretože do roku 2012 boli konvolučné neurónové siete využívané prevažne na klasifikačné úlohy, kde stačí celej snímke prideliť triedu. Pri segmentácii je potrebné prideliť triedu každému pixlu [14]. Pri medicínskych obrazoch bolo aj problémom to, že dát na učenie bolo menej než dát pri iných úlohách, kde fotky môže zbierať a overovať bežný človek, a nie len odborník.

Prelomovým prístupom k segmentácii bolo v roku 2012 natrénovanie siete nie na obrázkoch ale na regiónoch obrázku (takzvaný sliding window setup), kde sieť predikovala triedu pre každý pixel na základe daného pixlu a regiónu okolo neho [15]. Následným spojením vznikol segmentovaný obrázok. Tento postup má ale viacero nevýhod. Okrem toho, že je časovo náročnejší, pretože rozdeľuje obrázok na malé časti, je aj redundantný pretože regióny sa prekrývajú [14]. Veľkosť regiónu je taktiež problém. Kým veľký región znižuje presnosť, pretože vyžaduje viacero max-pooling vrstiev, malý región môže poskytovať príliš málo kontextu na pochopenie obrázku [14].

2.1 U-Net pre segmentáciu DFU

U-net je konvolučná neurónová sieť, ktorá bola navrhnutá v roku 2015 na účely sémantickej segmentácie. Architektúra tejto siete je založená na takzvanej plnej konvolučnej sieti (FCN) navrhnuťej v roku 2014. Tieto siete využívajú výhradne lokálne prepojené vrstvy, ako je konvolúcia, pooling a zväčšovanie (upsampling). U-net nepoužíva husté vrstvy (dense layers) čo má za následok menej parametrov a zrýchlenie tréningu siete. Tým, že vrstvy sú prepojené lokálne, sieť dokáže pracovať so snímkami rôznych rozmerov, pretože obrázok sa rozdelí na menšie časti, pre ktoré prebieha predikcia. Predikcia prebieha na menšej časti než ktorá je

vystrihnutá. Zvyšné okraje sú potrebné na získanie kontextu pre predikciu. Okrajové regióny sú doplnené o zrkadlený obraz, ako je možné vidieť na obrázku 2.1.

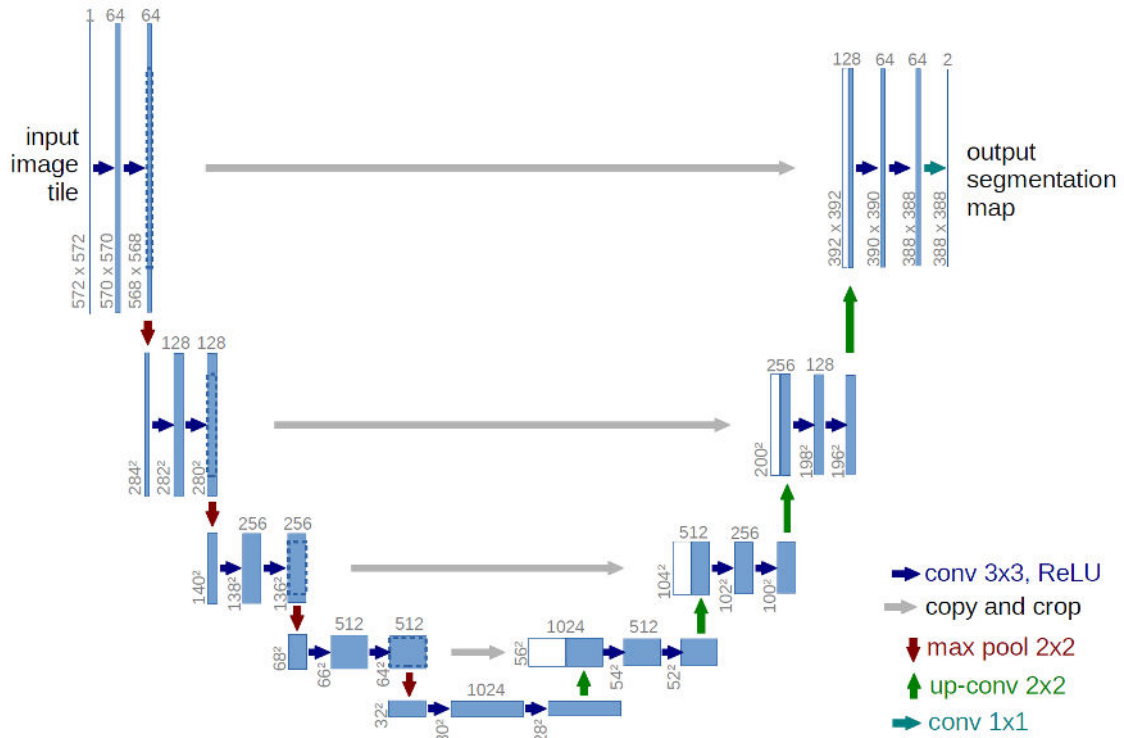


Obr. 2.1: Stratégia prekryvania dlaždíc [14]. Na obrázku je možné vidieť aj doplnené zrkadlenie na okrajovom regióne (región medzi žltou a modrou čiarou), ktoré pomáha doplniť kontext pre predikciu. Vďaka rozdeleniu je možné predikciu spúšťať na obrázkoch rôznych veľkostí

U-net získal svoj názov na základe architektúry, ktorá sa skladá z dvoch častí, kontrakčnej (smer nadol) a expanzívnej (smer nahor). Kontrakčná a expanzívna cesta spolu s ústím (bottleneck) pripomínajú písmeno U. Kódovanie je postup prepoužitý z klasických neurónových sietí používaných na klasifikáciu [14]. Kontrakčná cesta má za úlohu extrahovať príznaky zo vstupného obrazu. V tejto ceste sa každou vrstvou zväčšuje počet filtrov, a znižuje rozlíšenie vstupného obrazu. Tento postup zabezpečí, že nižšie vrstvy dokážu zachytiť zložitejšie a abstraktnejšie znaky. Ide o opakované použitie konvolúcií, nasledovaných rektifikovanou lineárnou jednotkou tzv. ReLu funkciou a Max pooling operáciou.

Dekódovanie je proces, vďaka ktorému je sieť schopná pretransformovať zhusťenú mapu príznakov na formát pôvodného obrázka. Expanzívna časť pozostáva z opakovanej up-konvolúcie, ktorej účelom je zväčšiť rozlíšenie obrázku a zredukovať počet kanálov. Expanzívna časť ďalej obsahuje preskakované spojenia. Ich úlohou je napomôcť lokalizácii sčítaním orezaných máp príznakov z kontrakčnej vrstvy na rovnakej úrovni. Expanzívna časť taktiež obsahuje konvolúcie. To pomáha zabezpečiť, aby bola do segmentačnej mapy zakomponovaná aj informácia o detailoch a textúrach vstupného obrazu. Expanzívna cesta je symetrická s kontrakčnou cestou [14]. Orežanie pri sčítavaní kanálov z kontrakčnej vrstvy do ďalšej kontrakčnej vrstvy je potrebné kvôli strateným pixlom z okrajov ku čomu prichádza pri konvolúciách. Finálna konvolúcia premapuje každý vektor znakov do pre nás potrebného počtu tried. Finálna konvolúcia je typu 1x1, čo znamená,

že nezmení počet pixlov, iba počet kanálov.



Obr. 2.2: Architektúra siete U-net [14].

U-net je aj v súčasnosti veľmi populárnou neurónovou sieťou a jeho modifikácie sa stali jednými z primárnych nástrojov používaných pri segmentácii medicínskych obrazov.

2.2 NnU-Net pre segmentáciu DFU

Konvolučné neurónové siete vyžadujú množstvo rozhodnutí z hľadiska architektúry, predspracovania, tréovania a inferencie [16]. Ak sa aj podarí dosiahnuť presné výsledky na jednom probléme a dátovej sade, je vysoká pravdepodobnosť, že rovnaká architektúra sa nebude schopná efektívne natréovať na inom probléme. Ďalším problémom je aj to, že správnosť niektorých parametrov nie je možné uhádnuť inak, než časovo náročnou experimentáciou. NnU-Net bol vyvinutý tak, aby riešil tieto problémy automaticky, a aby sa tímy namiesto toho mohli venovať vylepšovaniu architektúry, namiesto jej celého prerábania alebo náhodných experimentálnych zmien.

Táto sieť vznikla pri súťaži, kde mali účastníci za úlohu vyvinúť algoritmus na segmentáciu schopnú automaticky sa prispôbiť rôznym súborom údajov [17]. Súťažiaci mali k dispozícii 7 medicínskych súborov dát na tréning, a na testo-

vane tri nové. Práve aj vďaka tejto súťaži bol nnU-Net vyvinutý, a stal sa aj jej víťazom. Ďalším dôkazom efektivity nnU-Net architektúry je aj fakt, že do 2 rokov po decathlon súťaži vyhrali jeho modifikácie až 33 z 53 celosvetových súťaží v segmentácii rôznych medicínskych obrazov [17]. Nižšie budú opísané postupy, ako sa nnU-net líši od siete U-net.

Predspracovanie je plne automatizované [16]. Najprv prebieha orezávanie, na nenulové hodnoty obrázkov (pozerá sa na nenulové hodnoty obrázkov, nie másk). Nulové hodnoty nie sú dôležité pre tréning, a vďaka tomu, že sa ich zbavíme, znížime výpočtovú záťaž [16]. Následne prebieha resampling (iba pre 3 a viacrozmerné dáta) a normalizácia. Obrázky sa automaticky normalizujú na základe štatistických údajov celej príslušnej množiny údajov.

Na tréning sa ako predvolené nastavenie používa súčet dice a cross-entropy stratovej funkcie [16]. Túto funkciu je veľmi jednoduché zmeniť. Na základe množstva výsledkov z minulosti však vyzerá, že práve kombinácia dice a cross entropy stratových funkcií je výhodná pre súbory údajov s nerovnováhou tried. Medzi ďalšie predvolené nastavenia siete patrí adam optimizér s počiatočnou rýchlosťou učenia $3 * 10^{-4}$ [16]. Jedna epocha iteruje 250 trénovacích dávok, a model sa trénuje na 1000 epochách [16]. Rýchlosť učenia sa redukuje päťnásobne vždy, keď sa posledných 30 epoch nezlepší exponenciálny kľzavý priemer validácie aspoň o $5 * 10^{-3}$ [16]. Na aktiváciu sa používa Leaky ReLu funkcia.

Ďalšou efektívnou technikou v nnU-Nete je Deep supervision modul. Deep supervision je technika používaná v oblasti strojového učenia, ktorá zvyšuje presnosť výstupu neurónových sietí s väčším počtom vrstiev. Táto technika pridáva do siete tzv. vedľajšie výstupy, ktoré umožňujú, aby výstupy boli získané nielen z poslednej vrstvy, ale aj z vnútorných vrstiev. Na konci každej vrstvy siete v expanzívnej časti je na výstup vrstvy aplikovaná konvolúcia s počtom výstupných znakov rovných počtu očakávaných znakov vo výslednom obrázku (v prípade DFU sú to dva znaky, pretože poznáme len pozadie a ranu). Výstup tejto konvolúcie je zväčšený a sčítaný s výstupom z vyššej vrstvy a tento postup sa opakuje až do finálnej vrstvy, kde po poslednom súčte je aplikovaná softmax funkcia.

Medicínske obrazy sú v danom datasete na prvý pohľad často podobné. Snímky sú neraz robené pod rovnakým svetlom, vzdialenosťou a uhlom. Aby sa predišlo pretrénovaniu, je potrebné dáta mierne modifikovať. Takáto modifikácia sa nazýva augmentácia. NnU-Net používa knižnicu batchgenerators, so širokou škálou augmentácií. Tie sú už automaticky zadané ale samozrejme je možné augmentácie pridať, odstrániť, pozmeniť ich poradie a intenzitu.

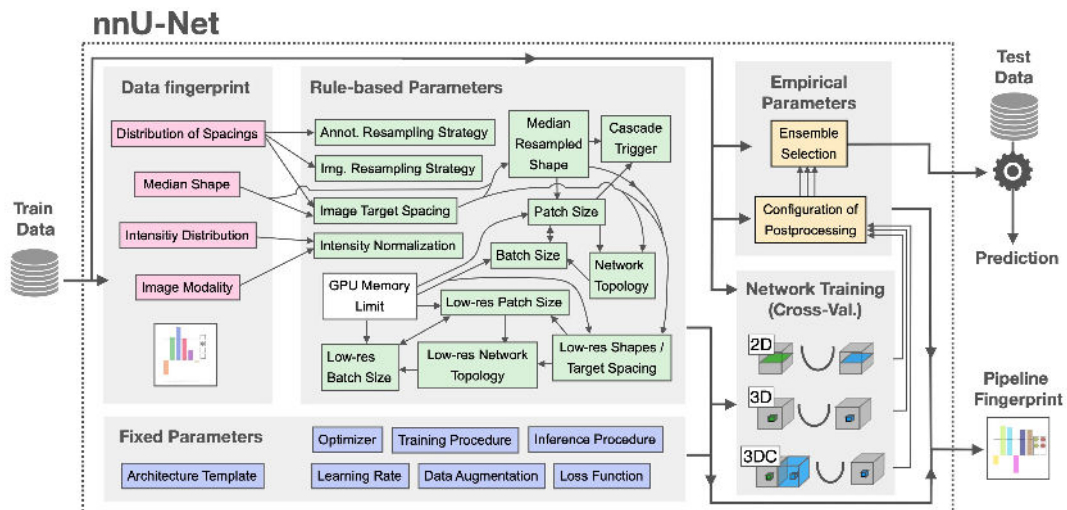
NnU-Net nepoužíva krátke preskakované spojenia, dense-connections a po-

Rýchlosť učenia	Plán PolyLR (začína na 0,01)
Funkcia straty	Súčet dice a cross entropy
Architektúra	Rovnaká ako Unet (encoder-decoder, preskakované spojenia na rovnakej úrovni) Leaky ReLU, deep supervision.
Optimizer	SGD s nesterovou hybnosťou (0,99)
Augmentácie	Rotácie, škálovanie, gaussian noise, gaussian blur, kontrast, jas, nízke rozlíšenie, gamma, zrkadlenie
Tréning	1000 epoch po 250 minidávkach, foreground oversampling

Tabuľka 2.1: Fixné parametre nnU-Net, ktoré sa preukázali ako účinné naprieč širokou škálou datasetov. To však neznamená že ich zmenenie nezlepší výsledok na konkrétny dataset.

zornostné mechanizmy [16]. Tieto mechanizmy zvyšujú výpočtovú zložitosť, ale ich pridanie do nnU-Net-u by mohlo teoreticky zlepšiť presnosť.

Vysoká úspešnosť a prepoužiteľnosť, možnosť použitia na 2D aj 3D dáta, množstvo preddefinovanej funkcionality a jednoduchá modifikácia architektúry robí z tejto siete pre nás ideálneho kandidáta na segmentáciu DFU.



Obr. 2.3: Diagram nnU-Netu. Je možné vidieť, že niektoré parametre má zafixované fixne, iné sú určené automaticky podľa množstva faktorov, ako napr. limit GPU, modalita obrázkov, ich rozmerov atď.

2.3 Mixup Augmentácia pre segmentáciu DFU

Augmentácie sú užitočným nástrojom v predchádzaní pretrénovania neurónových sietí. Modifikáciou dát zabezpečujú, že model dostáva vždy nové dáta pri tréningu a tým pádom sa učí generalizácii. Diabetické vrede na nohách sú zvlášť problematické, pretože väčšinu obrázkov tvorí pozadie, zatiaľ čo samotná rana tvorí iba malú časť obrázka. Na boj s týmto problémom existujú augmentačné metódy, ktoré pomáhajú vyrovnať tento nerovnovážny pomer.

Metóda Mixup spočíva v lineárnom kombinovaní obrázkov a ich masiek [18]. Existuje viacero prístupov k mixupom pri segmentácii. Môže kombinovať obrázky v statickom alebo dynamickom pomere. Mixup zreguluje model vycenrovaním rozhodovacej hranice medzi triedami [19]. Mixup augmentácia napomáha modelu správať sa lineárne medzi tréningovými príkladmi [19]. Lineárne správanie znižuje množstvo nežiaducich oscilácií pri predikovaní mimo tréningových príkladov [19]. Model sa môže lepšie naučiť nájsť menej intenzívne rany, a taktiež správne klasifikovať pozadie, ktoré sa mierne podobá na ranu. Mixup tiež pomáha bojovať proti zapamätaniu nesprávnych označení tried, citlivosti na adverzné príklady a nestabilite pri adverznom tréningu [19]. Táto augmentácia často zväčší obsah masky voči obsahu pozadia, čo mierne napomáha vyrovnať nerovnováhu tried. Je však otázkou, ako intenzívne časti masky by mali byť po mixupe označené ako pozadie, a ktoré ako rana. Kombinácia obrázkov v pomere 9:1 môže mať za následok príliš slabú intenzitu rany z druhého obrázka, ktorú sieť nedokáže správne odhaliť. Preto je dôležité nájsť hranicu intenzity, pod ktorou bude maska označená ako pozadie, a nad ktorou ostane maskou. Tento prístup sa nazýva asymetrický mixup [20]. Hranica líši pri rôznych dátach a architektúrach siete [20], a preto je dôležité s ňou experimentovať.

$$\tilde{x}_i = \lambda x_i + (1 - \lambda)x_j, \quad \tilde{y}_i = \lambda y_i + (1 - \lambda)y_j. \quad (2.1)$$

2.1 Výpočet mixup [20]. X_i a X_j predstavuje dve náhodné vstupné obrázky a Y_i a Y_j k nim prislúchajúce masky. λ predstavuje koeficient, ktorým sú obrázky násobené aby mali príslušnú intenzitu. λ je väčšinou náhodne vybrané číslo beta distribúcie v rozmedzí od 0 do 1. Beta distribúcia potrebuje parameter α . Množstvo zdrojov odporúča vybrať pre alfa parameter číslo medzi 0.2 až 0.4 [21].


$$\hat{y}_i = \begin{cases} y_i & \text{if } (\lambda > m \text{ and } y_i = r) \text{ or } y_i = y_j, \\ y_j & \text{if } (1 - \lambda > m \text{ and } y_j = r) \text{ or } y_i = y_j, \\ 0 & \text{otherwise.} \end{cases} \quad (2.2)$$

2.2 Tresholding pri mixupe [20]. m predstavuje treshold intenzity masky (napríklad hodnota pixelu medzi 0 a 255), pod ktorým sa maska bude považovať za pozadie a nad ktorým ako rana.

2.4 Reziduálne spojenia pre segmentáciu DFU

Základná architektúra U-netu obsahuje preskakované spojenia, teda spojenie zväčšených map príznakov pri kontrakčnej ceste spolu s mapami príznakov z rovnakej úrovne pri expanzívnej ceste. Tieto preskakované spojenia pomáhajú obnoviť plné priestorové rozlíšenie na výstupe siete, vďaka čomu sú plne konvolučné metódy (FCN) vhodné na sémantickú segmentáciu [22]. Tieto preskočené spojenia sa taktiež nazývajú v niektorých článkoch dlhé preskakované spojenia [22].

Okrem toho ale poznáme aj krátke preskakované spojenia (Residual skip connections), ktoré základná architektúra U-netu neobsahuje. Tieto spojenia sú používané v takzvaných Residual neural networks, určených na klasifikáciu. Ukázalo sa, že hĺbka sietí dokáže signifikantne zlepšiť výsledky tréningu [23]. Nie je to ale len tak, že čím hlbšia sieť, tým lepšie výsledky. Hĺbka siete so sebou totiž prináša viacero problémov, ktoré je potrebné vyriešiť. Jedným z nich je degradačný problém [23], kde sa presnosť pri tréningu presýti (saturates), a následne začne prudko klesať. Krátke preskakované spojenia tvoria skratku z vyšších vrstiev do hlbších tým, že spoja vstup do konvolučného bloku s jeho výstupom. Rôzne vrstvy siete sa učia rozdielne znaky. Krátke preskakované spojenia pomáhajú zachovať znaky z vyšších vrstiev a zabrániť degradačnému problému [24]. Na to, že krátke preskakované spojenia sú nápomocné aj pri segmentácii prišli autori článku, *The Importance of Skip Connections in Biomedical Image Segmentation* [22], keď pridali do ResNetu expanzívnu cestu, vďaka čomu z toho vzniklo FCN. Sieť vyskúšali tréňovať iba s dlhými preskakovanými spojeniami, iba s krátkymi a s oboma. Kombinácia oboch sa preukázala ako najefektívnejšia.



Obr. 2.4: Krátke alebo "reziduálne" preskakované spojenia. Na rozdiel od dlhých sú pripočítavané po vertikálnej ceste siete medzi vrstvami.

2.5 Mechanizmy pozornosti pre segmentáciu DFU

Pozornostné mechanizmy vznikli na základe chápania fungovania ľudského zraku. Ľudský zrak sa dokáže sústrediť iba na časť všetkých viditeľných informácií spracovaných okom [25]. Pozornostný mechanizmus v konvolučných neurónových sieťach môžeme chápať ako dynamické upravenie váh prvkov a oblastí, ktoré sú pre danú úlohu relevantné, na základe príznakov vstupného obrázka [26].

Za posledné roky bolo vyvinuté veľké množstvo pozornostných mechanizmov. Zameriame sa na tri hlavné triedy týchto mechanizmov relevantných pre segmentáciu obrázkov bližšie sa pozrieme na úspešné architektúry pozornostných modulov pre dané triedy.

2.5.1 Kanálová pozornosť

Kanálová pozornosť odhaľuje medzi-kanálové vzťahy príznakov [27]. Pri vstupe 2D DFU obrázka do neurónovej siete, má obrázok tri kanály: červený, zelený a modrý. Po každej konvolúcii sú generované nové kanály obsahujúce rôzne informácie [25]. Kanály väčšinou reprezentujú rôzne objekty extrahované zo vstupného obrázka [28]. Modul kanálovej pozornosti pridá váhy jednotlivým kanálom, alebo zjednodušene povedané objektom, vďaka čomu sa model učí "čo" je dôležité pre jeho učenie [27]. Najznámejším príkladom je SE modul [29], a jeho upravená verzia Efficient channel attention (ECA), ktorá na výpočet používa 1D konvolučné vrstvy namiesto average pooling.


Squeeze and excitation

V každej konvolučnej vrstve neurónovej siete sa nachádza súbor filtrov, ktorý vyjadruje susedské priestorové vzory konektivity pozdĺž vstupných kanálov - spájajú priestorové a kanálové informácie spolu v rámci miestnych receptívnych polí [29]. Architektúrna jednotka squeeze and excitation napomáha sieti k zameraniu sa na vzťahy medzi jednotlivými kanálmi [29]. Tento blok umožňuje sieti rekalibrovať príznaky, prostredníctvom čoho sa môže naučiť využívať globálne informácie na selektívne zdôraznenie informatívnych príznakov a potlačenie menej užitočných [29].

Na obrázku 2.5 je možné vidieť architektúru SE bloku. Každá konvolúcia v sieti produkuje mapu príznakov, na ktorú je možné aplikovať SE blok. Ten túto mapu vezme na vstup, aplikuje squeeze operáciu - agreguje mapy príznakov naprieč ich priestorovými dimenziami pomocou globálneho average pooling. Exci-

tation operácia vezme výstup squeeze operácie a vytvorí z neho kolekciu modulačných váh pre každý kanál. Tieto váhy sú nakoniec aplikované na mapy príznakov, ktoré vyšli z konvolúcie. Výsledkom je mapa príznakov, kde ma každý príznak váhu na základe jej dôležitosti pre učenie.

Štruktúru SE bloku je možné vidieť na obrázku 2.5. SE blok môžeme zostaviť pre akúkoľvek transformáciu F_{tr} , ktorá mapuje vstup X na mapy príznakov U . SE blok sa používa na rekalkuláciu máp príznakov U . Najskôr funkčné mapy U prechádzajú stlačovacou operáciou, ktorá agreguje vlastnosti funkčných máp na kanálový opis tým, že ich stláča v priestore $(H \times W)$. Kanálový opis poskytuje vloženie celkového rozdelenia funkčných odpovedí po kanáloch. Agregácia je nasledovaná excitačnou operáciou, ktorá používa jednoduchý samoregulačný mechanizmus na produkciu modulačných váh pre každý kanál zo vstupu. Tieto váhy sa aplikujú na funkčné mapy U a vytvárajú výstup SE bloku, ktorý sa môže priamo vložiť do nasledujúcich vrstiev siete [29].



Obr. 2.5: Squeeze and excitation blok

Účinnosť tejto poznostnej jednotky pri segmentácii je preukázaná aj v článku *USE-Net: incorporating Squeeze-and-Excitation blocks into U-Net for prostate zonal segmentation of multi-institutional MRI datasets* [30], ktorý pridaním SE blokov do U-netu výrazne zlepšil výkon siete. Autori popisujú 3 miesta v architektúre U-netu, kde je možné pridať SE blok - v kontrakčnej časti, v expanzívnej časti a po klasifikátore [30]. Podľa experimentov je účinnosť bloku najvyššia v kontrakčnej časti, menej účinná pri expanzívnej, a najmenej po klasifikátore [30].

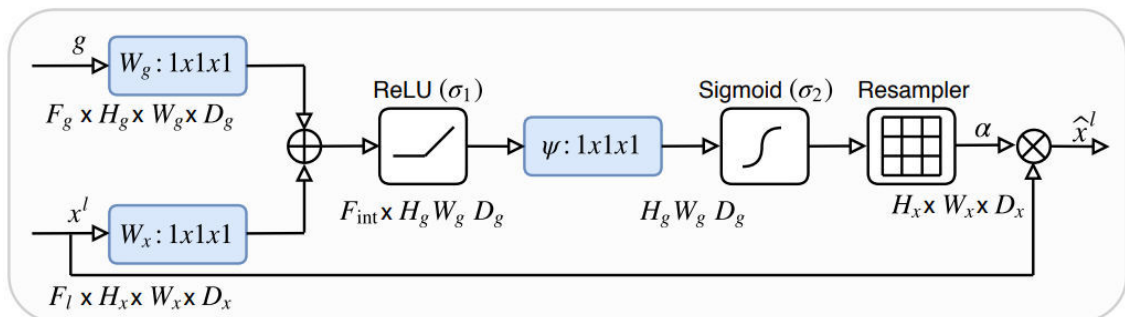
2.5.2 Priestorová pozornosť

Priestorová pozornosť využíva medzipriestorové vzťahy príznakov. Zatiaľ čo kanálová pozornosť sa zameriava na "čo" je dôležité, priestorová pozornosť zvyrazňuje "kde" je dôležitá informácia [27]. Výpočet vygeneruje priestorovú mapu pozornosti, zvyrazňujúcu na ktorú časť obrázku sa sústrediť a na ktorú nie [27].

Attention U-net

Attention U-net navrhnutý pri segmentácii obličiek [31] napomáha modelu sústrediť sa na cieľové štruktúry [31]. Pripájanie preskakovaných spojení pri expanzii je naivná metóda. Tým že v nízkoúrovňových príznakoch je nedostatok sémantických informácií, prinášajú so sebou aj množstvo zbytočných informácií z pozadia, ktoré môžu negatívne zasahovať do segmentácie cieľového objektu [32]. Úlohou pozornosťného modulu v Attention U-nete je zachytávať vysokoúrovňové sémantické informácie a zdôrazňovať cieľové príznaky [32].

Attention U-net potláča nedôležité regióny zatiaľ čo zvýrazňuje tie dôležité [31]. Tento mechanizmus je pridaný do každej úrovne expanzívnej cesty U-netu. Vieme, že dlhé preskakované spojenia v U-nete napomáhajú lokalizácii a obnoveniu detailov. Attention gate (AG) upravujú príznaky získavané z týchto preskakovaných spojení tým, že ich vynásobia vypočítanými koeficientami ktoré zvýraznia dôležité príznaky.



Obr. 2.6: Proces výpočtu AG [31]. Príznaky (x^l) z preskakovaných spojení sú vynásobené koeficientmi vypočítanými v AG. Koeficienty AG sú vypočítané súčtom preskakovaných spojení a vstupov z nižšej vrstvy (g), následne aplikovanej ReLU funkcii, konvolúcii a sigmoid funkcii.

2.5.3 Zmiešaná pozornosť


Ide o kombináciu priestorovej a kanálovej pozornosti. Prvým takýmto mechanizmom bol CBAM (angl. Convolutional Block attention module) [27], ktorý prišiel ako vylepšená verzia Squeeze and excitation blokov, pridaním priestorovej pozornosti. Ďalšími známymi mechanizmami je BAM (Bottleneck attention module) [33], zameriavajúci sa na nižšie číslo parametrov pozornosti na zníženie náročnosti výpočtu a Triplet attention [34] postavenom z poznatkov o CBAM, skladajúcej sa z troch vetiev - priestorová pozornosť, kanálová pozornosť a pozornosť na celkovú štruktúru vstupu. Triplet attention modul funguje tak, že obsahuje tri

vetvy fungujúce na rovnaký princíp a mení sa len vstup tým, že sa rotuje okolo inej dimenzie [34].

Convolutional Block Attention Module


CBAM (Convolutional Block Attention Module) je ďalší pozornosťný modul pre konvolučné neurónové siete. Vzhľadom na prechodnú mapu vlastností modul sekvenčne odvodzuje mapy pozornosti pozdĺž dvoch samostatných dimenzií, kanálovej a priestorovej, následne sa mapy pozornosti znásobia na vstupnú mapu vlastností pre adaptívne spresnenie vlastností [27]. Tento modul je aplikovateľný na mapu príznakov po každej konvolúcii pri downsamplingu. Skladá sa z dvoch podmodulov: kanálový pozornosťný modul a priestorový pozornosťný modul.

Modul kanálovej pozornosti agreguje priestorové informácie aplikovaním average pooling a max pooling. Obidve outputy následne prejdú zdieľaným viacvrstvovým perceptronom s jednou skrytou vrstvou [27]. Výsledky sú následne sčítané.



Obr. 2.7: Kanálová pozornosť v CBAM moduli [27].

Priestorová pozornosť najprv sčíta výsledky average a max pooling operácií naprieč kanálovou osou, čoho výsledkom je zvýraznenie informatívnych regiónov [27]. Na výsledku je aplikovaná konvolučná vrstva, ktorá vygeneruje priestorovú mapu pozornosti, zobrazujúcu kde sa sústrediť a kde nie [27].



Obr. 2.8: Priestorová pozornosť v CBAM moduli [27].

3 Zlepšenie výkonu siete nnU-Net pomocou architektonických inovácií a dátových augmentácií: Experimenty

NnU-Net patrí medzi najúspešnejšie neurónové siete na riešenie segmentačných problémov medicínskych obrazov. Ide o modifikovaný U-net, prispôsobený k učeniu sa na širokej škále medicínskych 2d aj 3d dát. Na základe tohto faktu sme sa rozhodli zvoliť nnU-Net ako hlavný nástroj na segmentáciu DFU. Najprv bude potrebné získať výsledok základného modelu nnU-Netu, a následne experimentovať s modifikáciami architektúry, a porovnávať tieto modifikácie s výsledkom základného modelu. Výhodou modifikovania nnU-Netu je aj to, že naše nové architektúry bude možné použiť na tréning aj na iných datasetoch, s potenciálom vylepšiť výsledky aj pri iných problémoch. Plánom je vyskúšať rôzne kombinácie augmentácií, implementovať do kódu mixup a cutmix augmentácie, porovnať rôzne relevantné funkcie straty pre nevyvážené súbory údajov, pokúsiť sa pridať do architektúry prvky, ktoré sa v minulosti preukázali ako účinné pri segmentácii medicínskych obrazov ako napríklad krátke preskakované spojenia, mechanizmus pozornosti alebo ich kombinácia.

Na to, aby sme stihli vykonať veľké množstvo experimentov za krátky čas, budeme model trénovať na 100 epochách. Najúspešnejšiu architektúru natrénujeme na 1000 epochách a nad všetkými dátami naraz. Taktiež sa pokúsime výsledky vylepšiť pomocou následného spracovania.

3.1 Charakteristiky a použitie súborov údajov DFU

Do sprístupnenia nového súboru údajov v roku 2022 existoval len jeden súbor údajov určený na segmentáciu DFU pod názvom FUSeg [35]. Ten má ale dvakrát menej snímok, ktoré sú z veľkej časti orezané a vyplnené čiernou farbou na doplnenie rozmerov a niektoré masky sú očividne chybné.



Obr. 3.1: Príklad pravdepodobne chybných masiek pre snímky FUSeg. Prvé dve zľava podľa masky nemajú vred, no podľa snímky je očividne prítomný. Tretia maska zľava má nesprávne označený ľavý vred.


Začiatkom roku 2022 bol sprístupnený doteraz najväčší súbor dát určený na segmentáciu DFU s názvom DFUC2022. Na jeho vývoji spolupracovali odborníci z Manchesterskej Univerzity a množstva zdravotníckych inštitúcií [36].

Obrázky boli fotené za rovnakých podmienok, vzdialenosti cca 35 cm, zachytená celá noha, najsignifikantnejší vred v centre fotky [36]. Obrázky boli prevzorované na rozmery 640x480 [36], čo spôsobuje rozmazanie okrajov masiek. Trénovací súbor údajov obsahuje 2000 obrázkov a k nim prislúchajúcich masiek. Väčšina obrázkov obsahuje 1 vred, ale nie je to pravidlo. Hovorí o tom aj fakt, že 2000 obrázkov obsahuje 2304 vredov [36].

Na vyznačovanie bol použitý softvér s názvom VGG annotator, pomocou ktorého vykonávali vyznačovanie experti. Následne bol na maskách použitý algoritmus aktívnych obrysov, ktorý spôsobil zjemnenie obrysov masiek. Autori súboru údajov sú presvedčení, že tento algoritmus zlepšuje schopnosť sietí učiť sa na dátach, a zároveň zachováva podobnosť masiek s pôvodnými (0.9650 Dice similarity coefficient).

S DFU súborom dát prichádza viacero problémov, ktoré negatívne ovplyvnia úspešnosť tréningu. Poprvé, masky sú poväčšine veľmi malé oproti pozadiu, čo spôsobí nerovnováhu tried. Je známym faktom, že segmentácie sú problematické

pri malých regiónoch. Z 2304 masiek, až 2054 je menších než 5% celej snímky, iba 36 je väčších než 15% snímky [36]. Najväčší vred zaberá iba 35% snímky [36].



Obr. 3.2: Štatistiky počtu rán rôznych veľkostí v súbore údajov DFUC2022 [36].

Ďalším problémom bude prítomné pozadie nohy, ktoré obsahuje rôzne objekty, plachty, prípadne škvrny, ktoré môžu byť podobné s ranou. Na pacientovej nohe sa taktiež často nachádzajú podobné anatomické štruktúry ako DFU, a to napríklad odhalená kosť, kalus alebo nesúvisiace kožné lézie. V neposlednom rade, problém môžu spôsobovať vredy, ktoré sú podobné s kožou. Nie všetky vredy sú totiž výrazné rany. Niekedy majú vzhľad veľmi podobný vyschnutej koži [36].



Obr. 3.3: Prehľad niektorých snímkov nového súboru dát. Obsahuje rany každého typu. Zľava idú typy: neuropatický, ischemický a neuroischemický. Úplne napravo je možné vidieť, že niektoré rany je neskúseným človekom ťažké rozoznať od zdravej pokožky.

3.2 Metriky hodnotenia pre segmentáciu DFU

Na vyhodnotenie presnosti predikcií natrénovaného modelu potrebujeme použiť evalvačné metriky. Bližšie sa pozrieme na Dice similarity coefficient (DSC), False positive error (FPE) a False negative error (FNE).

Dice metrika je číslo v rozmedzí od 0 do 1, kde 1 znamená presnú zhodu medzi segmentovaným a referenčným obrazom [31]. Jej výpočet vzniká vynásobením počtu prekrývajúcich sa pixelov DFU na predikovanej a skutočnej (ground truth) maske číslom 2, a predelením súčtu celkového počtu pixelov DFU masky na oboch obrázkoch. Výhodou DSC metriky je to, že odráža zhodu o veľkosti aj lokalizácii, čo je viac v súlade s kvalitou vnímania v porovnaní s metrikou presnosti pixelov [31].

$$DSC := \frac{2|A \cap B|}{|A| + |B|} \quad (3.1)$$

Vzorec pre výpočet DSC skóre. Premenné A a B predstavujú referenčný a segmentovaný obraz

FPE meria počet neplatne označených pixelov v segmentovanom obraze vzhľadom k referenčnému obrazu. To znamená, že FPE sa zvyšuje, keď model označuje pixely, ktoré nie sú súčasťou referenčného obrazu ako súčasť segmentu. FPE sa vypočíta ako podiel počtu falošne pozitívnych pixelov k celkovému počtu označených pixelov [36].

$$FPE := \frac{FP}{FP + TN} \quad (3.2)$$

Vzorec pre výpočet FPE.

FNE, naopak ako FPE, meria počet neoznačených pixelov v segmentovanom obraze vzhľadom k referenčnému obrazu. To znamená, že FNE sa zvyšuje, keď model neoznačuje pixely, ktoré sú súčasťou referenčného obrazu ako súčasť segmentu. FNE sa vypočíta ako podiel počtu falošne negatívnych pixelov k celkovému počtu pixelov v referenčnom obraze [36].

$$FNE := \frac{FN}{FN + TP} \quad (3.3)$$

Vzorec pre výpočet FNE.

Neurónová sieť na segmentáciu DFU bude trénovaná na DFU datasete určenom na medzinárodnú súťaž DFU image segmentation 2022. Víťazný bude ten model, ktorý má najvyššie DSC skóre. DSC metrika nám teda pomôže porovnávať výkonnosť modelu vo všeobecnosti. FPE a FNE nám pomôžu porovnávať, či modely majú skôr tendenciu klasifikovať pozadie ako ranu alebo ranu ako pozadie.

3.3 Základný model pre segmentáciu DFU

Najprv bolo potrebné naklonovať nnU-Net repozitár a nainštalovať potrebné knižnice do virtuálneho prostredia ako napríklad pytorch. Na porovnanie efektivity modifikácií nnU-Netu je dôležité získať výsledok základného modelu, oproti ktorému budeme výsledky porovnávať.

3.3.1 Predspracovanie dát

NnU-Net je prispôbený na trénovanie prevažne 3D dát a preto akceptuje dáta vo formáte *.nii*. Bolo potrebné vytvoriť skript pre konverziu 2D *.png* a *.jpg* obrázkov do 3D obrázkov s treťou dimenziou o veľkosti 1 vo formáte *.nii*.

Na maskách sme okrem konverzie vykonali tresholding. Segmentačné masky obsahovali rozmazanie ktoré vzniklo pri úpravách rozmerov obrázkov počas tvorby súboru dát. Na začiatok sme sa rozhodli ako treshold udať 255, teda všetky pixely s hodnotou menšou ako 255 budú považované za pozadie (0) a rovné 255 budú považované za ranu (1). Po rozdelení dát na trénovacie (1600) a testovacie (400), konverzii a tresholdingu sme prešli na preprocessing, ktorý je v nnU-Nete automatizovaný a obsahujúci následovné procesy:

- Orezanie obrázkov na nenulovú oblasť. V našom prípade to nerobí nič, pretože DFU dataset obsahuje fotky, kde neexistujú nenulové hodnoty.
- Údaje sa analyzujú a určia sa informácie o rozostupoch, rozdelení intenzity a tvaroch
- nnU-Net konfiguruje architektúry U-Net a na základe týchto informácií. Všetky siete U-Net sú nakonfigurované tak, aby optimálne využívali GPU s kapacitou 12 GB. V súčasnosti je náročné sa prispôsobiť menším alebo väčším GPU, čo prináša problém pri upravovaní baseline modelu, ktoré môže pamäťové nároky modelu ešte viac zvýšiť. Tento problém sa nám podarilo vyriešiť zmenšením batch size.
- Normalizácia a resampling. Normalizácia je ovplyvnená modalitou a rozložením intenzity vstupného obrázka [37]. Súbor údajov sa premietne do oblasti z-skóre s priemernou hodnotou a štandardnou odchýlkou každého obrázku [37].

3.3.2 Parametre a postup tréningu

Ako základný model bol zvolený tzv. nnUnetTrainerV2. NnU-Net je navrhnutý pre 5-vrstvovú krížovú-validáciu. Tento proces náhodne rozdeľuje dáta do 5 častí a potom je potrebné natrénovať model na každej z týchto častí. Pri predikcii masiek je aplikovaný ensembling (zlučovanie), ktoré skombinuje predikované masky z piatich modelov. Keďže trénovanie modelu pre segmentáciu obrázkov je časovo náročný proces, 5-vrstvová krížová-validácia nie je ideálna metóda na porovnávanie výkonnosti modelov. Porovnávanie výkonnosti modelov iba na jednej časti (fold) je tiež nepresné, pretože daná časť môže náhodne obsahovať dáta, ktoré sú dôležitejšie pre segmentáciu ako iné časti. Preto sme sa rozhodli natrénovať model na celom datasete, aby sme získali presnejšie výsledky. NnU-Net je nastavený na 1000 epoch. Tréning DFU dát s týmto počtom epoch trvá približne 30 hodín na našej grafickej karte Nvidia GeForce RTX 3070 Ti s kapacitou 8GB. Pre rýchlejšie získanie výsledkov na porovnávanie výkonnosti modelov sme sa rozhodli počet epoch znížiť na 100.

Parameter	Hodnota
Batch size	10
Patch size	(512, 640)
Median shape	(480, 640)
Modalita	RGB
Počet tried	1
Počet epoch	100 s 250 iteráciami na 1 epochu.

Tabuľka 3.1: Parametre dát a modelu pri trénovaní základného modelu.

Augmentácia	Popis
SpatialTransform	Rotácia, Škálovanie.
GaussianNoise	0.1 pravdepodobnosť, intenzita medzi 0 až 0.1.
GaussianBlur	0.2 pravdepodobnosť, intenzita medzi 0.5 až 1.
Brightness	Zmena jasu pre každý kanál. 0.15 pravdepodobnosť.
Contrast	0.15 pravdepodobnosť, intenzita medzi 0.75 až 1.25.
SimulateLowResolution	Simulácia nízkeho rozlíšenia. Pravdepodobnosť 0.25.
Gamma	Pravdepodobnosť 0.1.
Mirror	Zrkadlenie obrázku. Pravdepodobnosť 0.5.

Tabuľka 3.2: Augmentácie, ich stručný popis a parametre pri základnom modeli nnUnetTrainerV2

Základný model po 100 epochách dosiahol Dice similiarity coefficient na testovacích dátach o hodnote 0.7115.

3.4 Implementácia pokročilých augmentácií

Augmentácie mixup a cutmix môžu modelu napomôcť vyhnúť sa pretrénovaniu. Prvým prístupom na implementáciu mixup augmentácie bolo vygenerovať obrázky a obohatiť nimi dataset pred spustením predspracovania. Takýto postup má ale viacero nevýhod. Keďže pri mixup augmentácii je potrebné experimentovať s tresholdom, ktorý určí či sa hodnota pixelu zaokrúhli na triedu ale na pozadie, je postup manuálneho generovania obrázkov a masiek časovo náročný. Pri manuálnom generovaní pred tréningom a nie počas tréningu je potrebné nanovo spustiť preprocessing, čo je taktiež časovo a pamäťovo náročné.


Ako riešenie sme doplnili knižnicu augmentácií, ktorú používa nnU-Net o 2 triedy - MixupTransform a CutmixTransform. To zabezpečí generovanie augmentovaných dát počas tréningu, výhodou čoho je jednoduchšie spúšťanie a väčší počet augmentovaných variácií.

MixupTransform obsahuje 2 parametre: Treshold a alpha. Alpha parameter sa používa na generovanie náhodného čísla λ v rozmedzí od 0 do 1 z beta distribúcie, ktorá určuje, v akom pomere sa budú obrázky miešať. MixupTransform vytvorí kópiu dávky, ktorá predstavuje súbor obrázkov a súbor masiek o počte veľkosti dávky (batch size), náhodne premieša kópie, a spojí ich s pôvodnou dávkou pričom pôvodnú dávku vynásobi o $1 - \lambda$ a kópiu vynásobi o λ . Následuje tresholding na vygenerovanej maske podľa parametra treshold.



Obr. 3.4: Príklad dynamicky vygenerovaných obrázkov po mixup augmentácii na jednej dávke o veľkosti 10. V tomto prípade bol λ parameter blízko 0.5, pretože je pomerne zreteľne vidno obidva obrázky. Obrázky majú nerealisticky vyzerajúce farby pre ľudské oko, pretože sú už predspacované.

CutmixTransform obsahuje taktiež 2 parametre. Pravdepodobnosť aplikovania augmentácie a alfa parameter, ktorý sa používa na generovanie λ rovnako ako pri mixupe. λ sa pri cutmixe použije na náhodný výber veľkosti vyrezaného obrázka. Následuje rovnaký proces ako pri mixupe - Náhodné premiešanie dávky, vyrezanie obrázkov a masiek z premiešanej dávky a prilepenie na originálnu dávku.



Obr. 3.5: Príklad dynamicky vygenerovaných obrázkov po cutmix augmentácii na jednej dávke o veľkosti 10.

S cieľom identifikovať optimálne nastavenie parametrov sme experimentovali s nastavením tresholdu a λ .

Metóda	DSC skóre
Baseline	0.712
Mixup tr. 50%, λ 0.4	0.67
Mixup tr. 33%, λ 0.4	0.702
Mixup tr. 25%, λ 0.4	0.712
Mixup tr. 20%, λ 0.4	0.715
Mixup tr. 10%, λ	0.701
Cutmix	0.713

Tabuľka 3.3: Porovnanie efektivity mixup augmentácií. Z výsledkov je jasné, že experimentovanie s tresholdom je dôležité. Rozdiely v tejto tabuľke vyzerajú ako zanedbateľné, no po natrénovaní na 1000 epoch namiesto 100 a evalvácii na väčšom množstve dát sa tieto rozdiely prehĺbia.

Záverom po experimentoch s augmentáciami je, že sa pridanie mixup augmentácie s tresholdom 20% do finálnej architektúry modelu na segmentáciu DFU zvýši presnosť jeho predikcií. Je však možné, že pri inej architektúre siete a inom počte epoch budú výhodnejšie iné parametre.


3.5 Implementácia reziduálnych spojení

Reziduálne spojenia pomáhajú modelu udržiavať nízkoúrovňové príznaky, ako sú napríklad hrany, ktoré by sa inak stratili pri prechode cez rôzne vrstvy. Tým pomáhajú modelu generalizovať na nových dátach, pretože udržiavajú nielen vysokoúrovňové, ale aj nízkoúrovňové príznaky.

Pre pridanie reziduálnych spojení do architektúry nn-UNetu je potrebné zachovať premennú vstupu na začiatku každej vrstvy v kontrakčnej časti. Sčítať predchádzajúci vstup s výstupom po prechode vrstvou kontrakčnej časti je možné len ak obe premenné majú rovnaké rozmery. Pretože konvolúcie v jednotlivých vrstvách pridávajú počet kanálov a znižujú veľkosť obrázka, je potrebné redukovat dimenzionálnosť aj predchádzajúceho vstupu pomocou konvolúcie. Reziduálne spojenie sa pridáva do každej vrstvy kontrakčnej časti.

Metóda	DSC skóre
Baseline	0.712
Residual nnU-Net	0.713
Residual nnU-Net and Mixup treshold 20%	0.724

Tabuľka 3.4: Porovnanie reziduálnych spojení s baseline a mixup modelom. Podľa výsledkov je možné predpokladať, že modelu s reziduálnymi spojeními signifikantne napomáha aj mixup augmentácia.



Obr. 3.6: Spriemerované mapy vlastností obrázka v každej vrstve pred pripočítaním reziduálnych spojení (hore), a po pripočítaní reziduálnych spojení (dole).

Evalváciou sme dokázali, že reziduálne spojenia pomáhajú mierne vylepšiť základný model nnU-Netu. Ešte dôležitejším poznatkom je, že kombinácia mixup augmentácií s reziduálnym U-netom je efektívna, pretože zatiaľ čo mixup vylepšil základný model o 0.3%, reziduálne spojenia o 0.1%, ich kombinácia napomohla až o 1.2%.

3.6 Implementácia mechanizmov pozornosti


Pozornostné mechanizmy sa ukázali ako efektívne a ľahko implementovateľné do architektúr neurónových sietí. Je možné ich doplniť do kontrakčnej aj expanzívnej časti U-netu. Rozhodli sme sa zamerať na rôzne mechanizmy patriace do priestorovej pozornosti, kanálovej a ich kombináciám. Následne výsledky porovnáme a pokúsime sa otestovať najefektívnejší mechanizmus na našom doteraz najlepšom modeli (Residual skip + mixup nnU-Net).

Je dôležité poznamenať, že pridanie pozornostných mechanizmov zvyšuje pamäťové nároky modelu, a preto bolo potrebné zmenšiť veľkosť dávky (batch size) z 10 na 8. Modely tréňované na rozdielnych veľkostiach dávky nie je možné medzi sebou porovnávať, pretože spracovali rozdielne množstvo dát.

3.6.1 Priestorová pozornosť

Na priestorovú pozornosť sme sa rozhodli vyskúšať pozornosťný modul podľa článku o segmentácii pankreasu[31] kde pozornosťný mechanizmus pridaný do U-netu preukázal zvýšenie výkonu modelu. V článku autori pridávajú tento mechanizmus do expanzívnej cesty. Tento priestorový pozornosťný blok vezme na vstup preskakované spojenia z kontrakčnej časti a upsamplovanú mapu vlastností z predchádzajúcej vrstvy expanzívnej časti. Na oboch aplikuje konvolúciu, relu funkciu na ich súčte nasledovanú konvolúciou a sigmoid funkciou. Vznikne mapa koeficientov ktoré po vynásobení s mapou príznakov pridajú alebo uberú váhu relevantným regiónom.

Pri 100 epochách zlepšila priestorová pozornosť priemerné dice skóre o 0.5%. Po implementovaní attention gates do architektúry nášeho zatiaľ najlepšieho modelu (residual skip and mixup nnU-net), sa preukázala ešte lepšia výkonnosť (+1%).



Obr. 3.7: Vybrané 2 kanály z preskakovaných spojení (vľavo), koeficienty z priestorovej pozornosti (v strede), a výsledok koeficientov priestorovej pozornosti aplikovanej na preskakované spojenia. Z obrázka je možné potvrdiť správne fungovanie mechanizmu, lebo zatiaľ čo zvýrazňuje ranu, potláča okolie.

3.6.2 Kanálová pozornosť


Na implementáciu kanálovej pozornosti sme vyskúšali squeeze and excite (SE) bloky, Triplet attention a Efficient channel attention (ECA) bloky. ECA blok je po-

stavený na rovnakom princípe, ako SE blok, ale mal by byť výpočtovo menej náročný. SE aj ECA používajú na squeeze operáciu global average pooling. ECA zachytáva lokálnu medzikanálovú interakciu bráním do úvahy každý kanál a jeho k susedov. ECA je implementovaná 1D konvolúciou veľkosti k , kde veľkosť kernelu k predstavuje pokrytie lokálnej medzikanálovej interakcie, t.j. koľkí susedia sa podieľajú na predikcii pozornosti jedného kanála [38]. ECA by mala dosahovať veľmi podobné, prípadne lepšie výsledky ako SE.

Prvým experimentom bolo pridanie bloku na koniec každej vrstvy kontrakčnej časti. Výstup je uložený do preskakovaných spojení, a poslaný do nižšej kontrakčnej časti. Existujú zdroje, ktoré uvádzajú pridanie výstupu bloku iba do preskakovaných spojení, a do nižšej vrstvy kontrakčnej časti posielajú výstup bez SE alebo ECA operácie. Po evalvácii sa ukázalo, že obidva bloky sú nápomocné. SE blok sa ukázal byť nápomocnejší než ECA blok v nnU-Net architektúre. Na základe toho sme sa rozhodli ďalej experimentovať už iba so SE blokom.

Po úspešnosti pridania SE bloku do kontrakčnej časti sme ho skúsili pridať do nášeho najúspešnejšieho modelu - Residual skip and mixup U-net. Bloky boli pridané po každej vrstve reziduálneho spojenia. Táto kombinácia sa preukázala ako efektívna, pretože už pri 100 epochách zlepšila DSC o takmer percento a pol oproti základnému modelu.

Rozhodli sme sa ďalej experimentovať s pridávaním SE blokov, a to konkrétne do bottlenecku a expanzívnej časti. Pridanie bloku do bottlenecku nepomohlo, ale do expanzívnej časti vylepšilo výsledky o ďalšie percento pri 100 epochách. Doposiaľ najlepšou architektúrou s pozornostným mechanizmom sa teda stal Residual nnU-Net s pridanými SE blokmi do kontrakčnej aj expanzívnej cesty. Tento model má ale narozdiel od ostatných problém v tom, že mixup na vylepšenie jeho výsledkov nemá žiaden efekt.



Obr. 3.8: Vizualizácia niektorých kanálov produkovaných nnU-netom po tretej vrstve kontrakčnej cesty.

Čísla na mape príznakov 3.8 znázorňujú koeficienty, ktorými boli dané kanály prenasobené. Čísla väčšie ako 0.5 znamenajú, že kanál je dôležitý pre učenie, a preto je zvýraznený vynásobením kanála koeficientom. Čísla menšie než 0.5 znamenajú, že kanál je menej dôležitý pre učenie. Z obrázku je možné vidieť správne fungovanie SE bloku, pretože obrázky, kde sú aktivované iné oblasti než rana sú potláčané nižším koeficientom, zatiaľ čo obrázky s aktivovanou ranou sú zvýraznené. Počas učenia siete sa rozdiely týchto koeficientov od 0.5 zvýrazňujú.

3.6.3 Zmiešaná pozornosť

Na experimentovanie so zmiešaným pozornosťným mechanizmom sme sa rozhodli implementovať CBAM bloky. Bloky sme aplikovali na koniec každej vrstvy kontrakčnej časti, rovnako ako SE bloky. CBAM bloky sa preukázali ako veľmi efektívne. Prekonali SE bloky aj AG bloky.

Posledným experimentom bolo skombinovanie SE blokov v kontrakčnej časti a AG blokov v expanzívnej, čím vznikne taktiež zmiešaná pozornosť. SE bloky aj do expanzívnej cesty nebolo možné pridať z dôvodu vysokej pamäťovej náročnosti modelu. Kombinácia SE a AG sa preukázali ako najlepšia kombinácia. Zatiaľ čo mixup pri SE blokoch nijako nemenil výsledky, v tejto architektúre napomáhal bez problémov, vďaka čomu tento model prekonal všetky doposiaľ ostatné modely.

3.6.4 Porovnanie výkonnosti mechanizmov pozornosti: Experimenty a výsledky

Najlepšou architektúrou bez mixup augmentácie siete je SE pridané do kontrakčnej aj expanzívnej cesty, no po vyskúšaní množstva mixup parametrov na tejto architektúre nebolo možné nájsť parametre, ktoré by zlepšili presnosť modelu. Narozdiel od toho, druhá najlepšia architektúra, SE v kontrakčnej časti a AG v expanzívnej sa dokázala výrazne zlepšiť vďaka mixup augmentácii, a to natoľko, že ďaleko prekonala SE enc-dec model.

Model	DSC skóre (100 epoch, challenge testovacie data)
Skip SE enc, AG dec, mixup 25 alpha 0.3	0.6729
Skip SE enc, AG dec, mixup 20 alpha 0.3	0.6708
Skip SE enc, AG dec, mixup 20 alpha 0.4	0.6705
Skip SE enc, AG dec, mixup 20 alpha 0.1	0.6702
Skip SE enc, AG dec, mixup 15 alpha 0.4	0.6687
Skip SE enc-dec	0.6679
Skip SE enc, AG dec	0.6671
Skip SE enc mixup a 0.4 treshold 20	0.6663
Skip CBAM	0.6608
Skip SE enc	0.6593
Skip SE enc dec mixup a 0.4 treshold 20	0.6592
Skip AG	0.6571
Baseline	0.6524

Tabuľka 3.5: Porovnanie efektivity pridaných pozornostných modulov do architektúry nnU-Netu. Skratka enc. znamená blok pridaný do kontrakčnej časti, a dec. znamená blok pridaný do expanzívnej časti. Dôležité je poznamenať, že tieto výsledky nie je možné porovnávať s inými tabuľkami v tejto práci, pretože modely boli trénované na všetkých trénovacích dátach a testované na inej vzorke dát (oficiálne testovacie dáta pre DFU 2022 segmentation challenge.)

3.7 Porovnanie výkonnosti navrhnutých architektúr nnU-Net

Po získaní poznatkov z veľkého množstva tréningov na nižšom počte trénovacích dát, nízkom počte epoch a evalvácii na malej vzorke obrázkov bolo potrebné

overiť správnosť predpokladov o najlepšom modeli. Poslednou úlohou je teda dosiahnuť čo najvyššie DSC skóre. Na maximalizáciu výkonu modelu sme sa rozhodli spustiť tréning na 1000 epoch narozdiel od 100. Na tréning budú použité všetky trénovacie dáta, teda 2000 obrázkov. Počas tréningu model nebude mať oddelené žiadne dáta na evalváciu. Evalvácia nastane až na online odovzdaní 2000 masiek k 2000 novým obrázkom, ku ktorým nie sú zverejnené referenčné obrázky.

Model	DSC	FNE	FPE
Baseline	0.6879	0.2479	0.2586
Residual Skip	0.7002	0.2297	0.2580
Skip SE enc.	0.7030	0.2293	0.2557
Skip SE enc. AG dec.	0.7036	0.2291	0.2541
Skip CBAM enc.	0.7051	0.2239	0.2565
Skip SE enc. and dec.	0.7053	0.2293	0.2557
Skip CBAM enc. with mixup	0.7070	0.2324	0.2437
Skip SE enc. AG dec. with mixup	0.7075	0.2251	0.2498

Tabuľka 3.6: Finálne výsledky najlepších modelov

V tabuľke 3.6 je možné vidieť, že poradie modelov sedí s výsledkami modelov pri nižšom počte dát a epoch 3.5. Keď sa pozrieme na evalvačné metriky, dozvieme sa viacero zaujímavých faktov. Porovnanie baseline modelu s modelom s reziduálnymi spojeniami ukazuje, že reziduálne spojenia skoro vôbec nezlepšili FPE, ale zato výraznejšie zlepšili FNE. To znamená, že model s reziduálnymi spojeniami dokáže rozpoznať viac oblastí s ranami, avšak reziduálne spojenia nepomáhajú pri oblastiach bez rán, ktoré sa na rany z rôznych dôvodov podobajú.

Squeeze and excite bloky a attention gates zasa znižujú False positive error, teda napomáhajú modelu neoznačiť pozadie ako ranu.


Pri porovnaní modelu s a bez mixup augmentácie je možné vidieť pokles aj u FPE aj u FNE. To sedí s hypotézou, že mixup pomáha modelu lepšie naučiť najst menej intenzívne rany, a taktiež správne klasifikovať pozadie, ktoré sa mierne podobá na ranu. Posúvaním tresholdu dokážeme meniť hranicu medzi FPE a FNE. Treshold príliš nízky väčšinou zväčší FPE, pretože označuje znaky príliš podobné pozadiu ako ranu, a treshold príliš vysoký zasa zväčší FNE, pretože označí pozadie príliš ťažko rozpoznateľné od rany ako pozadie.

3.7.1 Krivky učenia pri DFU tréningu

Krivky učenia zobrazujú vývoj presnosti a straty počas trénovania modelu vo forme grafu. Po každej epoche sa na grafe zaznamená hodnota približnej presnosti a straty pre dávku, ktorá bola v epoche použitá. Sledovaním krivky učenia vieme určiť vhodný počet epoch, a tým zabrániť pretrénovaniu alebo podtrénovaniu modelu. Správny počet epoch určíme na základe vývoja presnosti modelu v čase, ak sa dlhší čas presnosť nezvyšuje, je možné tréning ukončiť. A naopak, ak sa presnosť viditeľne zvyšuje, je nevhodné tréning ukončiť.

Z kriviek validačnej a trénovacej straty je možné vyčítať dôležité informácie o priebehu tréningu ako napríklad overfitting a underfitting. Overfitting je rozpoznateľný, keď trénovacia strata klesá no validačná sa zvyšuje alebo neklesá. To znamená že model sa zlepšuje na trénovacích dátach no nieje schopný generalizovať na iných a validačných dátach. Underfitting je rozpoznateľný, keď validačná aj trénovacia strata je vysoká a má problém klesať. Znamená, že model má problém učiť sa na trénovacích dátach. Optimálny tréning je vyčítateľný, keď klesá ako validačná tak aj trénovacia krivka.

Keďže sme sa rozhodli trénovať bez validačných dát z dôvodu lepšieho porovnania výkonnosti modelu tým, že trénovacie dáta budú vždy rovnaké, zatiaľ čo pri náhodnom oddelení validačných dát by práve toto náhodne rozdelenie mohlo spôsobiť rozdiel, nebudeme schopní čítať to, či sa model naozaj učí generalizovať. Sledovanie kriviek je napriek tomu informatívne, pretože stále môžeme vidieť, či sa model dokáže učiť.




Obr. 3.9: Krivky učenia pri 1000 epochách. Vľavo hore nnU-Net Skip CBAM, vpravo hore nnU-Net Skip CBAM mixup, vľavo dole nnU-Net Skip SE down, AG up, a vpravo dole nnU-Net Skip SE down, AG up s mixupom.

Z vyššie uvedených kriviek je možné vyčítať, že aj pri 1000 epochách je model schopný sa učiť. Síce evalvačné (zelené) krivky na ľavej strane, teda na modeloch bez mixupu sú mierne vyššie než pri modeloch bez mixupu, no evalvácia na testovacích dátach je lepšia pri modeloch s mixupom. To potvrdzuje predpoklad, že mixup znižuje pretrénovanie a napomáha generalizácii na iných dátach.

3.8 Následné spracovanie výsledkov segmentácie

Na finálnu úpravu masiek generovaných nnU-Netom je možné použiť viacero techník následného spracovania. Pri sledovaní generovaných masiek sme si všimli niekoľko problémov. Niektoré masky obsahovali diery, teda pozadie, kde by mala byť rana. Pri sledovaní referenčných obrázkov sme nenašli ani jeden taký, ktorý by obsahoval dieru. Na základe toho sme usúdili, že vyplnenie takýchto dier môže

zvýšiť presnosť predikcie. Ďalším zaujímavým zistením bolo, že model niekedy generoval malé masky, ktoré sú primálne na to, aby boli vredom a aby ich lekár bol schopný označiť. To môžeme vyriešiť odstránením primálnych masiek a nahradením ich pozadím. Poslednou úpravou, ktorá má šancu zlepšiť výsledok je korekcia hrán, keďže tú použili aj autori súboru dát pri tvorbe masiek. Autori použili algoritmus aktívnych obrysov, ktorý spôsobil zjemnenie obrysov masiek [36].



Obr. 3.10: Obrázok vľavo, segmentačná maska v strede a segmentačná maska po vyplnení dier vpravo.

Následné spracovanie	DSC	FNE	FPE
Žiaden	0.70751	0.2251	0.2498
Vyplnenie dier, odstránenie malých masiek	0.70754	0.2254	0.2499
Vyplnenie dier, odstránenie malých masiek, korekcia hrán	0.7055	0.2168	0.2613

Tabuľka 3.7: Porovnanie výsledkov následného spracovania najlepšieho modelu.

Tabuľka 3.7 ukazuje, že vyplnenie dier pomáha zlepšiť DSC skóre, aj keď iba nepatrne. Algoritmus aktívnych obrysov zhoršil skóre

3.9 Hľadanie správnej funkcie chyby

Funkcie chyby majú za úlohu kvantifikovať rozdiel medzi predikovanými maskami a referenčnými maskami a poskytnúť meradlo, ako dobre sa modelu darí. Existuje veľké množstvo funkcií chyby používaných pri segmentácii a každá má

nejaké výhody a nevýhody. Na najlepšom modeli vyskúšame viaceré funkcie chyby a porovnáme výsledky. Konkrétne pôjde o Dice loss, Cross entropy loss, Focal loss a ich kombinácie. funkcie chyby sú komplikovaná a rozsiahla téma, preto v tejto práci bude poskytnuté len stručné vysvetlenie funkcií a ich výhod.

Cross entropy loss je miera rozdielu medzi predpovedanými a skutočnými pravdepodobnostnými distribúciami segmentačných tried. Cross entropy má predpoklad fungovať dobre pri väčšej sade dát a vyvážených triedach.

Dice loss je inšpirovaná Dice metrikou používanou na evalváciu dát. Táto funkcia je vhodná na menej vyvážené datasety.

Focal loss je funkcia špeciálne navrhnutá na riešenie problému nerovnováhy tried v segmentácii. Focal loss priradí vyššiu váhu k nesprávne klasifikovaným príkladom, ktoré sú ťažké správne klasifikovať. Focal loss môže pomôcť zlepšiť výkon modelu, keď v obraze existuje veľa pozadia, ale nemusí byť tak efektívna, keď sú predmety popredia malé.

Väčšinou sa odporúča používať kombináciu viacerých funkcií chyby, vďaka čomu sa vykompenzujú výhody a nevýhody kombinovaných funkcií. Kombinácia rôznych funkcií chyby môže byť napríklad Dice loss pre segmentáciu objektov a cross-entropy loss pre segmentáciu pozadia. Tento prístup môže pomôcť zlepšiť presnosť detekcie objektov, zatiaľ čo zároveň umožní správne segmentovať pozadie. Práve takúto kombináciu používa nnU-Net ako predvolené nastavenie.

Funkcia chyby	DSC	FNE	FPE
Dice + CE	0.7075	0.2251	0.2498
CE	0.6991	0.210	0.274
Focal	0.7014	0.222	0.2613
Dice	0.7094	0.241	0.2313


Tabuľka 3.8: Porovnanie funkcií chyby na najlepšom modeli

Dice funkcia chyby sa osvedčila ako najlepšia pre DFU súbor údajov. Dôvodom môže byť to, že Dice funkcia chyby je vhodná na nevyvážené súbory dát a je schopná zachytiť aj malé rany, a súbor dát bol príliš nevyvážený na to, aby pomohlo kombinovať dice a cross-entropy funkciu.

3.10 Architektúra najúspešnejšieho modelu

Najúspešnejší model je teda nnU-Net obohatený o squeeze and excite bloky, reziduálne spojenia v kontrakčnej časti a attention gates v expanzívnej časti, s pri-

danou mixup augmentáciou s tresholdom 0.25 a alphou 0.3. Model je trénovaný s Dice funkciou chyby. Bližší pohľad na pozíciu blokov v architektúre poskytne diagram.



Obr. 3.11: Architektúra nami navrhnutého najúspešnejšieho modelu pre DFU.

V diagrame 3.11 je možné vidieť, že sieť sa skladá z ôsmich vrstiev. NnU-Net používa na konvolúcie modul s názvom StackedConvLayers, ktoré sa skladajú z postupnosti dvoch 2D konvolučných vrstiev s kernelom veľkosti 3x3, stride 2x2 v prvom bloku a 1x1 v druhom bloku a paddingom 1x1. Po každej konvolúcii je aplikovaná inštančná normalizácia a LeakyRelu funkcia.

Reziduálne spojenia sú aplikované pred vykonaním SE. Skladajú sa z 1x1 konvolúcie na zredukovanie dimenzionality a na úpravu tvaru do rovnakej podoby ako výstup z konvolúcie a následného súčtu prvkov.

Následujú SE bloky, ktoré zvyraznia dôležité kanály, výstup SE bloku je uložený do preskakovaných spojení, následne na výstup je aplikovaný maxpooling a cyklus sa opakuje. SE bloky majú redukciu nastavenú na 16, teda squeeze operácia stlačí počet znakov o vstupný počet znakov/16. Excite operácia naspäť zvýši počet znakov na pôvodný.

V expanzívnej časti je zväčšený výstup poslaný do attention gate spolu s preskakovaným spojením, výstup z bloku je následne sčítaný so zväčšeným výstupom. To sa opakuje v každej vrstve. Nami použitý attention blok je mierne upravená verzia pôvodného bloku, pretože používa aj batch normalizáciu po každej konvolúcii, ktorá napomáha regularizácii a stabilizácii tréovania. Konvolúcie v našom attention mechanizme majú redukciu nastavenú na 4. Nižšia redukcia nebola možná, pretože pre pamäťové nároky modelu by to nebolo možné splniť na našej grafickej karte.

Na konci každej vrstvy v expanzívnej časti je použitý deep supervision modul, ktorý umožňuje získať výstupy aj z vnútorných vrstiev a preukázateľne napomáha zlepšiť výsledky tréovania.

Diskusia

Na zistenie problémov, s ktorými sa neurónová sieť stretáva pri predikcii DFU sa pozrieme na 3 obrázky. V prvom budú predikcie s DSC blízky alebo rovným nule. V druhom budú obrázky s DSC 0.7, čo predstavuje priemerné DSC skóre. A v poslednom obrázku budú znázornené predikcie s DSC väčším ako 0.9. Vďaka tomu pochopíme silné a slabé stránky modelu.

Lekárskom označenú ranu predstavuje zelená farba. Masku generovanú modelom predstavuje červená a prelínanie oboch masiek predstavuje oranžová farba.



Obr. 3.12: Porovnanie predikcie modelu s GT s veľmi nízkym DSC

Vďaka obrázku znázorňujúcemu nesprávne predikcie je možné rozoznať najslabšie stránky modelu.

Je vidieť, že model si občas pomýli necht s vredom. Na strednom hornom obrázku je veľmi podobný necht označený expertom vred. Na ľavom hornom obrázku model označil tmavú medzeru medzi prstami, ako vred. Zároveň je vidieť, že model má problém s DFU v skorej fáze vývoja, ktorá ja spozorovateľná mozolmi, suchou popraskanou kožou alebo bradavicami. V strednom dolnom obrázku je vidieť prehliadnutý Ischemický DFU. Možnou príčinou prehliadnutia je

slabý kontrast so zvyškom nohy, ktorá je už postihnutá nektrózou. Nakoniec je dôležité poukázať na anomáliu, kde model označil časť pravítka ako vred.

Riešením niektorých problémov by mohlo byť pridanie fotiek zdravých nôh, z ktorých by sa model mal potenciál naučiť rozoznávať medzery medzi prstami a nechty od DFU.



Obr. 3.13: Porovnanie predikcie modelu s DSC skóre v rozmedzí 0.6 - 0.8.

Obrázok zobrazujúci mierne nepresné predikcie poukáže na malé nepresnosti, ktoré môžu spôsobiť problémy pri predikcii.

Horný ľavý obrázok ukazuje, že model pri neuropatickom DFU má tendenciu zvýrazniť hlavne vnútornú časť rany, zatiaľ čo doktor vyznačí aj časť kalusu, pod ktorým sa rana nachádza. Naopak, v druhom a treťom hornom obrázku model vyznačil aj okolitú kožu, ktorú nedokázal rozoznať od neuroischemického DFU. V ľavom dolnom obrázku si model pomýlil začervenaný prst s pokračujúcou ranou.

V dolnom strednom a pravom obrázku je vidieť už vyššie spomínaný problém s nechtami a DFU v počiatočnom štádiu. Pri nechtoch je zaujímavé, že nedochádza len k falošnej pozitívnej ale aj falošne negatívnej predikcii.



Obr. 3.14: Porovnanie predikcie modelu s DSC skóre väčším, ako 0.9.

Najpresnejšie predikcie robí model, ak je DFU pod čo najkolmejším uhlom. Je to vidieť na hornom ľavom obrázku, lebo ide o rovnakú ranu, ako v hornom ľavom obrázku 3.12, sfotenu z priamejšieho uhla. Model dokáže bezproblémovo označiť vyčistené neuropatické DFU (ľavý a stredný horný obrázok). Všetky vyššie uvedené obrázky majú spoločné to, že je viditeľné ohraničenie medzi zdravou pokožkou a ranou. V ľavom dolnom obrázku model dokázal rozoznať ischemický DFU na prste, narozdiel od obrázka 3.12, pravdepodobne vďaka farebnému rozdielu medzi prstom a zdravou kožou.

4 Záver

Sémantická segmentácia DFU má potenciál zjednodušiť diagnostiku a kontrolu tejto choroby. Okrem toho, segmentácia môže byť užitočná pri liečbe, napríklad pri výrobe špeciálnej obuvi alebo vložiek, kde by maska rany poskytla tvar výseku podrážky, ktorý by minimalizoval tlak na postihnutú oblasť a tým urýchlil proces hojenia rany. Taktiež, dáta vyzbierané pri pravidelnej segmentácii môžu byť využité ako nástroj pri výskume účinnosti rôznych liečebných metód a ich vplyvu na rýchlosť hojenia rán.

V práci sme analyzovali plne konvolučnú sieť nnU-Net, a na základe zistení sme navrhli potenciálne vylepšenia funkcionality a architektúry. Do nnU-Netu sme pridali asymetrickú mixup augmentáciu s tresholdom 25% a parametrom alpha 0.3, ktorá dokázateľne pomohla znížiť pretrénovanie a napomohla modelu rozhodnúť sa medzi pozadím a ranou v nevýrazných prípadoch. Pridaním reziduálnych spojení sme pomohli modelu zabrániť problému miznúcich gradientov. Rozsiahlou analýzou a experimentami sme preskúmali kanálové, priestorové a kombinované pozornosťné mechanizmy. Potvrdili sme hypotézu, že pridaním týchto pozorností sa nnU-Net modelom darí viac sa sústrediť na dôležité znaky obrázka, a ignorovať tie nedôležité pre učenie. Kombinácia kanálovej pozornosti, konkrétne squeeze-and-excite bloky pridané do kontrakčnej časti a priestorovej - Attention gates pridanej do expanzívnej časti sa ukázala ako najlepšia modifikácia architektúry nnU-Netu. Týmto modelom sme dosiahli DSC skóre 0.7094. Druhou najlepšou modifikáciou boli CBAM bloky pridané do kontrakčnej časti.

Pomocou následného spracovania vo forme vyplnenia dier masiek a odstránenia veľmi malých masiek sme dokázali mierne vylepšiť najlepší výsledok.

Porovnali sme viacero funkcií chyby a našli sme najlepšiu funkciu pre DFU súbor údajov - Dice loss.

Analýzou predikovaných masiek sme odhalili slabé stránky modelu. Tými sú hlavne rany v počiatočnej fáze vývoja v podobe suchej pokožky alebo bradavice, a mýlenie si nechtov alebo medzier medzi prstami s ranou.

Celkovo sme v rámci nášho výskumu dosiahli výrazné zlepšenie segmentá-

cie DFU pomocou navrhnutých úprav a modifikácií nnU-Net architektúry. Vďaka tomu sa môže stať cenným nástrojom pre diagnostiku a liečbu DFU v modernej medicíne. Výhodou modifikácie nnU-Netu je prepoužiteľnosť kódu na iné medicínske segmentačné problémy a súbory údajov.

Práca môže v budúcnosti pokračovať viacerými smermi. Prvou možnosťou je úprava pozornosťných mechanizmov a pokročilých augmentácii tak, aby mohli byť aplikovateľné na 3-D dáta a dátové sady s viac než 2 triedami. Následne bude potrebné preskúmať účinnosť nami navrhnutých modelov na segmentáciu DFU na iných dátových sadách.

Ďalším príkladom pokračovania práce je vylepšovanie navrhnutých modelov pre segmentáciu DFU. Nápomocné bude preskúmanie najnovších článkov o segmentácii DFU a z týchto poznatkov navrhnuť vylepšené riešenia. V rámci pokusu o zlepšenie výsledkov modelu by bolo vhodné skúsiť obohatiť tréningovú dátovú sadu o fotky zdravých nôh. Tieto fotky chýbali v pôvodnej tréningovej sade, ale boli prítomné v testovacej sade. Obohatenie dát by mohlo pomôcť modelu v situáciách, keď sa na fotografiách objavujú objekty podobné ranám. Výsledkom by bolo zníženie falošne pozitívnych výsledkov.

Na to, aby bola segmentácia jednoducho vykonaná pacientom, bola by vhodná implementácia segmentácie do mobilnej aplikácie, ktorá pacientovi bude poskytovať možnosť pravidelnej kontroly rán.

Literatúra

1. ARMSTRONG; G., David; BOULTON; J.M., Andrew; BUS; A., Sicco. Diabetic Foot Ulcers and Their Recurrence. *New England Journal of Medicine*. 2017, roč. 376, č. 24, s. 2367–2375. Dostupné z DOI: 10.1056/NEJMr1615439. PMID: 28614678.
2. ROGLIC, G.; ORGANIZATION, World Health. *Global Report on Diabetes*. World Health Organization, 2016. ISBN 9789241565257. Dostupné tiež z: <https://books.google.sk/books?id=tNsEkAEACAAJ>.
3. JW, Walsh; OJ, Hoffstad; MO, Sullivan; DJ., Margolis. Association of diabetic foot ulcer and death in a population-based cohort from the United Kingdom. *New England Journal of Medicine*. 2016, roč. 33, č. 11, s. 1493–1498. Dostupné z DOI: 10.1111/dme.13054.
4. LIPSKY; A., Benjamin; BERENDT; R., Anthony; CORNIA; B., Paul; PILE; C., James; PETERS; G., Edgar J.; ARMSTRONG; G., David; DEERY; GUNNER, H.; EMBIL; M., John; JOSEPH; S., Warren; KARCHMER; W., Adolf; PINZUR; S., Michael; SENNEVILLE; ERIC. 2012 Infectious Diseases Society of America Clinical Practice Guideline for the Diagnosis and Treatment of Diabetic Foot Infections. *Clinical Infectious Diseases*. 2012, roč. 54, č. 12, e132–e173. Dostupné z DOI: 10.1093/cid/cis346.
5. ZHANG, Pengzi; LU, Jing; JING, Yali; TANG, Sunyinyan; ZHU, Dalong; BI, Yan. Global epidemiology of diabetic foot ulceration: a systematic review and meta-analysis. *Annals of Medicine*. 2017, roč. 49, č. 2, s. 106–116. Dostupné z DOI: 10.1080/07853890.2016.1231932. PMID: 27585063.
6. ARMSTRONG, D. G.; LAVERY, L. A. Diabetic foot ulcers: prevention, diagnosis and classification. *Am Fam Physician*. 1998, roč. 57, č. 6, s. 1325–1332.
7. CHADWICK, Paul; EDMONDS, Michael; MCCARDLE, Joanne; ARMSTRONG, David. Best Practice Guidelines: Wound Management in Diabetic Foot Ulcers. *Am Fam Physician*. 2013. Dostupné tiež z: www.woundsinternational.com.

8. FARD, A. Shojaie; ESMAELZADEH, M.; LARIJANI, B. Assessment and treatment of diabetic foot ulcer. *International Journal of Clinical Practice*. 2007, roč. 61, č. 11, s. 1931–1938. Dostupné z doi: <https://doi.org/10.1111/j.1742-1241.2007.01534.x>.
9. BANDYK, Dennis F. The diabetic foot: Pathophysiology, evaluation, and treatment. *Seminars in Vascular Surgery*. 2018, roč. 31, č. 2, s. 43–48. ISSN 0895-7967. Dostupné z doi: <https://doi.org/10.1053/j.semvascsurg.2019.02.001>. Fighting Diabetic Foot Ulcers.
10. ZHANG, Zhiming; ZHANG, Wenjing; XU, Yuqi; LIU, Dewu. Efficacy of hyperbaric oxygen therapy for diabetic foot ulcers: An updated systematic review and meta-analysis. *Asian Journal of Surgery*. 2022, roč. 45, č. 1, s. 68–78. ISSN 1015-9584. Dostupné z doi: <https://doi.org/10.1016/j.asjsur.2021.07.047>.
11. FJ, Álvaro-Afonso; Y, García-Álvarez; JL, Lázaro-Martínez; D, Kakagia; N., Papanas. Advances in Dermoepidermal Skin Substitutes for Diabetic Foot Ulcers. *Curr Vasc Pharmacol*. 2020, č. 1, s. 182–192. Dostupné z doi: [doi : 10.2174/1570161117666190408170144](https://doi.org/10.2174/1570161117666190408170144).
12. ZIMNY; STEFAN; SCHATZ; H; PFOHL; MARTIN. The Effects of Ulcer Size on the Wound Radius Reductions and Healing Times in Neuropathic Diabetic Foot Ulcers. *Experimental and clinical endocrinology and diabetes : official journal, German Society of Endocrinology and German Diabetes Association*. 2004, roč. 112, s. 191–4. Dostupné z doi: [10.1055/s-2004-817932](https://doi.org/10.1055/s-2004-817932).
13. JIANG; HONGJIE; OCHOA; MANUEL; JAIN; VAIBHAV; ZIAIE; BABAK. A laser-customizable insole for selective topical oxygen delivery to diabetic foot ulcers. *MRS Communications*. 2018, roč. 8, s. 1–7. Dostupné z doi: [10.1557/mrc.2018.181](https://doi.org/10.1557/mrc.2018.181).
14. RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. 2015. Dostupné tiež z: <http://arxiv.org/abs/1505.04597>. cite arxiv:1505.04597Comment: conditionally accepted at MICCAI 2015.
15. CIRESAN, Dan; GIUSTI, Alessandro; GAMBARDELLA, Luca; SCHMIDHUBER, Jürgen. Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images. In: PEREIRA, F.; BURGESS, C.J.; BOTTOU, L.; WEINBERGER, K.Q. (ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2012, zv. 25. Dostupné tiež z: <https://proceedings>.

- neurips . cc / paper / 2012 / file / 459a4ddcb586f24efd9395aa7662bc7c - Paper . pdf.
16. ISENSEE, Fabian; PETERSEN, Jens; KLEIN, André; ZIMMERER, David; JAEGER, Paul F.; KOHL, Simon; WASSERTHAL, Jakob; KÖHLER, Gregor; NORAJITRA, Tobias; WIRKERT, Sebastian J.; MAIER-HEIN, Klaus H. nnU-Net: Self-adapting Framework for U-Net-Based Medical Image Segmentation. *CoRR*. 2018, roč. abs/1809.10486. Dostupné z arXiv: 1809.10486.
 17. ANTONELLI, Michela; REINKE, Annika; BAKAS, Spyridon; FARAHANI, Keyvan; KOPP-SCHNEIDER, Annette; LANDMAN, Bennett A.; LITJENS, Geert; MENZE, Bjoern; RONNEBERGER, Olaf; SUMMERS, Ronald M.; GINNEKEN, Bram van; BILELLO, Michel; BILIC, Patrick; CHRIST, Patrick F.; DO, Richard K. G.; GOLLUB, Marc J.; HECKERS, Stephan H.; HUISMAN, Henkjan; JARNAGIN, William R.; MCHUGO, Maureen K.; NAPEL, Sandy; PERNICKA, Jennifer S. Golia; RHODE, Kawal; TOBON-GOMEZ, Catalina; VORONTSOV, Eugene; MEAKIN, James A.; OURSELIN, Sebastien; WIESENFARTH, Manuel; ARBELÁEZ, Pablo; BAE, Byeonguk; CHEN, Sihong; DAZA, Laura; FENG, Jianjiang; HE, Baochun; ISENSEE, Fabian; JI, Yuanfeng; JIA, Fucang; KIM, Ildoo; MAIER-HEIN, Klaus; MERHOF, Dorit; PAI, Akshay; PARK, Beomhee; PERSLEV, Mathias; REZAIIFAR, Ramin; RIPPEL, Oliver; SARASUA, Ignacio; SHEN, Wei; SON, Jaemin; WACHINGER, Christian; WANG, Liansheng; WANG, Yan; XIA, Yingda; XU, Daguang; XU, Zhanwei; ZHENG, Yefeng; SIMPSON, Amber L.; MAIER-HEIN, Lena; CARDOSO, M. Jorge. The Medical Segmentation Decathlon. *Nature Communications*. 2022, roč. 13, č. 1. Dostupné z doi: 10.1038/s41467-022-30695-9.
 18. EATON-ROSEN, Zach; BRAGMAN, Felix; OURSELIN, Sebastien; CARDOSO, M Jorge. Improving data augmentation for medical image segmentation. 2018.
 19. ZHANG, Hongyi; CISSE, Moustapha; DAUPHIN, Yann N.; LOPEZ-PAZ, David. *mixup: Beyond Empirical Risk Minimization*. arXiv, 2017. Dostupné z doi: 10.48550/ARXIV.1710.09412.
 20. LI, Zeju; KAMNITSAS, Konstantinos; GLOCKER, Ben. *Overfitting of neural nets under class imbalance: Analysis and improvements for segmentation*. arXiv, 2019. Dostupné z doi: 10.48550/ARXIV.1907.10982.
 21. ISAKSSON, Lars; SUMMERS, Paul; RAIMONDI, Sara; GANDINI, Sara; BHALERAO, Abhir; MARVASO, Giulia; PETRALIA, Giuseppe; PEPA, Matteo; JERECZEK-FOSSA, Barbara. Mixup (Sample Pairing) Can Improve the Per-

- formance of Deep Segmentation Networks. *Journal of Artificial Intelligence and Soft Computing Research*. 2022, roč. 12, s. 29–39. Dostupné z [doi: 10.2478/jaiscr-2022-0003](https://doi.org/10.2478/jaiscr-2022-0003).
22. DROZDZAL, Michal; VORONTSOV, Eugene; CHARTRAND, Gabriel; KADOURY, Samuel; PAL, Chris. The Importance of Skip Connections in Biomedical Image Segmentation. In: CARNEIRO, Gustavo; MATEUS, Diana; PETER, Loïc; BRADLEY, Andrew; TAVARES, João Manuel R. S.; BELAGIANIS, Vasileios; PAPA, João Paulo; NASCIMENTO, Jacinto C.; LOOG, Marco; LU, Zhi; CARDOSO, Jaime S.; CORNEBISE, Julien (ed.). *Deep Learning and Data Labeling for Medical Applications*. Cham: Springer International Publishing, 2016, s. 179–187. ISBN 978-3-319-46976-8.
 23. HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. *Deep Residual Learning for Image Recognition*. arXiv, 2015. Dostupné z [doi: 10.48550/ARXIV.1512.03385](https://doi.org/10.48550/ARXIV.1512.03385).
 24. WU, Dongxian; WANG, Yisen; XIA, Shu-Tao; BAILEY, James; MA, Xingjun. *Skip Connections Matter: On the Transferability of Adversarial Examples Generated with ResNets*. arXiv, 2020. Dostupné z [doi: 10.48550/ARXIV.2002.05990](https://doi.org/10.48550/ARXIV.2002.05990).
 25. YANG, Xiao. An Overview of the Attention Mechanisms in Computer Vision. *Journal of Physics: Conference Series*. 2020, roč. 1693, s. 012173. Dostupné z [doi: 10.1088/1742-6596/1693/1/012173](https://doi.org/10.1088/1742-6596/1693/1/012173).
 26. GUO, Meng-Hao; XU, Tian-Xing; LIU, Jiang-Jiang; LIU, Zheng-Ning; JIANG, Peng-Tao; MU, Tai-Jiang; ZHANG, Song-Hai; MARTIN, Ralph R.; CHENG, Ming-Ming; HU, Shi-Min. Attention mechanisms in computer vision: A survey. *Computational Visual Media*. 2022, roč. 8, č. 3, s. 331–368. Dostupné z [doi: 10.1007/s41095-022-0271-y](https://doi.org/10.1007/s41095-022-0271-y).
 27. WOO, Sanghyun; PARK, Jongchan; LEE, Joon-Young; KWEON, In So. CBAM: Convolutional Block Attention Module. In: *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018.
 28. CHEN, Long; ZHANG, Hanwang; XIAO, Jun; NIE, Liqiang; SHAO, Jian; LIU, Wei; CHUA, Tat-Seng. SCA-CNN: Spatial and Channel-wise Attention in Convolutional Networks for Image Captioning. arXiv, 2016. Dostupné z [doi: 10.48550/ARXIV.1611.05594](https://doi.org/10.48550/ARXIV.1611.05594).
 29. HU, Jie; SHEN, Li; ALBANIE, Samuel; SUN, Gang; WU, Enhua. *Squeeze-and-Excitation Networks*. arXiv, 2017. Dostupné z [doi: 10.48550/ARXIV.1709.01507](https://doi.org/10.48550/ARXIV.1709.01507).

30. RUNDO, Leonardo; HAN, Changhee; NAGANO, Yudai; ZHANG, Jin; HATAYA, Ryuichiro; MILITELLO, Carmelo; TANGHERLONI, Andrea; NOBILE, Marco S.; FERRETTI, Claudio; BESOZZI, Daniela; GILARDI, Maria Carla; VITABILE, Salvatore; MAURI, Giancarlo; NAKAYAMA, Hideki; CAZZANIGA, Paolo. *USE-Net: incorporating Squeeze-and-Excitation blocks into U-Net for prostate zonal segmentation of multi-institutional MRI datasets*. arXiv, 2019. Dostupné z doi: 10.48550/ARXIV.1904.08254.
31. OKTAY, Ozan; SCHLEMPER, Jo; FOLGOC, Loic Le; LEE, Matthew; HEINRICH, Mattias; MISAWA, Kazunari; MORI, Kensaku; MCDONAGH, Steven; HAMMERLA, Nils Y; KAINZ, Bernhard; GLOCKER, Ben; RUECKERT, Daniel. *Attention U-Net: Learning Where to Look for the Pancreas*. arXiv, 2018. Dostupné z doi: 10.48550/ARXIV.1804.03999.
32. NI, Zhen-Liang; BIAN, Gui-Bin; ZHOU, Xiao-Hu; HOU, Zeng-Guang; XIE, Xiao-Liang; WANG, Chen; ZHOU, Yan-Jie; LI, Rui-Qi; LI, Zhen. *Raunet: Residual attention u-net for semantic segmentation of cataract surgical instruments*. In: *International Conference on Neural Information Processing*. 2019, s. 139–149.
33. PARK, Jongchan; WOO, Sanghyun; LEE, Joon-Young; KWEON, In So. *BAM: Bottleneck Attention Module*. arXiv, 2018. Dostupné z doi: 10.48550/ARXIV.1807.06514.
34. MISRA, Diganta; NALAMADA, Trikey; ARASANIPALAI, Ajay Uppili; HOU, Qibin. *Rotate to Attend: Convolutional Triplet Attention Module*. arXiv, 2020. Dostupné z doi: 10.48550/ARXIV.2010.03045.
35. WANG, Chuanbo; MAHBOD, Amirreza; ELLINGER, Isabella; GALDRAN, Adrian; GOPALAKRISHNAN, Sandeep; NIEZGODA, Jeffrey; YU, Zeyun. *FUSeg: The Foot Ulcer Segmentation Challenge*. arXiv, 2022. Dostupné z doi: 10.48550/ARXIV.2201.00414.
36. KENDRICK, Connah; CASSIDY, Bill; PAPPACHAN, Joseph M.; O'SHEA, Claire; FERNANDEZ, Cornelious J.; CHACKO, Elias; JACOB, Koshy; REEVES, Neil D.; YAP, Moi Hoon. *Translating Clinical Delineation of Diabetic Foot Ulcers into Machine Interpretable Segmentation*. arXiv, 2022. Dostupné z doi: 10.48550/ARXIV.2204.11618.
37. ZHAO, Li; ZHOU, Dongming; JIN, Xin; ZHU, Weina. *nn-TransUNet: An Automatic Deep Learning Pipeline for Heart MRI Segmentation*. *Life*. 2022, roč. 12, č. 10. ISSN 2075-1729. Dostupné z doi: 10.3390/life12101570.

38. WANG, Qilong; WU, Banggu; ZHU, Pengfei; LI, Peihua; ZUO, Wangmeng; HU, Qinghua. *ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks*. arXiv, 2019. Dostupné z DOI: [10.48550/ARXIV.1910.03151](https://doi.org/10.48550/ARXIV.1910.03151).

Zoznam príloh

Príloha A CD médium – záverečná práca v elektronickej podobe,