

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2025

Bc. Michael Malík



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

ANALÝZA SEGMENTAČNÍCH MODELŮ PRO DIAGNOSTIKU ONEMOCNĚNÍ ARTÉRIÍ V ANGIOGRAFICKÝCH OBRAZECH

ANALYSIS OF SEGMENTATION MODELS FOR CORONAR ARTERY DISEASE IN XCA IMAGES

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Michael Malík

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Chmelík, Ph.D.

BRNO 2025

Diplomová práce

magisterský navazující studijní program **Bioinženýrství**

Ústav biomedicínského inženýrství

Student: Bc. Michael Malík

ID: 230398

Ročník: 2

Akademický rok: 2024/25

NÁZEV TÉMATU:

Analýza segmentačních modelů pro diagnostiku onemocnění artérií v angiografických obrazech

POKYNY PRO VYPRACOVÁNÍ:

1) Provedte literární rešerši zabývající se segmentací tepen ve snímcích rentgenové kontrastní angiografie (XCA). 2) Na základě rešerše popište alespoň tři vhodné segmentační modely a jeden z nich také implementujte. 3) Implementovaný model natrénujte na části dostupného veřejného datasetu se zaměřením na segmentaci tepen. 4) Implementujte alespoň jeden další model a proveďte analýzu vlivu jejich hyperparametrů na kvalitu výsledné segmentace. 5) Oba dva modely rozšiřte také o segmentaci oblastí stenózy. 6) Výsledky statisticky vyhodnoťte a diskutujte praktická doporučení.

DOPORUČENÁ LITERATURA:

[1] POPOV, Maxim, Akmaral AMANTURDIEVA, Nuren ZHAKSYLYK, et al. Dataset for Automatic Region-based Coronary Artery Disease Diagnostics Using X-Ray Angiography Images. Scientific Data [online]. 2024, 11(1) [cit. 2024-09-02]. ISSN 2052-4463. DOI:10.1038/s41597-023-02871-z

[2] ZHANG, Hongwei, Zhifan GAO, Dong ZHANG, William Kongto HAU a Heye ZHANG. Progressive Perception Learning for Main Coronary Segmentation in X-Ray Angiography. IEEE Transactions on Medical Imaging [online]. 2023, 42(3), 864-879 [cit. 2024-09-02]. ISSN 0278-0062. DOI:10.1109/TMI.2022.3219126

Termín zadání: 10.2.2025

Termín odevzdání: 28.5.2025

Vedoucí práce: Ing. Jiří Chmelík, Ph.D.

doc. Ing. Radim Kolář, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato diplomová práce se zabývá segmentací tepen a stenóz na rentgenových kontrastních angiografických snímcích (XCA) pomocí modelů U-Net a DeepLabV3+. Součástí práce byla také analýza vlivu jednotlivých hyperparametrů na výslednou výkonnost modelu s využitím metod SHAP a fANOVA. Modely byly testovány na datasetu ARCADE ve variantách s předzpracováním obrazu (CLAHE, top-hat transformace) i bez něj. Výkon byl hodnocen pomocí Dice skóre, senzitivity, PPV a Jaccardova indexu. Nejlepších výsledků v segmentaci tepen dosáhl model DeepLabV3+ bez předzpracování, zatímco pro stenózy byl nejúspěšnější DeepLabV3+ s předzpracováním. Výsledky potvrzují význam volby architektury i předzpracování pro přesnost segmentace.

KLÍČOVÁ SLOVA

Hluboké učení, segmentace, rentgenová kontrastní angiografie, neuronové sítě, analýza modelu

ABSTRACT

This thesis focuses on the segmentation of arteries and stenoses in X-ray contrast angiographic (XCA) images using U-Net and DeepLabV3+ models. The work also includes an analysis of the influence of individual hyperparameters on model performance using SHAP and fANOVA methods. The models were evaluated on the ARCADE dataset, both with and without image preprocessing techniques (CLAHE, top-hat transformation). Performance was assessed using the Dice score, sensitivity, PPV, and the Jaccard index. The best results in artery segmentation were achieved by the DeepLabV3+ model without preprocessing, whereas DeepLabV3+ with preprocessing performed best in stenosis segmentation. The results highlight the importance of model architecture and preprocessing in achieving accurate segmentation.

KEYWORDS

Deep-learning, segmentation, XCA, neural networks, model analysis

MALÍK, Michael. *Analýza segmentačních modelů pro diagnostiku onemocnění artérií v angiografických obrazech*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2025, 75 s. Diplomová práce. Vedoucí práce: Ing. Jiří Chmelík, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Bc. Michael Malík

VUT ID autora: 230398

Typ práce: Diplomová práce

Akademický rok: 2024/25

Téma závěrečné práce: Analýza segmentačních modelů pro diagnostiku onemocnění artérií v angiografických obrazech

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno
.....
podpis autora*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Jiřímu Chmelíkovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci, které přispěly k jejímu dokončení. Dále bych rád poděkoval své rodině, která mě podporovala po celou dobu studia.

Obsah

Úvod	10
1 Metody segmentace tepen na rentgenových angiogramech	11
1.1 Rentgenová kontrastní angiografie	11
1.2 Segmentace tepen ve snímcích XCA	12
1.3 Segmentace založená na hlubokém učení	12
1.4 Srovnání segmentačních metod	20
1.5 Výběr segmentačních modelů	20
2 Implementace segmentačních modelů	22
2.1 ARCADE dataset	22
2.2 Předzpracování dat	26
2.3 Architektura modelu U-Net	29
2.4 Architektura upraveného modelu AngioNet	29
2.5 Optimalizace hyperparametrů	31
2.6 Trénování a validace modelů	33
3 Statistická analýza výsledků	38
3.1 Analýza vlivu hyperparametrů na kvalitu výsledné segmentace	38
3.2 Dosažené výsledky na testovací sadě dat	48
3.3 Statistické vyhodnocení segmentačních modelů	51
3.4 Diskuze	56
Závěr	60
Literatura	61
Seznam symbolů a zkratk	66
Seznam příloh	67
A Optimalizace na datasetu ARCADE, část Syntax	68
A.1 Výsledky modelu DeepLabV3+	68
A.2 Výsledky modelu U-Net	70
B Optimalizace na datasetu ARCADE, část Stenosis	72
B.1 Výsledky modelu DeepLabV3+	72
B.2 Výsledky modelu U-Net	74

Seznam obrázků

1.1	Segmentace hlavních koronárních tepen	11
1.2	Architektura U-Net	13
1.3	Postup pro detekci stenózy z XCA dat	14
1.4	Architektura sítě StenUNet	14
1.5	Architektura sítě SVS-net	16
1.6	Architektura sítě AngioNet	18
1.7	Algoritmus YOLO-Angio	19
2.1	Struktura datasetu ARCADE	22
2.2	Příklad zobrazení snímku XCA a jeho anotované masky	23
2.3	Snímek XCA s příslušnou nedokonalou anotovanou maskou	24
2.4	Snímek XCA s příslušnou anotovanou maskou stenózy	25
2.5	Snímek XCA s příslušnou nepřesnou anotovanou maskou stenózy	26
2.6	Metodologie SYNTAX	26
2.7	Adaptivní vylepšení histogramu s omezeným kontrastem	27
2.8	Snímek XCA po aplikaci předzpracování	28
2.9	Modul dilatovaného prostorového pyramidového sdružování (ASPP)	30
2.10	Porovnání průběhu ztrátové chyby během trénování na datasetu Syntax	34
2.11	Porovnání průběhu ztrátové chyby během trénování na datasetu Ste- nosis	35
3.1	SHAP summary plot pro model U-Net pro část Syntax	39
3.2	SHAP summary plot pro model DeepLabV3+ pro část Syntax	40
3.3	SHAP summary plot pro model U-Net pro část Stenosis	41
3.4	SHAP summary plot pro model DeepLabV3+ pro část Stenosis	43
3.5	fANOVA důležitost hyperparametrů pro část Syntax	44
3.6	fANOVA důležitost hyperparametrů pro část Stenosis	45
3.7	Příklad shody predikce s anotací, Syntax	48
3.8	Příklad predikce lepší než anotace, Syntax	49
3.9	Příklad predikce horší než anotace, Syntax	49
3.10	Příklad shody predikce s anotací, Stenosis	50
3.11	Příklad predikce horší než anotace vlivem cizích předmětů, Stenosis	50
3.12	Příklad predikce horší než anotace vlivem slehání predikce, Stenosis	51
3.13	Porovnání výkonu modelů U-Net a DeepLabV3+ bez předzpracování a s ním pomocí krabicových grafů na části datasetu Syntax	52
3.14	Porovnání výkonu modelů U-Net a DeepLabV3+ bez předzpracování a s ním pomocí krabicových grafů na části datasetu Stenosis	55

Seznam tabulek

1.1	Srovnání úspěšnosti segmentačních metod.	20
2.1	Finální hodnoty hyperparametrů pro jednotlivé modely s nejvyšším validačním Dice skóre na části datasetu SYNTAX.	32
2.2	Finální hodnoty hyperparametrů pro jednotlivé modely s nejvyšším validačním Dice skóre na části datasetu Stenosis.	32
2.3	Porovnání trénování jednotlivých modelů na datech části Syntax z datasetu ARCADE.	36
2.4	Porovnání trénování jednotlivých modelů na datech části Stenosis z datasetu ARCADE.	37
3.1	Porovnání nejdůležitějších hyperparametrů podle SHAP a fANOVA .	46
3.2	Výsledky průměru, mediánu a směrodatné odchylky pro modely U-Netraw, U-Netpre, DeepLabV3+raw a DeepLabV3+pre pro dané nastavení vah. Výsledky jsou vyjádřeny v procentech. Tučně jsou vyznačeny nejlepší hodnoty průměru a mediánu v rámci každé metriky.	53
3.3	Výsledky průměru, mediánu a směrodatné odchylky pro modely U-Netraw, U-Netpre, DeepLabV3+raw a DeepLabV3+pre při segmentaci stenózy. Tučně jsou vyznačeny nejlepší modely v rámci každé metriky podle průměru a mediánu.	56
3.4	Srovnání výsledků segmentace koronárních tepen na datasetu ARCADE	57
3.5	Srovnání výsledků segmentace stenóz na datasetu ARCADE	58
A.1	Výsledky modelu DeepLabV3+ bez předzpracování dat	68
A.2	Výsledky modelu DeepLabV3+ s předzpracováním dat	69
A.3	Výsledky modelu U-Net bez předzpracování	70
A.4	Výsledky modelu U-Net s předzpracováním	71
B.1	Výsledky modelu DeepLabV3+ bez předzpracování	72
B.2	Výsledky modelu DeepLabV3+ s předzpracováním	73
B.3	Výsledky modelu U-Net bez předzpracování	74
B.4	Výsledky modelu U-Net s předzpracováním	75

Úvod

Segmentace tepen ve snímcích rentgenové kontrastní angiografie (XCA, angl. *X-ray Coronary Angiography*) představuje klíčový krok v diagnostice ischemické choroby srdeční, jedné z nejčastějších příčin úmrtí na světě [10, 30]. Ischemická choroba srdeční (CAD, angl. *Coronary Artery Disease*) postihuje miliony lidí ročně a její včasná a přesná diagnostika je zásadní pro efektivní léčbu. XCA je jednou z nejpoužívanějších zobrazovacích metod pro diagnostiku CAD, umožňující lékařům identifikovat potenciální stenózy a hodnotit stav cévního řečiště. [41]

Segmentace tepen v XCA snímcích představuje výzvu kvůli rozmanitosti anatomických struktur, variabilitě kontrastních úrovní a přítomnosti šumu v obrazech. Tradiční segmentační metody často nejsou schopny dostatečně zachytit složité anatomické variace, zatímco moderní techniky využívající hluboké učení vykazují slibné výsledky. Důležitým faktorem je také časová náročnost manuální segmentace, kterou provádějí radiologičtí specialisté, přičemž automatizovaný přístup představuje významný pokrok v této oblasti. [9, 21]

Tato diplomová práce se zaměřuje na návrh, implementaci a vyhodnocení segmentačních modelů určených k segmentaci tepen v angiografických snímcích a stenotických oblastech. Práce je členěna do tří hlavních kapitol.

V první kapitole jsou představeny současné přístupy k segmentaci v rámci rentgenové kontrastní angiografie se zaměřením na metody využívající hluboké učení. Kapitola rovněž obsahuje přehled vybraných segmentačních modelů, přičemž dva z nich byly vybrány k podrobnější analýze. Jeden z modelů je U-Net a druhý modifikovaný AngioNet.

Druhá kapitola se věnuje implementaci segmentačních modelů. Nejprve je představen dataset ARCADE použitý pro trénink neuronových sítí. Dále jsou popsány metody předzpracování obrazových dat, zejména kombinace CLAHE a morfologické transformace typu bílá top-hat. Následuje detailní popis architektury modelu U-Net a upravené architektury AngioNet, které byly implementovány. Kapitola také zahrnuje optimalizaci hyperparametrů a proces trénování a validace modelů.


Třetí kapitola se soustředí na statistické vyhodnocení dosažených výsledků. Analyzuje vliv optimalizovaných hyperparametrů na kvalitu segmentace a prezentuje dosažené výsledky na testovací sadě dat. Zvláštní důraz je kladen na porovnání výkonu jednotlivých modelů prostřednictvím statistických ukazatelů, jako jsou krabicové grafy. Závěrečná část práce je věnována diskuzi výsledků, které zahrnují srovnání s jinými studiemi a formulaci praktických doporučení pro další výzkum i klinické využití.

1 Metody segmentace tepen na rentgenových angiogramech

1.1 Rentgenová kontrastní angiografie

Kontrastní rentgenová angiografie (XCA, angl. *X-ray Coronary Angiography*) je jednou z nejpoužívanějších zobrazovacích metod pro diagnostiku ischemické choroby srdeční. Během tohoto vyšetření se do koronárních tepen aplikuje kontrastní látka, která umožňuje lékařům pomocí 2D snímků identifikovat potenciální stenózy a hodnotit stav cévního řečiště [10, 41].

Ischemická choroba srdeční (CAD, angl. *Coronary Artery Disease*) patří mezi nejčastější příčiny úmrtí na celém světě. Podle údajů z článku [31] způsobuje toto onemocnění každoročně až 18 milionů úmrtí. Klíčovými strukturami pro diagnostiku koronárního onemocnění jsou tři hlavní koronární tepny: levá přední sestupná tepna (LAD, angl. *Left Anterior Descending Artery*), levá cirkumflexní tepna (LCX, angl. *Left Circumflex Artery*) a pravá věnčitá tepna (RCA, angl. *Right Coronary Artery*). Tyto cévy zajišťují zásobení srdečního svalu kyslíkem a živinami. Stenózy se nejčastěji vyskytují právě v těchto tepnách, a proto je jejich přesná segmentace klíčová pro stanovení závažnosti onemocnění. Jak je znázorněno na Obr. 1.1, správná segmentace těchto cév je nezbytná pro následnou diagnostiku. [21, 31, 37]



Obr. 1.1: Segmentace tří hlavních koronárních tepen (RCA, LAD, LCX) z angiografických snímků, které jsou klíčové pro hodnocení koronárního onemocnění. Na levé straně jsou zobrazeny 2D snímky tepen po aplikaci kontrastní látky, zatímco pravá část ukazuje výsledky segmentace těchto cév. (Upraveno z [41])

1.2 Segmentace tepen ve snímcích XCA

Jak již bylo zmíněno, správná segmentace hraje klíčovou roli pro posouzení stavu koronárního řečiště. Nicméně se nejedná o lehký úkol. Segmentace tepen v XCA snímcích čelí několika výzvám, které vyplývají z různých faktorů, jako jsou variabilita anatomie, různé úrovně kontrastování a přítomnost šumu v obrazech. Tyto faktory mohou ztížit přesnou identifikaci a lokalizaci cév, což může mít přímý dopad na diagnostiku a léčbu ischemické choroby srdeční. Zejména pak podhodnocování stavu stenózy je velkým problémem, jelikož může vést k nesprávné diagnóze a ke zhoršení stavu pacienta. [9, 21, 41]

Různé nežilní tkáně a struktury, jako jsou obrysy katétru, páteře a žeber, mohou výrazně ztížit proces segmentace, neboť vykazují podobnosti s cévními segmenty. Tato podobnost komplikuje lokalizaci lézí při hodnocení závažnosti stenózy. Stávající segmentační metody, ať už tradiční nebo moderní, založené na hlubokém učení, mají potíže se vyrovnat s těmito výzvami. Tradiční přístupy se často opírají o ručně vytvářené obrazové vlastnosti, které však postrádají důležité informace o sémantických vztazích a nejsou schopny adekvátně zachytit komplexní anatomické variace. Na druhé straně metody založené na hlubokém učení, i když disponují určitými sémantickými informacemi, se potýkají se ztrátou detailů a nedokonalým zachováním obrysů cév, jak bylo uvedeno v článku [41].

Přesto moderní segmentační přístupy, které jsou založeny na hlubokém učení, představují pokrok oproti tradičním metodám, které se ukázaly jako nedostatečné pro současné potřeby v této oblasti. [11]


1.3 Segmentace založená na hlubokém učení

Moderní metody segmentace koronárních tepen v XCA snímcích stále více využívají techniky hlubokého učení. Tyto metody znamenají výrazný pokrok oproti tradičním segmentačním technikám, protože nejen automatizují proces segmentace, ale také výrazně zvyšují přesnost a spolehlivost při identifikaci cévních struktur. To je zásadní pro správné hodnocení stavu cév a diagnostiku ischemické choroby srdeční. [12, 32]

1.3.1 U-Net

Jednou z nejrozšířenějších architektur založených na hlubokém učení je neuronová segmentační síť U-Net. Od jejího představení na konferenci MICCAI 2015 se U-Net stal zlatým standardem pro segmentaci biomedicínských obrazů díky své jednoduché, ale efektivní architektuře. U-Net se vyznačuje přítomností enkodéru a dekodéru, které jsou propojeny pomocí přeskokovacích spojení, jak ilustruje Obr. 1.2. Tento

design umožňuje síti efektivně zachytit prostorové rysy obrazu na různých úrovních rozlišení a s vysokou přesností segmentovat i složité struktury, jako jsou cévy. [33]



Obr. 1.2: Schéma architektury neuronové sítě U-Net. Vpravo je znázorněn enkodér, který postupně snižuje rozlišení obrazu a extrahuje klíčové rysy prostřednictvím konvolučních vrstev (červené šipky) a max-pooling operací (oranžové šipky). Vlevo se nachází dekodér, který provádí zpětnou rekonstrukci obrazu s vyšším rozlišením pomocí upsampling operací (žluté šipky). Uprostřed jsou přesakovací spojení (modré šipky), která propojují odpovídající vrstvy enkodéru a dekodéru, čímž umožňují přenos detailních prostorových informací z enkodérové cesty do dekodérové cesty. (Převzato z [33])


Autoři Yang a kol. využili základní architekturu U-Net pro segmentaci tří hlavních koronárních cév a dosáhli průměrné úspěšnosti na základě Dice skóre 87 %, jak uvádí článek [39]. Mnoho segmentačních sítí využívá architekturu U-Net jako základní stavební kámen, který je dále modifikován podle specifických požadavků dané segmentační úlohy. V kontextu segmentace cév v XCA snímcích jsou příklady těchto modifikací například síť StenUNet [23] a SVS-net [12], které byly navrženy pro přesnější detekci cévních struktur.

1.3.2 StenUNet

StenUNet je modifikovaná architektura založená na U-Netu, vyvinutá speciálně pro segmentaci stenóz v koronárních tepnách na snímcích XCA. Autoři architektury


StenUNet aplikovali metody předzpracování před tím, než jsou snímky z angiografie předány do sítě. Tento proces zahrnuje homomorfní zlepšení obrazu pomocí Butterworthova vysokopásmového filtru, který efektivně redukuje šum v pozadí a odlesky. Díky této aplikaci se zajišťuje, že vstupní snímky mají lepší kvalitu, což přispívá k přesnějšímu detekování stenóz. [23]

Celý proces je znázorněn na Obr. 1.3, kde vidíme, jak je nejprve aplikováno předzpracování, poté snímek vstupuje do sítě StenUNet a nakonec je provedeno postzpracování (angl. *postprocessing*), během kterého jsou odstraněny malé struktury, které anatomicky neodpovídají koronárním tepnám a nejsou považovány za stenózu.



Obr. 1.3: Postup pro detekci stenózy. Nejprve je aplikováno předzpracování, poté samotná segmentace pomocí StenUNet a nakonec postzpracování. (Upraveno z [23])

Architektura StenUNet Obr. 1.4 se skládá ze dvou hlavních komponent: enkodéru na levé straně a dekodéru na pravé straně. Enkodér extrahuje vysoce abstraktní rysy ze vstupních dat a současně postupně snižuje rozměry map rysů, což rozšiřuje zorné pole sítě. Následně dekodér tyto rysy postupně rekonstruuje, aby generoval segmentační mapy v původní velikosti. [23]



Obr. 1.4: Schéma architektury StenUNet pro automatickou detekci stenóz z rentgenové koronární angiografie. (Převzato z [23])

Přeskakovací spojení propojují vysoce úrovně a nízko úrovně rysy, což zlepšuje celkovou přesnost segmentace a umožňuje modelu lépe zachytit detaily v obraze. Tento design činí StenUNet efektivním nástrojem pro detekci stenóz v koronárních tepnách, což je klíčové pro diagnostiku ischemické choroby srdeční. [23]

Architektura StenUNet oproti standardnímu U-Netu využívá specifické ztrátové funkce pro trénink, které byly navrženy s ohledem na potřebu přesnější segmentace tepen a identifikaci stenózy. V průběhu tréninku StenUNet se rozdíl mezi výstupem modelu a skutečnými daty (angl. *ground truth*) vypočítává pomocí váženého součtu binární vzájemné entropie (BCE, angl. *Binary Cross-Entropy*) a ztráta podle Diceova koeficientu (angl. *Dice loss*). [23] Celková ztrátová funkce L je definována jako:

$$L = L_{\text{BCE}} + L_{\text{dice}} = - \left(Y \log \hat{Y} + (1 - Y) \log(1 - \hat{Y}) \right) + \left(1 - \frac{2Y \cap \hat{Y}}{Y \cup \hat{Y}} \right), \quad (1.1)$$

kde Y představuje skutečné hodnoty, $\hat{Y}$ je výstup modelu, přičemž 0 označuje pozadí a 1 označuje pixelovou stenózu. Zatímco BCE ztráta zajišťuje stabilní a efektivní tréninkový proces, ztráta dle Diceova koeficientu se aplikuje pro řešení a eliminaci vlivu třídní nerovnováhy mezi stenózou a pozadím. Tímto způsobem StenUNet dosahuje vyšší přesnosti v segmentaci i v případech, kdy jsou léze méně zastoupené v trénovacích datech. [23]

Autoři otestovali svou architekturu na datasetu ARCADE, který obsahuje 1000 snímků pro trénování modelu, 200 pro validaci a 300 pro testování. Pro vyhodnocení svého modelu autoři použili Dice skóre.

Na základě provedené ablační studie na datasetu ARCADE dosáhl StenUNet-pre+post nejlepšího výsledku s Dice skóre 53,48 % při porovnání s variantou StenUNet-raw, která dosáhla 48,34 %, a variantou StenUNet-pre, která dosáhla 49,60 %. Tyto výsledky ukazují, jak důležité je zahrnout předzpracování a postzpracování pro zlepšení výkonu algoritmu v úlohách segmentace stenóz. V ARCADE výzvě z roku 2023 pro automatickou detekci stenózy ze snímků XCA se autoři se svou sítí StenUNet umístili na třetím místě. [23]

1.3.3 SVS-net

SVS-net je segmentační síť upravená speciálně pro sekvenční segmentaci tepen v datech XCA. Tato síť vychází z architektury U-net, ale obsahuje řadu úprav zaměřených na lepší zachycení temporálně-prostorových rysů cév a na potlačení šumových artefaktů pozadí. [12]

Autoři této architektury Obr. 1.5 aplikovali 3D konvoluční vrstvy pro extrakci temporálně-prostorových rysů z několika sekvenčních snímků XCA, čímž umožnili



Dalším důležitým prvkem sítě SVS-net je využití operace slučování rysů (FFO, angl. *Feature Fusion Operation*), který spojuje informace z různých úrovní kódování a dekodování. FFO integruje nízkoúrovňové rysy, jako jsou hrany a textury s vysoce abstraktními informacemi, které jsou nezbytné pro správnou rekonstrukci cévních struktur. Tento modul zajišťuje, že během segmentace se nepřetrhává přenos klíčových informací mezi enkodérem a dekodérem, což přispívá k vyšší přesnosti výsledného segmentovaného obrazu. Významným prvkem je použití přeskokovacích spojení, která zajišťují efektivní předávání informací mezi kódovacími a dekodovacími fázemi sítě, což přispívá k přesnější segmentaci cévních struktur na snímcích XCA. [12]

Pro trénování autoři využili ztrátu Diceova koeficientu (angl. *Dice loss*), tento přístup byl zvolen k řešení problému třídní nerovnováhy, který je u segmentace cévních struktur velmi častý. Autoři otestovali svou navrženou síť SVS-net na 120 klinických sekvenčních snímcích XCA z Šanghajske nemocnice Renji. Tyto sekvence byly ručně anotovány třemi odborníky, přičemž výsledná anotace byla založena na průměrné hodnotě od všech tří expertů. Sekvence byly získány z různých rentgenových zařízení, což vedlo k rozdílům v rozlišení, distribuci šumu a intenzitě pixelů jednotlivých snímků. Aby byly tyto rozdíly eliminovány, autoři snímky upravili na jednotné rozlišení 512×512 pixelů s 8 bity na pixel. Autoři uvádějí výsledky svého algoritmu pomocí metriky Dice skóre, kde model SVS-net dosáhl na úspěšnost 84,3 %. [12]

1.3.4 AngioNet

AngioNet je segmentační síť zaměřená na segmentaci cév z XCA snímků. Využívá speciální síť pro angiografické zpracování (APN, angl. *Angiographic Processing Network*), která se zaměřuje na optimalizaci filtrů pro předzpracování obrazů. APN je navržena tak, aby maximalizovala kvalitu vstupních dat před samotnou segmentací, což přispívá k přesnějšímu rozlišení cévních struktur. Použití APN je spojeno s architekturou Deeplabv3+. [7, 17]

Autoři představili segmentační síť AngioNet, jak je ilustrováno na Obr. 1.6. Vlevo je vstupní normalizovaný snímek XCA, který je nejprve upraven pomocí bloku APN. Tento blok aplikuje filtraci pomocí masek o velikosti 3×3 a 5×5 , čímž odstraňuje šum a zlepšuje kontrast cévních struktur. Tato fáze předzpracování zajišťuje lepší vstupní data pro následnou segmentaci. [7, 17]


Po předzpracování je snímek zpracován segmentační sítí Deeplabv3+, která využívá atrous konvoluci pro efektivní zachycení víceúrovňových kontextových informací. Výsledná predikce je znázorněna napravo a představuje přesně segmentované cévní struktury, což usnadňuje diagnostiku onemocnění koronárních tepen. [17]

Významným blokem segmentační sítě Deeplabv3+ je atrous konvoluce. Jedná

se o techniku, která umožňuje zvětšit zorné pole filtru bez nutnosti zvyšovat počet parametrů nebo ztrácet prostorové rozlišení. Tento přístup zavádí mezery mezi prvky filtru, a tím umožňuje síti zpracovávat informace na více měřítkách. Rovnice pro atrous konvoluci je definována:

$$y(i) = \sum_k x(i + r \cdot k) \cdot w(k), \quad (1.2)$$

kde $y(i)$ představuje výstupní hodnotu, $x(i + r \cdot k)$ je vstupní signál, kde r je dilatační koeficient, který určuje velikost kroku mezi pixely vstupního signálu, a k je index filtru. Váha $w(k)$ je aplikována na jednotlivé hodnoty vstupního signálu, což umožňuje zachytit víceúrovňové kontextové informace bez ztráty prostorové rozlišení. Díky tomuto přístupu atrous konvoluce umožňuje modelům efektivněji rozpoznávat detaily v obrazech. [7]



Obr. 1.6: Schéma architektury AngioNet: vlevo vstupní normalizovaný snímek XCA, který je upraven pomocí bloku APN, kde dochází k filtraci snímku pomocí 3×3 a 5×5 masek. Poté je snímek zpracován segmentační sítí Deeplabv3+ a napravo je výsledná predikce. (Upraveno z [17])


Autoři otestovali síť AngioNet na datasetu UM, který zahrnoval 462 angiogramů pacientů s kardiologickým onemocněním. K vyhodnocení úspěšnosti segmentace použili Dice skóre, přičemž dosáhli úspěšnosti až 90 % na vybraném datasetu. Dále uvedli, že jednou z hlavních výhod sítě AngioNet je schopnost potlačit pozadí artefaktů a zároveň zachovat konektivitu cév, což je klíčové pro správnou diagnostiku a léčbu. [17]

1.3.5 YOLO-Angio

YOLO-Angio je algoritmus pro automatickou segmentaci koronární anatomie, který představil autor Liu a kol. Tento algoritmus využívá metody předzpracování, jež za-

hrnují vylepšení obrazu pomocí ekvalizace histogramu, vyhlazení obrazu, homomorfického filtru a dalších technik. Tyto metody mají za cíl zlepšit kvalitu snímků XCA před samotným procesem segmentace. Autoři zdůrazňují, že důkladné předzpracování je klíčové pro dosažení vysoké přesnosti segmentace. [24]

Algoritmus YOLO-Angio Obr. 1.7 kombinuje tyto metody předzpracování se segmentační sítí YOLOv8, která byla představena v roce 2023. Na základě informací z článku [36], tento model ukazuje slibné výsledky v segmentaci koronární anatomie. Koncovým bodem algoritmu je použití segmentace cévních větví na základě logiky. Tento blok eliminuje falešně pozitivní případy. [36]



Obr. 1.7: Postup algoritmu YOLO-Angio: nejprve je aplikováno předzpracování snímků XCA na základě ekvalizace histogramů, vyhlazení obrazu a dalších technik. Poté následuje segmentace pomocí modelu YOLOv8 a finálním blokem je logický blok, který eliminuje falešně pozitivní případy predikce. (Převzato z [36])

Autoři otestovali algoritmus YOLO-Angio na datasetu ARCADE, který obsahuje 1000 snímků pro trénink modelu, 200 snímků pro validaci a 300 snímků pro testování. Pro vyhodnocení modelu bylo použito Dice skóre. V rámci ablační studie dosáhli nejlepšího výsledku díky metodám předzpracování, které zahrnovaly ekvalizaci histogramu a připojení logického bloku k eliminaci falešně pozitivních predikcí, přičemž tento výsledek činil 42,9 % Dice skóre. Naopak, při využití pouze segmentační sítě YOLOv8 bez předzpracování a logického bloku, dosáhli autoři pouze 27 % Dice skóre. Tyto výsledky jasně ukazují, jak důležité je předzpracování pro zlepšení

segmentace a následnou diagnostiku snímků XCA. V rámci výzvy ARCADE 2023 se tento algoritmus umístil na 10. místě. [36]

1.4 Srovnání segmentačních metod

V rámci rešerše bylo představeno pět algoritmů založených na hlubokém učení, které se zaměřují na segmentaci cév v XCA snímcích. Tab. 1.1 shrnuje úspěšnost těchto algoritmů a poskytuje ucelený přehled o jejich výkonu.

Tab. 1.1: Srovnání úspěšnosti segmentačních metod.

Algoritmus	Dataset	Dice Skóre [%]
U-Net	Asan Medical Center	87,0
StenUNet	ARCADE	53,5
SVS-net	Renji Hospital of Shanghai	84,3
AngioNet	UM	90,0
YOLO-Angio	ARCADE	42,9

Z hlediska výkonu jednotlivých algoritmů lze konstatovat, že každý z nich přináší specifické výhody a omezení, což ovlivňuje jejich celkovou efektivitu při segmentaci cév v XCA snímcích. Například algoritmus AngioNet vykazuje nejvyšší úspěšnost s Diceovým skóre 90 %, což naznačuje jeho schopnost účinně potlačit artefakty pozadí a zachovat konektivitu cév. Na druhou stranu, algoritmus YOLO-Angio, i když přináší inovativní přístupy, dosahuje nižší úspěšnosti s Dice skóre 42,9 %. Tyto rozdíly ukazují na důležitost nejen samotné architektury, ale také metod předzpracování, které mohou výrazně ovlivnit výslednou segmentaci. Je důležité poznamenat, že výsledky uvedené v Tab. 1.1 nelze přímo porovnávat, neboť algoritmy byly testovány na různých datasetech, což může mít vliv na dosažené výkony.

1.5 Výběr segmentačních modelů

Na základě literární rešerše provedené v podkapitole 1.3 a analýzy výkonu pěti algoritmů hlubokého učení, zaměřených na segmentaci cév v XCA snímcích, byly vybrány tři segmentační modely: U-Net, StenUNet a AngioNet. Údaje o jejich úspěšnosti jsou shrnuty v Tab. 1.1, která poskytuje komplexní přehled o dosažených výsledcích.

Každý z vybraných algoritmů přináší specifické výhody a nevýhody, které ovlivňují jejich celkovou efektivitu při segmentaci cév. Model U-Net dosáhl Dice skóre

87.0% na datasetu Asan Medical Center, což dokládá jeho schopnost efektivně segmentovat cévní struktury. Algoritmus AngioNet vykazuje nejvyšší úspěšnost s Diceovým skóre 90.0% na datasetu UM, což naznačuje jeho efektivitu v potlačení artefaktů pozadí a zachování cévní konektivity. Na závěr, StenUNet, testovaný na datasetu ARCADE, dosáhl Dice skóre 53.48%. Tento model byl vybrán především proto, že umožňuje srovnání výsledků s autory, kteří pracovali se stejným datasetem, jenž bude využit při implementaci modelů v rámci praktické části práce.

U-Net je architektura navržená speciálně pro úlohy segmentace v medicíně, která se vyznačuje schopností efektivně pracovat i s omezeným množstvím tréninkových dat [33]. Tento model byl úspěšně aplikován v různých lékařských oborech, včetně segmentace cév v rentgenových snímcích, což potvrzuje jeho širokou užitečnost a adaptabilitu v oblasti medicínské obrazové analýzy. V rámci praktické části diplomové práce bude tento model také implementován.

AngioNet je algoritmus specificky navržený pro segmentaci angiografických snímků, který zohledňuje výzvy spojené se segmentací cév, jako jsou variace v jasu, kontrastu a přítomnost artefaktů [17]. Tento model dosahuje vysoké přesnosti, přičemž Dice skóre činí 90.0%. Tato vysoká úspěšnost potvrzuje jeho účinnost v segmentaci cévních struktur, což vedlo k jeho výběru pro tuto práci. V rámci praktické části bude použita modifikace sítě AngioNet.

StenUNet je vylepšená verze U-Net, která se primárně zaměřuje na segmentaci stenóz [23]. Autoři tohoto algoritmu se umístili na třetím místě v rámci výzvy ARCADE 2023, kde dosáhli Dice skóre 53.48%. Tento model nebude implementován v rámci této práce, ale bude použit jako referenční model pro srovnání na stenózních datech, která budou využita při trénování modelů U-Net a modifikace AngioNetu.


Vybrané modely pokrývají široké spektrum přístupů k segmentaci tepen ve snímcích XCA. V rámci praktické části práce budou implementovány modely U-Net a modifikace AngioNetu.

2 Implementace segmentačních modelů

Návrh a implementace algoritmů probíhaly v programovacím jazyce Python¹ v programovacím prostředí PyCharm² (verze 3.3). Trénování a testování modelů zaměřených na segmentaci tepen a stenóz v XCA snímcích probíhalo na výpočetním serveru CUDA2 s využitím grafické karty Nvidia Titan Xp 12 GB GDDR5. Tato karta byla vybrána pro svůj vysoký výpočetní výkon a efektivitu při zpracování velkých datových sad.

2.1 ARCADE dataset

Použitý dataset ARCADE (angl. *Angiographic Dataset for the Segmentation of Coronary Arteries*) byl vybrán, jelikož obsahuje data se zaměřením na segmentaci tepen v modalitě XCA. Struktura datasetu je znázorněna na Obr. 2.1, kde lze pozorovat




Obr. 2.1: Schéma datasetu ARCADE, který obsahuje dva hlavní adresáře: Syntax a Stenosis, a každý z nich tři podmnožiny: "train", "test" a "val". Každá z těchto sad obsahuje složky "images", kde jsou uloženy snímky XCA, a "annotations", kde jsou zakódované anotované masky.

¹<https://www.python.org/>

²<https://www.jetbrains.com/pycharm/>

rozdělení do dvou hlavních adresářů: **Syntax** a **Stenosis**, které obsahují soubory pro dvě různé úlohy datasetu. První z nich zahrnuje klasifikaci cévních větví podle metodologie SYNTAX [2] a druhá se zaměřuje na detekci stenózy. Uvnitř těchto adresářů jsou tři podmnožiny datasetu: *"train"*, *"val"* a *"test"*. V každém z těchto adresářů jsou další dvě úrovně adresářů: *"images"* a *"annotations"*. Adresář *"images"* obsahuje snímky ve formátu PNG, které byly extrahovány z DICOM záznamů. Adresáře *"annotations"* obsahují jednotlivé soubory ve formátu *".JSON"*, které jsou pojmenovány podle konkrétní úlohy, tedy *"train.JSON"*, *"val.JSON"* a *"test.JSON"*. Struktura souborů *".JSON"* obsahuje tři hlavní klíče: *"annotations"*, *"categories"* a *"images"*. Pole *"images"* obsahuje unikátní *"id"* snímku v datasetu, jeho šířku a výšku v pixelech a podpole *"file_name"*, které obsahuje konkrétní informace o snímku. Pole *"categories"* obsahuje unikátní *"id"* v rozmezí 1 až 26 a *"name"*, které jej spojuje s popisem SYNTAX. Pole *"annotations"* zahrnuje unikátní *"id"* anotace, hodnotu *"image_id"* vztahující se ke konkrétnímu snímku z pole *"images"* a *"category_id"* vztahující se ke konkrétní kategorii z pole *"categories"*. Sub-pole *"segmentation"* obsahuje souřadnice okrajových bodů masek ve formátu *"XYXY"*. Dataset pochází ze segmentační výzvy roku 2023 ARCADE³, jenž se zabývala segmentací koronárních artérií v XCA snímcích. Dataset ARCADE zahrnuje 3000 snímků, které jsou rozděleny na dvě hlavní oblasti: segmentaci tepen a detekci stenózy. Každá z těchto oblastí je dále rozdělena na trénovací, testovací a validační sadu dat. Trénovací sada obsahuje 1000 snímků, testovací sada 300 snímků a validační sada 200 snímků. [31]

Zobrazení XCA snímku a jeho příslušné anotované masky (angl. *ground truth*) lze pozorovat na Obr. 2.2. Anotovaná maska, která slouží jako referenční model




Obr. 2.2: Zobrazení XCA snímku (vlevo) s jeho příslušnou anotovanou maskou (vpravo). Na snímku XCA je viditelný koronární cévní systém, přičemž je patrný kontrast mezi cévami a okolními tkáněmi.

³<https://arcade.grand-challenge.org/>

pro hodnocení přesnosti segmentace, byla vytvořena převodem souřadnic z formátu *".JSON"* do binární podoby. Tento převod zahrnoval transformaci hraničních bodů masky ve formátu *"XYXY"* na obrazovou matici, v níž jednotlivé pixely získávají buď bílou, nebo černou hodnotu. Bílé pixely označují oblasti segmentovaných tepen, zatímco černé pixely představují pozadí, které není součástí segmentace. Proces zahrnoval pečlivou interpretaci těchto hraničních bodů tak, aby přesně odpovídaly tvaru a umístění tepen na původním snímku. Tento postup byl aplikován na celý dataset, což zahrnovalo vytvoření 1000 masek pro trénovací sadu, 300 masek pro testovací sadu a 200 masek pro validační sadu. K vytvoření anotovaných masek pro obrázky ve formátu PNG byl naprogramován skript *createmasks.py*. Tento skript zpracovává anotace obsažené v JSON souboru, který obsahuje informace o obrázcích a jejich příslušných segmentech. Po načtení JSON souboru s anotacemi se skript zaměřuje na vytvoření adresáře pro uložení vygenerovaných masek. Pokud tento adresář již existuje, nebude se nic měnit, jinak se vytvoří nový.


Hlavní část skriptu spočívá v iteraci přes všechny obrázky v načtených datech. Pro každý obrázek se vytvoří nová černobílá maska o stejných rozměrech jako obrázek. Poté se skript pomocí objektu *ImageDraw* pokouší vykreslit polygonální segmenty na tuto masku. Každý segment je definován souřadnicemi, které jsou uloženy v anotacích. Skript zkontroluje, zda každá anotace patří k aktuálnímu obrázku, a pokud ano, vykreslí polygon na masku. Jakmile jsou všechny segmenty vykresleny, maska se uloží jako PNG soubor do dříve vytvořeného adresáře, přičemž název souboru je odvozen od názvu původního obrázku. Na závěr skript vytiskne zprávu, že všechny masky byly úspěšně vytvořeny. Tento proces je klíčový pro přípravu dat pro trénink modelů v úlohách segmentace obrazu, neboť anotované masky slouží jako referenční standardy pro vyhodnocení výkonu modelů. Autoři datasetu ARCADE



Obr. 2.3: Příklad zobrazení snímku XCA (vlevo) a jeho nedokonalé anotované masky (vpravo). Na anotované masce jsou jasně vidět pouze některé části cévního řečiště, což ilustruje omezení anotace.

uvedli, že lékaři při anotaci snímků zanechali pouze 60 až 70 % hlavních koronárních cév [31]. Tato nedokonalost v anotaci může mít významný dopad na kvalitu a spolehlivost výsledků při trénování a testování modelů pro segmentaci cév. Na Obr. 2.3 je jasně vidět, že nedokonalé anotace mohou vést k tomu, že určité části cévního řečiště zůstanou neoznačené, což může ztížit správnou detekci a segmentaci cév v dalších analýzách.

Při segmentaci stenózy v rámci tohoto datasetu je použita metodika podobná té, která je aplikována při segmentaci hlavního cévního řečiště. Na Obr. 2.4 je zobrazeno cévní řečiště, přičemž vpravo je znázorněna maska s vyznačenými BB (angl. *Bounding Box*), které se běžně používají pro úlohy detekce. BB jsou v tomto případě ilustrativní, protože pro segmentaci stenózy je klíčová právě maska, která označuje přesnou oblast postiženou stenózou, stejně jako při segmentaci celého koronárního řečiště. Maska tedy hraje zásadní roli při detailním vymezení postižených oblastí, což je nezbytné pro přesnou segmentaci a analýzu stenózy v cévách. Tyto masky byly vytvořeny obdobným způsobem jako masky pro segmentaci cévního řečiště, a to za použití skriptu *createmasks.py*, který automaticky generuje masky na základě anotovaných dat. Tento skript zajistí, že masky pro stenózu budou odpovídat přesně těmto oblastem a umožní tak efektivní trénink segmentačních modelů.



Obr. 2.4: Příklad zobrazení cévního řečiště (vlevo) a masky stenózy s vyznačenými BB (vpravo). Masky s BB jsou běžně používány pro úlohy detekce, ale pro segmentaci stenózy je klíčová právě maska, která přesně vymezuje postiženou oblast.


Nicméně, v některých případech může docházet k nepřesným anotacím, což může ovlivnit kvalitu segmentace. Na Obr. 2.5 je zobrazen příklad snímku s nepřesnou anotovanou maskou stenózy. Tato maska neodpovídá přesně oblasti stenózy, protože buď zasahuje do okolní cévní struktury, nebo naopak nezahrnuje celou postiženou oblast, což může vést k chybám při následné segmentaci a analýze stenózy.

Na závěr je třeba zmínit, že metodologie SYNTAX Obr. 2.6 se používá k hodnocení složitosti a závažnosti koronární arterosklerózy. Tato metodologie poskytuje



Obr. 2.5: Příklad zobrazení snímku cévního řečiště (vlevo) a jeho nepřesné anotované masky stenózy s BB (vpravo). Masky zde buď zasahuje do okolní cévní struktury, nebo nezahrnuje celou postiženou oblast stenózy, což ilustruje problém s kvalitou anotace.

system pro klasifikaci cévních větví a určení optimální léčby pacientů. SYNTAX skóre bere v úvahu faktory jako počet a umístění stenóz, typy cévních větví a jejich funkční význam, přičemž je široce používaný v klinické praxi. [2, 13]



Obr. 2.6: Schéma metodologie SYNTAX poskytuje hodnocení závažnosti stavu onemocnění koronárního řečiště. (Převzato z [2])

2.2 Předzpracování dat

Na základě rešerše uvedené v podkapitole 1.3 byla zdůrazněna klíčová role předzpracování dat v procesu analýzy snímků XCA. Bylo také dokázáno, že adekvátní před-

zpracování může zlepšit výkon segmentačního modelu, jak uvedli autoři sítě StenUNet [23] a autoři algoritmu AngioNet [21]. V kontextu XCA snímků tepen se zaměřujeme především na metody, které pomáhají zvýraznit cévní struktury a efektivně potlačují šum v pozadí.


Předzpracování dat zahrnuje různé techniky, jako jsou například filtrování nebo vylepšení kontrastu obrazu. Pro účely diplomové práce bylo využito předzpracování ve formě adaptivní ekvalizace histogramu s omezeným kontrastem (CLAHE, angl. *Contrast Limited Adaptive Histogram Equalization*) [14] a bílé top-hat transformace [3].

2.2.1 Adaptivní vylepšení histogramu s omezeným kontrastem

Adaptivní ekvalizace histogramu s omezeným kontrastem patří mezi používané techniky zvýraznění cév v medicínské oblasti. Hlavní kroky metody CLAHE zahrnují rozdělení obrazu na nepřekrývající se oblasti, výpočet histogramu pro každou oblast, stanovení limitu pro ořezání histogramu a redistribuci histogramu tak, aby jeho výška nepřesáhla stanovený limit. [14, 19] Limit pro ořezání histogramu β je dán vzorcem:

$$\beta = \frac{MN}{L} \left(1 + \frac{\alpha}{100} (s_{max} - 1) \right), \quad (2.1)$$

kde $M \times N$ je počet pixelů v každé oblasti, L je počet úrovní šedi, α je faktor ořezání (0-100) a S_{max} je maximální povolený sklon. Redistribuce histogramu přesune biny, které přesahují stanovený limit. Jak znázorňuje Obr. 2.7 metoda CLAHE omezuje zesílení histogramu ořezáním histogramu (zelená oblast), což zabraňuje vzniku šumových artefaktů v homogenních oblastech obrazu. Následná redistribuce však může některé biny opět přesunout nad stanovený limit (žlutě zvýrazněná oblast). [19]



Obr. 2.7: Proces metody CLAHE, která omezuje zesílení histogramu ořezáním (zelená oblast nad přerušovanou čarou). (Převzato z [19])

Pro účely předzpracování byla dle informací z článku [31] nastavena velikost mřížky na rozměry 8×8 a limit pro ořezání histogramu na hodnotu 2. Tento postup byl implementován ve skriptu *enhanceimg.py*.

2.2.2 Bílá top-hat transformace

Bílá top-hat transformace je metoda morfologické analýzy obrazu, která se používá k zvýraznění malých světlejších oblastí na tmavém pozadí. Tato transformace je definována jako rozdíl mezi původním obrazem a jeho morfologickým otevřením. V kontextu medicínských obrazů, jako jsou snímky cév, může tato metoda pomoci zvýraznit drobné cévní struktury nebo jiné důležité detaily, které by jinak mohly být přehlédnuty. [3, 35]


Vzorec pro bílou top-hat transformaci je dán vztahem:

$$WTH(x, y) = f(x, y) - f \circ B(x, y), \quad (2.2)$$

kde $WTH(x, y)$ je bílá top-hat transformace, $f(x, y)$ je vstupní obraz a $f \circ B(x, y)$ je otevření obrazu pomocí strukturovacího prvku B [3].

V rámci skriptu *enhanceimg.py* byla na negativ vstupního obrazu aplikována bílá top-hat transformace. Nejprve byl obraz invertován, což znamená, že všechny světlé oblasti byly převedeny na tmavé a naopak. Následně byla provedena bílá top-hat transformace s použitím morfologického strukturovacího prvku o velikosti 50×50 . Výsledkem této transformace bylo zvýraznění jemných světlejších oblastí na tmavém pozadí, což pomohlo lépe odhalit detaily, které by jinak mohly být přehlédnuty. Poté byla aplikována CLAHE s mřížkou 8×8 a limitem pro ořezání histogramu s hodnotou 2. CLAHE pomohla vylepšit kontrast obrazu bez přidání šumových artefaktů.

Výsledek kombinace použití CLAHE a bílé top-hat transformace je znázorněn na Obr. 2.8, kde lze pozorovat zvýraznění cévních struktur, což by mělo přispět k lepšímu učení neuronové sítě. Tato kombinace předzpracování byla inspirována autory Popov a kol. [31] a Tao a kol. [35].



Obr. 2.8: Snímek XCA z trénovací sady před aplikací předzpracování (vlevo). Snímek XCA po aplikaci CLAHE a bílé top-hat transformace (vpravo).

2.3 Architektura modelu U-Net

V diplomové práci byla využita architektura neuronové sítě U-Net [33]. U-Net byl vybrán na základě jeho úspěšnosti v medicínských segmentačních úlohách, zejména i při segmentaci cév ve snímcích XCA, kde pomáhá překonávat náročné podmínky při rozlišování cévních struktur. Velkou výhodou U-Netu je jeho účinnost i s omezeným počtem tréninkových dat, což tento model činí vhodným pro použití v této práci.

Pro účely trénování byl vytvořen skript *modelUNet.py*, ve kterém je definována třída *ConvBlock* pro konvoluci, *EncoderBlock* pro enkódovací blok a *DecoderBlock* pro dekódovací blok. Celková architektura U-Net se skládá z enkodéru a dekodéru propojených pomocí přeskakovacích spojení. Třída *ConvBlock* obsahuje dvě konvoluční vrstvy s filtry velikosti 3×3 , přičemž každá vrstva je následována batch normalizací a aktivační funkcí ReLU (angl. *Rectified Linear Unit*). Tato třída vytváří základní konvoluční blok využívaný v enkódovacích i dekódovacích částech modelu. V *EncoderBlock* je kromě konvolučního bloku *ConvBlock* zahrnuta také maximální sdružovací vrstva (*MaxPool2d*) o velikosti 2×2 s posunem 2 pro podvzorkování (angl. *downsampling*). Enkodér se skládá ze čtyř bloků *EncoderBlock*, které postupně zvyšují počet kanálů (64, 128, 256, 512) a snižují rozlišení obrazu, a tím se extrahují klíčové rysy na různých úrovních rozlišení. Dekodér je tvořen čtyřmi bloky *DecoderBlock*, které postupně rekonstruuji obraz zpět na původní rozlišení. Tyto bloky provádějí nadvzorkování (angl. *upsampling*) pomocí transponovaných konvolucí o velikosti 2×2 , přičemž počet kanálů se postupně snižuje (512, 256, 128, 64), čímž se zajišťuje efektivní přenos prostorových informací. Každý dekódovací blok spojuje výstup dekodéru s odpovídajícími příznakovými mapami z enkodéru, tak se umožňuje přenos detailních prostorových informací. Tato přeskakovací spojení jsou klíčová pro zajištění vysoké kvality rekonstruovaného obrazu. Mezi enkódující a dekódující částí modelu je umístěno hrdlo (angl. *bottleneck*), které obsahuje konvoluční blok s 1024 kanály a zajišťuje přenos nejdůležitějších informací mezi enkodérem a dekodérem. Jedná se o důležitý prvek, který v rámci U-Net sítě zabraňuje přeučení. Výstupní vrstva modelu je tvořena konvoluční vrstvou s jádrem velikosti 1×1 , která generuje finální segmentační masku.


2.4 Architektura upraveného modelu AngioNet

Navržená segmentační síť vychází z architektury AngioNet [17], avšak namísto původní APN sítě pro extrakci příznaků se zde využívá vlastní přístup k předzpracování dat, identický s tím, který byl aplikován u U-Netu. Tento přístup zahrnuje kombinaci CLAHE a bílé top-hat transformace. Pro segmentaci je použit model DeepLabV3+ [26], kde jako enkodér slouží předtrénovaný model ResNet-18 [27], který

byl trénován na datasetu ImageNet. Autoři AngioNetu (Iyer a kol.) [17] použili model DeepLabV3+ s předtrénovaným enkodérem Xception, který však není dostupný v knihovně PyTorch [29]. Z tohoto důvodu byl jako alternativa zvolen ResNet-18, který poskytuje dostatečnou extrakci příznaků a není výpočetně náročný.

Samotná architektura obsahuje zmíněný enkodér ResNet-18, který se skládá z 18 vrstev. První vrstva (conv1) provádí konvoluci se vstupním obrazem o jednom kanálu a využívá 64 filtrů o velikosti 7×7 , s krokem 2 a paddingem 3. Následuje batch normalizace (angl. *batch normalization*) a aktivace ReLU (angl. *Rectified Linear Unit*). Poté je aplikována maximálně sdružující operace (angl. *max pooling*) s jádrem 3×3 a krokem 2, která snižuje prostorové rozlišení vstupních dat. Po těchto úvodních operacích síť obsahuje čtyři hlavní bloky, z nichž každý se skládá z několika *BasicBlock* bloků. Každý *BasicBlock* obsahuje dvě konvoluční vrstvy, z nichž první (conv1) používá filtry o velikosti 3×3 pro zachování prostorového rozlišení a po ní následuje operace *batch normalization* a aktivační funkce ReLU. Druhá konvoluce (conv2) také používá filtry o velikosti 3×3 a po ní je aplikována pouze operace *batch normalization*. V ResNet-18 jsou tyto bloky opakovány v jednotlivých sekvencích s postupně rostoucím počtem kanálů, přičemž v první sekvenci je počet kanálů 64, v dalších sekvencích postupně až na 128, 256 a 512.

Jako dekodér je použit DeepLabV3+, který obsahuje modul dilatovaného prostorového pyramidového sdružování (ASPP, angl. *Atrous Spatial Pyramid Pooling*). Tento modul se skládá z několika konvolučních vrstev a separovatelných konvolucí, které umožňují modelu efektivně zachytit informace o objektech různých měřítek, což je znázorněno na Obr. 2.9. Díky dilataci konvolučních filtrů může model



Obr. 2.9: Snímek demonstruje, jak ASPP modul přispívá k přesné klasifikaci oranžového pixelu využitím paralelních konvolučních operací s různými měřítky. (Převzato z [6])

zohlednit širší kontext a zachytit různé míry rozlišení bez ztráty prostorové přes-

nosti [6]. Specifické vrstvy (*ASPPSeparableConv*) implementují separovatelné konvoluce, které rozdělují zpracování prostorových a kanálových informací do dvou oddělených kroků, což vede ke zvýšení výpočetní efektivity. Dále je použita adaptivní průměrná sdružující vrstva (*AdaptiveAvgPool2d*), která shrnuje informace z celého obrazu do jednoho bodu a poskytuje modelu globální kontext. Po každé konvoluční vrstvě je aplikována normalizace batch (angl. *batch normalization*), která stabilizuje učení a urychluje trénink. Pro nadvzorkování výstupu, tedy zvětšení rozměrů segmentovaného obrazu, je použita bilineární interpolace (*UpsamplingBilinear2d*). Na závěr je výstup zpracován pomocí konvolučních vrstev s velikostí jádra 1×1 , které redukuje počet kanálů na 1 pro účely binární segmentace. Následně dochází k opětovnému nadvzorkování výsledného obrazu.[7]

Implementace modelu DeepLabV3+ s předtrénovaným enkodérem ResNet-18 je založena na knihovně PyTorch a je umístěna ve skriptu *modelDeepLabV3.py*, který je volán při zahájení trénovacího procesu.

2.5 Optimalizace hyperparametrů

V rámci experimentů byly modely trénovány jak na surových datech (raw), tak na datech s aplikovaným předzpracováním (pre). Toto rozlišení je zachováno v celém textu a výsledcích experimentů. S cílem dosáhnout co nejlepších výsledků byly architektury modelů optimalizovány. Mezi vybírané hyperparametry patřila velikost batch (angl. *batch size*), krok učení (angl. *learning rate*) a L2 regularizace vah (angl. *weight decay*). V algoritmu Adam je tento hyperparametr zodpovědný za L2 regularizaci vah. K realizaci optimalizace hyperparametrů byl vybrán framework Optuna [1], který umožňuje efektivní vyhledávání optimálních hodnot hyperparametrů v kombinaci s knihovnou PyTorch. Optuna využívá Bayesovského přístupu a byl nastaven algoritmus TPE (angl. *Tree-structured Parzen Estimator*). Tento algoritmus buduje pravděpodobnostní model, který rozdělí prohledávací prostor na dvě distribuční skupiny: jedna obsahuje hyperparametry vedoucí k lepším výsledkům, druhá naopak ty, které vedou k horším. Na základě této rozdělené pravděpodobnosti vybírá nové kandidátní hodnoty, a tím upřednostňuje oblasti s vyšší pravděpodobností zlepšení [1].

V rámci experimentu byla optimalizace provedena s cílem dosažení co nejvyšší hodnoty validačního Dice skóre. Současně byla sledována i validační ztráta, která sloužila jako kritérium pro předčasné ukončení trénování pomocí algoritmu *early stopping*. Pokud v průběhu pěti po sobě jdoucích epoch nedošlo ke zlepšení validační ztráty, byl daný pokus (angl. *trial*) ukončen. Tento přístup pomohl předejít zbytečnému přetrénování a zároveň snížil výpočetní náročnost. Optimalizace byla

prováděna na dvou typech dat z datasetu ARCADE, konkrétně na segmentaci cévního řečiště podle metodiky SYNTAX a na segmentaci stenózy. Každý experiment byl realizován celkem čtyřikrát: jednou s předzpracováním a jednou bez něj pro oba modely, U-Net a DeepLabV3+. Celkem tak bylo provedeno osm samostatných experimentů ($2 \text{ typy dat} \times 2 \text{ modely} \times 2 \text{ varianty předzpracování}$).

Před začátkem optimalizace bylo zapotřebí definovat rozsah prohledávaných hyperparametrů. Pro *learning rate* a *weight decay* byl stanoven rozsah hodnot od 1×10^{-5} do 1×10^{-3} , přičemž toto rozmezí bylo identické pro oba modely. V případě hyperparametru *batch size* byl pro model U-Net zvolen rozsah od 2 do 6 s krokem 2, zatímco pro model DeepLabV3+ rozsah od 2 do 32 s krokem 4. Tento rozsah hyperparametrů byl použit jak při optimalizaci na části datasetu Syntax, tak na části Stenosis. Počet pokusů byl stanoven na 20 s ohledem na výpočetní i časovou náročnost. Finální hodnoty optimalizovaných hyperparametrů, které vedly k dosažení nejvyššího validačního Dice skóre na části datasetu Syntax, jsou uvedeny v Tab. 2.1. Analogicky jsou v Tab. 2.2 uvedeny nejlepší nalezené konfigurace hyperparametrů

Tab. 2.1: Finální hodnoty hyperparametrů pro jednotlivé modely s nejvyšším validačním Dice skóre na části datasetu SYNTAX.

Model	Learning Rate	Weight Decay	Batch Size	Dice Skóre
U-Netraw	$1,76 \times 10^{-4}$	$4,62 \times 10^{-5}$	4	0,790
U-Netpre	$7,77 \times 10^{-4}$	$1,04 \times 10^{-5}$	4	0,782
DeepLabV3+raw	$1,58 \times 10^{-4}$	$2,05 \times 10^{-5}$	6	0,810
DeepLabV3+pre	$3,35 \times 10^{-5}$	$1,93 \times 10^{-4}$	14	0,802

pro část datasetu Stenosis. Všechny výsledky jednotlivých běhů byly zaznamenány

Tab. 2.2: Finální hodnoty hyperparametrů pro jednotlivé modely s nejvyšším validačním Dice skóre na části datasetu Stenosis.

Model	Learning Rate	Weight Decay	Batch Size	Dice Skóre
U-Netraw	$9,26 \times 10^{-5}$	$1,04 \times 10^{-5}$	4	0,459
U-Netpre	$1,46 \times 10^{-4}$	$3,54 \times 10^{-5}$	6	0,477
DeepLabV3+raw	$3,73 \times 10^{-4}$	$4,36 \times 10^{-4}$	10	0,470
DeepLabV3+pre	$4,62 \times 10^{-4}$	$1,04 \times 10^{-5}$	22	0,469

do CSV souboru, jelikož budou dále využity pro vyhodnocení vlivu použitých hyperparametrů na výslednou kvalitu segmentace. Podrobnější analýza těchto výsledků je obsažena v následující kapitole 3, která se zaměřuje na statistické vyhodnocení dosažených výsledků. Kompletní výsledky optimalizace na částech Syntax a Stenosis jsou rovněž k nahlédnutí v přílohách A a B.

2.6 Trénování a validace modelů

K trénování modelů byla využita knihovna PyTorch Lightning [8], která poskytuje robustní nástroje pro efektivní správu tréninkového procesu. Vizualizace výstupů byla realizována pomocí knihoven NumPy [28] a Matplotlib [28].

Modely s architekturou U-Net a DeepLabV3+ byly trénovány za použití ztrátové funkce binární vzájemné entropie (angl. *Binary Cross Entropy*) a optimalizačního algoritmu Adam [18]. Trénink probíhal ve dvou variantách, a to s předzpracovanými daty a bez předzpracování. Celý proces trénování a validace byl řízen skriptem *engine.py*, jenž umožňuje snadné nastavení parametrů modelu a jednotlivých tréninkových kroků.


Optimalizace hyperparametrů byla realizována pomocí frameworku Optuna [1], který vyhledával optimální hodnoty pro krok učení (angl. *learning rate*), míru L2 regularizace vah (angl. *weight decay*) a velikost batch (angl. *batch size*). Experimenty byly provedeny na dvou částech datasetu ARCADE, konkrétně Syntax a Stenosis, a zahrnovaly celkem osm různých konfigurací (2 modely, 2 varianty dat, 2 režimy předzpracování). Maximální počet epoch byl při optimalizaci i při následném trénování stanoven na 30. Během tréninku byla využita funkcionality callbacků knihovny PyTorch Lightning, která umožnila průběžné sledování hodnot ztrátové funkce a metrik, včetně Dice skóre na validační množině. Optimalizace tréninkového procesu byla podpořena mechanismem *EarlyStopping*, jenž sledoval vývoj validační ztráty a ukončil trénink, pokud během pěti po sobě jdoucích epoch nedošlo ke zlepšení. Tento přístup nejenže snižoval riziko přeučení (angl. *overfitting*), ale také šetřil výpočetní kapacitu.

Pro testování modelů byla vždy použita ta verze modelu, která dosáhla nejvyššího validačního Dice skóre. Tento přístup zajistil, že predikce na testovacím datasetu reflektovaly nejlepší nalezenou konfiguraci hyperparametrů.

Nastavení hyperparametrů bylo řízeno skriptem *config.py*, v němž lze definovat hodnoty jako krok učení, míru L2 regularizace vah, velikost batch a počet epoch. Skript rovněž obsahuje dataloader pro načtení tréninkových, validačních a testovacích dat. Ve všech variantách modelů byly hyperparametry určeny na základě optimalizace prostřednictvím knihovny Optuna. Konkrétní hodnoty jsou uvedeny v Tab. 2.1 a Tab. 2.2.

Důležitou součástí skriptu *config.py* je proměnná *enhance*, která určuje, zda mají být vstupní data před tréninkem předzpracována. Pokud je nastavena na *True*, dataloader aplikuje předzpracování na každý tréninkový snímek, což modelu umožňuje učit se z upravených dat. Pokud je nastavena na *False*, do sítě jsou předávány původní, neupravené snímky.

Pomocí skriptu *plotloss.py* byly vytvořeny grafy znázorňující průběh ztrátové




Obr. 2.10: Porovnání průběhu ztrátové chyby během trénování na datech části Syntax z datasetu ARCADE. Grafy zobrazují dvě křivky pro každý z modelů – modrou pro trénovací ztrátu a oranžovou pro validační ztrátu. Porovnávány jsou čtyři varianty: U-Net s předzpracováním (U-Netpre), U-Net bez předzpracování (U-Netraw), DeepLabV3+ s předzpracováním (DeepLabV3+pre) a DeepLabV3+ bez předzpracování (DeepLabV3+raw). Vodorovná osa (x) představuje počet epoch, svislá osa (y) pak hodnoty ztrátové funkce.

chyby modelu během trénovacího procesu na datasetu ARCADE – část Syntax, jak je znázorněno na Obr. 2.10. V případě trénování modelu U-Net lze pozorovat, že varianta bez předzpracování (U-Netraw) vykazuje plynulý pokles tréninkové i validační ztráty, přičemž rozdíl mezi nimi zůstává relativně malý. To naznačuje dobrou generalizační schopnost modelu a stabilní konvergenci, která nastává přibližně po deseti epochách. Naopak varianta s předzpracováním (U-Netpre) vykazuje sice nižší hodnoty tréninkové chyby, nicméně validační chyba v průběhu tréninku mírně kolísá, což může indikovat přecitlivělost na validační vzorky a potenciální riziko přeučení.

U modelu DeepLabV3+ bez předzpracování (DeepLabV3+raw) dochází k výraznému poklesu tréninkové i validační ztráty během prvních několika epoch, po nichž následuje pozvolnější konvergence. Přibližně po desáté epoše však dochází k ná-

růstu validační chyby, což naznačuje začínající přeučení modelu. Z tohoto důvodu byl trénink předčasně ukončen pomocí algoritmu *early stopping*, který sleduje vývoj validační ztráty. Nejvýraznější zlepšení lze pozorovat u modelu DeepLabV3+ s předzpracováním (DeepLabV3+pre). Přestože tato varianta začíná s nejvyšší počáteční hodnotou ztrátové funkce, v průběhu tréninku dochází k plynulému a konzistentnímu poklesu obou chyb. Výsledkem je velmi těsné sladění mezi tréninkovou a validační ztrátou, což naznačuje výbornou generalizační schopnost modelu na validační data.



Obr. 2.11: Porovnání průběhu ztrátové chyby během trénování na datech části Stenosis z datasetu ARCADE. Grafy zobrazují dvě křivky pro každý z modelů – modrou pro trénovací ztrátu a oranžovou pro validační ztrátu. Porovnávají jsou čtyři varianty: U-Net s předzpracováním (U-Netpre), U-Net bez předzpracování (U-Netraw), DeepLabV3+ s předzpracováním (DeepLabV3+pre) a DeepLabV3+ bez předzpracování (DeepLabV3+raw). Vodorovná osa (x) představuje počet epoch, svislá osa (y) pak hodnoty ztrátové funkce.

Stejným způsobem byly vytvořeny grafy znázorňující průběh ztrátové chyby na datasetu ARCADE – část Stenosis, který je zobrazen na Obr. 2.11. Také v tomto

případě byl trénink řízen pomocí algoritmu *early stopping*, který monitoroval validační ztrátu a umožnil předčasné ukončení tréninku v případě, že nedocházelo k dalšímu zlepšení.

U modelu U-Net bez předzpracování (U-Netraw) lze pozorovat plynulý pokles obou ztrát, přičemž tréninková i validační chyba se po 15. epoše stabilizují na velmi nízkých hodnotách. Model vykazuje konzistentní učení bez známek přeučení.

U varianty s předzpracováním (U-Netpre) je průběh velmi podobný, avšak s mírně vyšší počáteční hodnotou chyb a rychlejším poklesem. Výsledné chyby jsou téměř totožné s variantou bez předzpracování, přičemž rozdíly mezi tréninkovou a validační ztrátou zůstávají minimální.

Model DeepLabV3+ bez předzpracování (DeepLabV3+raw) opět vykazuje prudký pokles chyb během prvních několika epoch, ale po 6. epoše lze pozorovat mírně kolísající validační chybu, což může naznačovat začínající přeučení. Přesto je zachována relativně dobrá generalizace a validační chyba se drží nízko.

Model DeepLabV3+ s předzpracováním (DeepLabV3+pre) vykazuje prudký pokles tréninkové a validační ztráty, nicméně po 10 epoše dochází k přeučení, což indikuje ukončení tréninku za pomoci *early stopping* algoritmu.

Průběh učení jednotlivých segmentačních modelů, a to jak s aplikovaným předzpracováním (pre), tak bez něj (raw), je podrobně zaznamenán v Tab. 2.3 a 2.4, které obsahují informace o celkovém počtu epoch, době tréninku a výsledném Dice skóre dosaženém na validačním datasetu. U části datasetu Syntax lze pozorovat, že modely s předzpracováním dosahují srovnatelného nebo mírně horšího Dice skóre. Tento výsledek naznačuje, že předzpracování v tomto případě nemělo výrazný vliv na zlepšení výkonu modelu, i když je předzpracování prováděno online. Nejlepšího výsledku dosáhl model DeepLabV3+ bez předzpracování (Dice = 81 %), přičemž rozdíl oproti variantě s předzpracováním je minimální. Obecně lze říci, že DeepLabV3+ vykazuje lepší efektivitu nejen z hlediska výkonu, ale i doby trénování.

Tab. 2.3: Porovnání trénování jednotlivých modelů na datech části Syntax z datasetu ARCADE.

Metoda	Počet epoch	Celková doba učení	Dice skóre [%]
U-Netraw	28	1,02 h	79,0
U-Netpre	24	52,55 min	78,2
DeepLabV3+raw	13	6,34 min	81,0
DeepLabV3+pre	29	13,11 min	80,2

U části datasetu Stenosis jsou výsledky výrazně horší než u části Syntax, což lze přičíst náročnější segmentaci stenotických oblastí a omezené kvalitě anotací. Model U-Net s aplikovaným předzpracováním dosahuje lepšího výkonu než varianta bez něj

Tab. 2.4: Porovnání trénování jednotlivých modelů na datech části Stenosis z data-setu ARCADE.

Metoda	Počet epoch	Celková doba učení	Dice skóre [%]
U-Netraw	23	50,54 min	45,9
U-Netpre	28	60,00 min	47,7
DeepLabV3+raw	15	6,93 min	47,0
DeepLabV3+pre	15	6,67 min	46,9

(Dice = 47,7 % oproti 45,9 %), což potvrzuje pozitivní vliv předzpracování na generalizační schopnost modelu a zlepšení výkonu při segmentaci stenózy. U modelu DeepLabV3+ jsou výsledky v obou variantách velmi podobné, přičemž trénování probíhalo výrazně rychleji než u modelu U-Net.

Celkově lze konstatovat, že aplikace předzpracování přispěla k lepšímu výkonu modelu U-Net, zejména u segmentace části Stenosis, kde varianta s předzpracováním vykazovala lepší výsledky než varianta bez něj. Naopak u části Syntax nepřineslo předzpracování výrazné zlepšení výkonu. Model DeepLabV3+ vykazuje stabilní výsledky a jeho výkon není výrazně ovlivněn aplikací předzpracování. Zároveň nabízí vyšší efektivitu z hlediska tréninkového času.


3 Statistická analýza výsledků

3.1 Analýza vlivu hyperparametrů na kvalitu výsledné segmentace

V rámci této diplomové práce byl zkoumán vliv hyperparametrů na kvalitu výsledné segmentace. Experimenty byly realizovány s využitím optimalizačního nástroje Optuna [1] pro všechny varianty testovaných modelů. Podrobný popis procesu optimalizace je uveden v podkapitole 2.5. Výsledky jednotlivých běhů, na nichž je tato analýza založena, jsou k dispozici v sekci příloh A a B.

Pro interpretaci výsledků byla využita metoda Shapleyho aditivních vysvětlení (SHAP, angl. *Shapley Additive Explanations*), která slouží jako nástroj pro interpretaci rozhodnutí modelů hlubokého učení. Inspiraci pro tuto analýzu poskytl článek [16], v němž autoři použili SHAP summary plot k hodnocení vlivu vstupních proměnných. V této práci je však SHAP summary plot využit k analýze vlivu jednotlivých hyperparametrů na kvalitu segmentace, přičemž hodnoticí metrikou bylo validační Dice skóre. Pro tuto analýzu byl vytvořen skript `shap_analysis.py`, ve kterém se načítají výsledky jednotlivých běhů pro každou variantu modelu. Na základě těchto dat je následně natrénován klasifikační model typu náhodného lesa, jehož výstupy jsou dále interpretovány pomocí SHAP analýzy. Skript automaticky generuje vizualizace (SHAP summary plot) samostatně pro část Syntax a samostatně pro část Stenosis. SHAP summary plot znázorňuje vliv jednotlivých hyperparametrů na výstupní validační Dice skóre. Na ose (x) jsou zobrazeny SHAP hodnoty, které udávají míru pozitivního či negativního dopadu daného hyperparametru na výsledné Dice skóre. Na ose (y) jsou hyperparametry seřazeny podle jejich významnosti. Každý bod v grafu odpovídá jednomu běhu modelu v rámci optimalizace, přičemž jeho horizontální poloha indikuje směr a sílu vlivu konkrétního hyperparametru. Barva bodu reprezentuje konkrétní hodnotu hyperparametru, přičemž modrá barva označuje nízké hodnoty a červená barva značí hodnoty vysoké. Pro správnou interpretaci výsledků SHAP analýzy je nezbytné znát rozsahy hodnot, ve kterých byly hyperparametry optimalizovány. V rámci optimalizačního procesu byly použity následující intervaly: pro *learning rate* a *weight decay* byl rozsah nastaven od 1×10^{-5} do 1×10^{-3} , přičemž volba těchto intervalů vycházela z doporučení uvedených v publikacích [34, 38] a z empirických zkušeností. Pro hyperparametr *batch size* byly u modelu U-Net zvoleny hodnoty od 2 do 6 s krokem 2 a u modelu DeepLabV3+ hodnoty od 2 do 32 s krokem 4. Tyto rozsahy byly stanoveny s ohledem na výpočetní náročnost trénování. Nízké hodnoty v grafu odpovídají parametrům blízkým dolní hranici daného intervalu, zatímco vysoké hodnoty odpovídají parametrům blízkým jeho horní hra-

nici. V rámci SHAP summary plotu byl vykreslen model U-Net bez předzpracování




Obr. 3.1: SHAP summary plot zobrazující vliv hyperparametrů na výstupní validační Dice skóre pro model U-Net bez předzpracování (U-Netraw) a s předzpracováním (U-Netpre) pro část Syntax. Na ose (x) jsou zobrazeny SHAP hodnoty, které udávají míru pozitivního či negativního dopadu daného hyperparametru na výsledné Dice skóre. Na ose (y) jsou hyperparametry seřazeny podle jejich významnosti. Každý bod v grafu odpovídá jednomu běhu modelu v rámci optimalizace, přičemž jeho horizontální poloha indikuje směr a sílu vlivu konkrétního hyperparametru. Barva bodu reprezentuje konkrétní hodnotu hyperparametru, přičemž modrá barva označuje nízké hodnoty a červená barva značí hodnoty vysoké.

(U-Netraw) a s ním (U-Netpre) a model DeepLabV3+ bez předzpracování (DeepLabV3+raw) a s ním (DeepLabV3+pre), a to jak pro část datasetu Syntax, tak i Stenosis.

Na Obr. 3.1 je znázorněn vliv jednotlivých hyperparametrů (*weight decay*, *lr*, *batch size*) na validačním Dice skóre modelu U-Net pro část dat Syntax. Tento vliv je zobrazen ve dvou variantách: bez předzpracování (U-Net raw) a s předzpracováním (U-Net pre) a vyjádřen pomocí SHAP hodnot.

U verze U-Netraw je patrný výraznější negativní dopad vyšších hodnot *weight decay* a *lr* na výkonnost modelu. V případě *batch size* jsou SHAP hodnoty blíže nule, což naznačuje menší vliv tohoto parametru na výslednou segmentaci. Naopak



Obr. 3.2: SHAP summary plot zobrazující vliv hyperparametrů na výstupní validační Dice skóre pro model DeepLabV3+ bez předzpracování (DeepLabV3+raw) a s předzpracováním (DeepLabV3+pre) pro část Syntax. Na ose (x) jsou zobrazeny SHAP hodnoty, které udávají míru pozitivního či negativního dopadu daného hyperparametru na výsledné Dice skóre. Na ose (y) jsou hyperparametry seřazeny podle jejich významnosti. Každý bod v grafu odpovídá jednomu běhu modelu v rámci optimalizace, přičemž jeho horizontální poloha indikuje směr a sílu vlivu konkrétního hyperparametru. Barva bodu reprezentuje konkrétní hodnotu hyperparametru, kde modrá barva označuje nízké hodnoty a červená barva značí hodnoty vysoké.


u U-Netpre jsou SHAP hodnoty pro všechny tři hyperparametry více rozptýlené, což naznačuje zvýšenou citlivost modelu na jejich nastavení při použití předzpracování dat. Nejvýznamnější vliv má v tomto případě *weight decay*, následovaný *lr*, zatímco nejmenší dopad má *batch size*. U všech tří hyperparametrů lze pozorovat, že vyšší hodnoty vedou k horší segmentaci, zatímco nižší hodnoty mají pozitivní dopad na výkon modelu.

Na Obr. 3.2 je znázorněn vliv hyperparametrů na validačním Dice skóre modelu DeepLabV3+ pro data Syntax, vyjádřený pomocí SHAP hodnot. Porovnány jsou verze bez předzpracování (DeepLabV3+raw) a s předzpracováním (DeepLabV3+pre).

U verze DeepLabV3+raw mají nižší hodnoty *weight decay* (modré body) převážně pozitivní vliv na výkon modelu, zatímco vyšší hodnoty (červené body) ne-

gativní dopad. Parametr *batch size* vykazuje více rozptýlených bodů okolo středu a odlehle vysoké hodnoty negativně ovlivňují segmentaci a nízké hodnoty pozitivně. Nejméně významný je *lr*, který vykazuje nejmenší rozptyl hodnot.

U verze DeepLabV3+pre dochází k výrazné změně v rozložení. Parametr *batch size* nyní vykazuje silnou koncentraci středních až vyšších hodnot v pozitivní oblasti SHAP, což naznačuje, že při předzpracování je větší batch výhodnější. Parametr *weight decay* má podobný trend jako u raw verze, ale s větším rozsahem hodnot. U *lr* jsou hodnoty více soustředěny kolem nuly. Předzpracování dat tedy významně mění



Obr. 3.3: SHAP summary plot zobrazující vliv hyperparametrů na výstupní validační Dice skóre pro model U-Net bez předzpracování (U-Netraw) a s předzpracováním (U-Netpre) pro část Stenosis. Na ose (x) jsou zobrazeny SHAP hodnoty, které udávají míru pozitivního či negativního dopadu daného hyperparametru na výsledné Dice skóre. Na ose (y) jsou hyperparametry seřazeny podle jejich významnosti. Každý bod v grafu odpovídá jednomu běhu modelu v rámci optimalizace, přičemž jeho horizontální poloha indikuje směr a sílu vlivu konkrétního hyperparametru. Barva bodu reprezentuje konkrétní hodnotu hyperparametru, přičemž modrá barva označuje nízké hodnoty a červená barva značí hodnoty vysoké.

citlivost modelu na jednotlivé hyperparametry, přičemž nejvýraznější změna nastává u parametru *batch size*, který se po předzpracování stává dominantním faktorem pro výkon modelu.

Na Obr. 3.3 je znázorněn vliv hyperparametrů (*weight decay*, *lr*, *batch size*) na validačním Dice skóre modelu U-Net pro data Stenosis, vyjádřený pomocí SHAP hodnot. Graf porovnává model bez předzpracování (U-Netraw, horní část) a s předzpracováním (U-Netpre, dolní část).

U verze U-Netraw mají nižší hodnoty *weight decay* (modré body) převážně pozitivní vliv na výkon modelu, zatímco vyšší hodnoty (červené body) jsou spojeny s negativními SHAP hodnotami, tedy s horším výkonem. Hyperparametr *lr* má podobný trend jako *weight decay*, ale s menším rozptylem. Poslední hyperparametr *batch size* má většinu hodnot soustředěnou kolem nuly, což naznačuje jeho menší vliv na výslednou segmentaci.


U verze U-Netpre lze pozorovat nižší rozptyl hodnot u všech tří hyperparametrů. Největší vliv má *weight decay*. Hodnoty *lr* a *batch size* zůstávají převážně kolem nuly, což potvrzuje jejich nízký dopad na výkon modelu v této konfiguraci. Celkově graf ukazuje, že pro data Stenosis má největší vliv na výkon modelu správné nastavení *weight decay*, zatímco *lr* a *batch size* hrají menší roli, zejména v případě modelu s předzpracováním. Na Obr. 3.4 je znázorněn vliv hyperparametrů (*batch size*, *weight decay*, *lr*) na validačním Dice skóre modelu DeepLabV3+ pro data Stenosis, vyjádřený pomocí SHAP hodnot. Graf porovnává model bez předzpracování (DeepLabV3+raw, horní část) a s předzpracováním (DeepLabV3+pre, dolní část).

U verze DeepLabV3+raw vykazuje parametr *batch size* zajímavý vzor, kde vyšší hodnoty (fialové až červené body) jsou zastoupeny jak v pozitivní, tak negativní oblasti SHAP hodnot. Parametr *weight decay* ukazuje výrazně negativní vliv vyšších hodnot (červené body) na výkon modelu, zatímco střední a nižší hodnoty jsou soustředěny blíže k nule. U *lr* jsou hodnoty koncentrovány především kolem nulové SHAP hodnoty, což naznačuje menší vliv tohoto parametru.

U verze DeepLabV3+pre jsou patrné výrazné změny. Parametr *weight decay* nyní vykazuje silný pozitivní vliv nízkých až středních hodnot, s koncentrací bodů v kladné oblasti SHAP. Výrazně negativní dopad mají pouze jednotlivé vysoké hodnoty. Parametr *batch size* má většinu hodnot soustředěných kolem nuly a v mírně pozitivní oblasti, s několika negativními odlehlými hodnotami. Parametr *lr* má minimální vliv s hodnotami těsně kolem nuly. Předzpracování dat tedy výrazně mění citlivost modelu na hyperparametry, zejména u parametru *weight decay*, který získává silnější pozitivní vliv při nižších hodnotách, zatímco u verze bez předzpracování má především negativní dopad při vyšších hodnotách.

Z provedených analýz vyplývá, že hodnota hyperparametru *weight decay* by měla být volena s opatrností, neboť má zásadní vliv na výslednou kvalitu segmentace. Ve všech sledovaných experimentech se ukázalo, že i malé změny této hodnoty mohou vést k výrazným rozdílům ve výkonnosti modelu.

Další metoda pro posouzení vlivu hyperparametrů byla zvolena Funkční analýza




Obr. 3.4: SHAP summary plot zobrazující vliv hyperparametrů na výstupní validační Dice skóre pro model DeepLabV3+ bez předzpracování (DeepLabV3+raw) a s předzpracováním (DeepLabV3+pre) pro část Stenosis. Na ose (x) jsou zobrazeny SHAP hodnoty, které udávají míru pozitivního či negativního dopadu daného hyperparametru na výsledné Dice skóre. Na ose (y) jsou hyperparametry seřazeny podle jejich významnosti. Každý bod v grafu odpovídá jednomu běhu modelu v rámci optimalizace a jeho horizontální poloha indikuje směr a sílu vlivu konkrétního hyperparametru. Barva bodu reprezentuje konkrétní hodnotu hyperparametru, přičemž modrá barva označuje nízké hodnoty a červená barva značí hodnoty vysoké.

rozptylu (fANOVA), která posuzuje marginální vliv důležitosti hyperparametrů, jak bylo popsáno v článku [15]. Pro účely práce byl vytvořen skript *fANOVA_analysis.py*, který zpracovává výsledky jednotlivých běhů pro každou variantu modelu. Na základě těchto dat je proveden výpočet důležitosti hyperparametrů pro každý model, přičemž jsou vyhodnoceny vlivy tří hlavních hyperparametrů: učícího se kroku (angl. *learning rate*), míra L2 regularizace vah (angl. *weight decay*) a velikosti batch (angl. *batch size*). Skript využívá knihovnu Optuna pro simulaci experimentů a aplikaci fANOVA metodologie. Nakonec na základě těchto analýz skript generuje vizualizace, které ukazují důležitost těchto hyperparametrů pro každý model v rámci části datasetu ARCADE Syntax a Stenosis. Výsledné grafy znázorňují, jaký vliv mají jednotlivé hyperparametry na výstupní validační Dice skóre. V rámci fANOVA ana-

lýzy byl vykreslen graf důležitosti hyperparametrů pro všechny modely společně, a to nejprve pro část Syntax, následně pro segmentaci stenózy (Stenosis). Byly zahrnuty modely U-Net bez předzpracování (U-Netraw) i s předzpracováním (U-Netpre), stejně jako modely DeepLabV3+ bez předzpracování (DeepLabV3+raw) a s předzpracováním (DeepLabV3+pre).


Na Obr. 3.5 je zobrazen sloupcový graf důležitosti hyperparametrů pro všechny čtyři varianty modelu: U-Netraw, U-Netpre, DeepLabV3+raw a DeepLabV3+pre. U modelu U-Netraw je nejdůležitějším hyperparametrem *weight decay*, stejně tak u varianty s předzpracováním (U-Netpre). V obou případech je druhým nejvýznamnějším hyperparametrem *lr* a nejméně důležitým *batch size*. U varianty modelu De-



Obr. 3.5: Sloupcový graf zobrazující důležitost jednotlivých hyperparametrů (*lr*, *batch size*, *weight decay*) podle funkční analýzy rozptylu (fANOVA) pro čtyři různé modely: U-Netraw, U-Netpre, DeepLabV3+raw a DeepLabV3+pre v části Syntax. Na ose (x) jsou jednotlivé modely, na ose (y) je důležitost hyperparametru. Každá barva reprezentuje jeden hyperparametr.

epLabV3+ bez předzpracování (DeepLabV3+raw) se jako nejvýznamnější hyperparametr ukázal *weight decay*, následovaný hyperparametrem *batch size*. Naopak u verze s předzpracováním (DeepLabV3+pre) měl největší vliv hyperparametr *batch*

size, přičemž druhý nejvýznamnější byl *weight decay*. Pro obě varianty modelu DeepLabV3+ platí, že hyperparametr *lr* měl nejmenší vliv na výslednou přesnost.



Obr. 3.6: Sloupcový graf zobrazující důležitost jednotlivých hyperparametrů (*lr*, *batch size*, *weight decay*) podle funkční analýzy rozptylu (fANOVA) pro čtyři různé modely: U-Netraw, U-Netpre, DeepLabV3+raw a DeepLabV3+pre v části Stenosis. Na ose (x) jsou jednotlivé modely, na ose (y) je důležitost hyperparametru. Každá barva reprezentuje jeden hyperparametr.

Na Obr. 3.6 je opět zobrazen sloupcový graf důležitosti hyperparametrů pro všechny čtyři varianty modelu. U modelu U-Netraw zůstává nejdůležitějším hyperparametrem *weight decay*, stejně tak u varianty s předzpracováním (U-Netpre), avšak u této varianty dosahuje jeho důležitost vyšších hodnot. V obou případech je druhým nejvýznamnějším hyperparametrem *learning rate* a nejméně důležitým *batch size*.

U modelu DeepLabV3+ bez předzpracování (DeepLabV3+raw) vykazuje hyperparametr *batch size* nejvyšší hodnotu důležitosti, přičemž stejný hyperparametr dosahuje nejvyšší hodnoty důležitosti i u předzpracované verze (DeepLabV3+pre), avšak s nižší hodnotou. Druhou nejvyšší hodnotu důležitosti má v obou variantách modelu hyperparametr *weight decay*. Nejnižší hodnotu důležitosti ve všech případech vykazuje *learning rate*. Tab. 3.1 shrnuje výsledky obou analýz a umožňuje porov-

nat, který hyperparametr byl označen jako nejdůležitější metodou SHAP a metodou fANOVA pro jednotlivé modely a části datasetu.

Z Tab. 3.1 vyplývá, že obě metody, SHAP a fANOVA, se ve většině případů shodují na identifikaci nejdůležitějšího hyperparametru, což potvrzuje konzistenci jejich výstupů. Například u modelů U-Net (raw i pre) a části datasetu Syntax i Stenosis se obě analýzy jednoznačně shodly na významnosti hyperparametru *weight decay*.

U modelu DeepLabV3+ panuje mezi metodami SHAP a fANOVA shoda v rámci části Syntax. U varianty DeepLabV3+raw obě metody určují jako nejvýznamnější hyperparametr *weight decay*. U varianty DeepLabV3+pre se obě metody shodují na tom, že největší hodnotu důležitosti má *batch size*.

V části Stenosis se situace liší. U varianty DeepLabV3+raw označují SHAP i fANOVA jako nejdůležitější hyperparametr *batch size*. U varianty DeepLabV3+pre se však výsledky metod rozcházejí. Zatímco metoda SHAP přisuzuje nejvyšší důležitost hyperparametru *weight decay*, metoda fANOVA za nejdůležitější považuje *batch size*.

Tab. 3.1: Nejdůležitější hyperparametr pro jednotlivé varianty modelů a části datasetu podle SHAP a fANOVA.

Model	Část datasetu	SHAP	fANOVA
U-Netraw	Syntax	weight decay	weight decay
U-Netpre	Syntax	weight decay	weight decay
DeepLabV3+raw	Syntax	weight decay	weight decay
DeepLabV3+pre	Syntax	batch size	batch size
U-Netraw	Stenosis	weight decay	weight decay
U-Netpre	Stenosis	weight decay	weight decay
DeepLabV3+raw	Stenosis	batch size	batch size
DeepLabV3+pre	Stenosis	weight decay	batch size

Výsledky analýzy vlivu hyperparametrů ukazují, že význam jednotlivých hyperparametrů se liší v závislosti na použité architektuře modelu a předzpracování dat. Nejvýznamnější hyperparametr je vždy ten, jehož změna má největší dopad na validační Dice skóre, což je doloženo jak metodou SHAP, tak fANOVA. Tyto metody poskytují konzistentní výsledky, s výjimkou jedné varianty modelu, kde se jejich závěry mírně liší.

U modelu U-Net na části Syntax se jako nejvýznamnější hyperparametr ukázal *weight decay*. Tento parametr zásadně ovlivňuje míru regularizace modelu, což je u U-Netu klíčové pro dosažení dobré generalizace. Příliš vysoká hodnota *weight decay* vede k nadměrnému penalizování modelu, což může způsobit ztrátu schopnosti naučit se jemné detaily segmentace, naopak příliš nízká hodnota může vést

k přeučení modelu. Výsledky ukazují, že nižší hodnoty *weight decay* (blíže 1×10^{-5}) přinášejí lepší Dice skóre. Tento závěr platí jak pro verzi modelu bez předzpracování dat, tak i pro variantu s předzpracováním.

U modelu DeepLabV3+ na části Syntax, bez předzpracování dat, se také jako nejvýznamnější hyperparametr ukázal *weight decay*, což naznačuje, že regularizace je v tomto případě zásadní pro udržení dobrého výkonu. Po předzpracování dat se však jako klíčový hyperparametr ukázala velikost batche. Větší velikost batche v této konfiguraci pravděpodobně přispívá ke stabilnějšímu učení a lepším výsledkům segmentace, pravděpodobně díky vyrovnanějšímu odhadu gradientů.

Pro model U-Net na části Stenosis je opět nejvýznamnějším hyperparametrem *weight decay*. I zde platí, že správné nastavení regularizace je zásadní pro dosažení optimálního výkonu. Nižší hodnoty *weight decay* přinášejí lepší výsledky, což odpovídá chování modelu na části Syntax. Tento závěr platí jak pro verzi modelu bez předzpracování dat, tak i pro variantu s předzpracováním.

U modelu DeepLabV3+ na části Stenosis se bez předzpracování dat nejdůležitějším hyperparametrem ukázala velikost batche. To znamená, že velikost batche má v této konfiguraci zásadní vliv na výslednou segmentaci. Větší velikosti batche mohou přispět k lepší stabilitě trénování. Po předzpracování dat se výsledky metod SHAP a fANOVA liší: podle SHAP je nejvýznamnější *weight decay*, podle fANOVA velikost batche. Tento rozdíl lze přičíst odlišným principům výpočtu důležitosti v těchto metodách, nicméně oba parametry jsou v tomto případě důležité a zasluhují pozornost.

Na základě těchto výsledků doporučuji následující přístupy pro ladění hyperparametrů:

- **U-Net (Syntax i Stenosis):** Zaměřit se především na správné nastavení *weight decay*, ideálně testovat nižší hodnoty v rámci zvoleného intervalu.
- **DeepLabV3+ bez předzpracování:** Pro část Syntax je klíčový *weight decay*, pro část Stenosis velikost batche.
- **DeepLabV3+ s předzpracováním:** Pro část Syntax je zásadní velikost batche, pro část Stenosis je vhodné věnovat pozornost jak *weight decay*, tak velikosti batche.

Learning rate má v těchto experimentech menší vliv, ale jeho extrémní hodnoty mohou výsledky ovlivnit. Například pokud by byla hodnota *learning rate* příliš malá a mimo vhodný interval, model by se nemusel efektivně naučit, což by vedlo k špatnému výkonu. Proto jej nelze zcela opomenout.

Tato doporučení reflektují výsledky obou použitých metod (SHAP a fANOVA) a specifika jednotlivých modelových architektur a variant předzpracování dat.

3.2 Dosažené výsledky na testovací sadě dat

Na datasetu ARCADE, část Syntax, který obsahuje 1000 snímků pro trénování, 200 pro validaci a 300 pro testování generalizace modelu, byla natrénována neuronová síť U-Net ve dvou variantách: bez aplikace předzpracování (U-Netraw) a s provedeným předzpracováním (U-Netpre). Rovněž segmentační síť DeepLabV3+ bez předzpracování (DeepLabV3+raw) a s ním (DeepLabV3+pre).

Pro vizuální hodnocení segmentace byly u testovací sady vykresleny predikce každého snímku pro každý model. Výsledky zahrnovaly tři varianty: správně vysegmentované cévní řečiště, segmentaci, která byla lepší než poskytnutá anotace, a segmentaci horší než poskytnutá anotace. Na Obr. 3.7 je uveden příklad správně vysegmentovaného snímku z testovací sady, který zahrnuje vstupní snímek, jeho předzpracovanou verzi a fúzi obrazu. Ve fúzi jsou barevně odlišena následující označení: anotace (zelená barva), chybná predikce modelu (fialová barva), správná segmentace (bílá barva) a správně nesegmentované oblasti (černá barva). Předzpracování zahrnovalo aplikaci metody CLAHE a bílé top-hat transformace.



Obr. 3.7: Ukázka procesu segmentace na snímku z testovací sady části Syntax. Zleva: originální snímek, předzpracovaný snímek a fúze anotované a predikované masky. Zelená barva označuje anotaci, fialová oblast chybnou predikci (segmentaci navíc), bílá správnou segmentaci a černá oblasti správně ponechané bez segmentace. Predikce odpovídá anotaci, což demonstruje správně vysegmentované cévní řečiště.


Jak již bylo zmíněno v podkapitole 2.1 o datasetu ARCADE, autoři sítě anotovali jen 60% až 70% koronárních cév. Tato skutečnost může vést k případům, kde predikce modelu vykazuje lepší segmentaci cévy než samotná provedená anotace. Na Obr. 3.8 vidíme situaci, kdy predikce modelu překonává kvalitu poskytnuté anotace, což ukazuje na omezení manuálního anotování datasetu ARCADE.

V posledním příkladu na Obr. 3.9 je ilustrována situace, kdy je predikce horší než poskytnutá anotovaná maska. Neúspěšnost predikce u tohoto konkrétního snímku je způsobena přítomností struktur odlišných od cév. Konkrétně jde o katéتر, který



Obr. 3.8: Ukázka procesu segmentace na snímku z testovací sady části Syntax. Zleva: originální snímek, předzpracovaný snímek a fúze anotované a predikované masky. Zelená barva označuje anotaci, fialová oblast chybnou predikci (segmentaci navíc), bílá správnou segmentaci a černá oblasti správně ponechané bez segmentace. Predikce překonává kvalitu poskytnuté anotace, což ukazuje na její nedostatečnost.


neuronová síť mylně vysegmentovala jako součást cévního systému. Přítomnost podobných objektů komplikuje proces segmentace. Autoři datasetu ARCADE zahrnuli snímky s takovými objekty, aby zvýšili náročnost segmentace a přiblížili ji reálným podmínkám.




Obr. 3.9: Ukázka procesu segmentace na snímku z testovací sady části Syntax. Zleva: originální snímek, předzpracovaný snímek a fúze anotované a predikované masky. Zelená barva označuje anotaci, fialová oblast chybnou predikci (segmentaci navíc), bílá správnou segmentaci a černá oblasti správně ponechané bez segmentace. Predikce nedosahuje kvality poskytnuté anotace, což je způsobeno nesprávnou segmentací kateétru zachyceného ve snímku.

Na druhé části datasetu ARCADE, konkrétně části Stenosis, která rovněž obsahuje 1000 snímků pro trénování, 200 snímků pro validaci a 300 snímků pro testování generalizace modelu, byly natrénovány modely: U-Netraw, U-Netpre, De-

epLabV3+raw a DeepLabV3+pre. Stejně jako u části Syntax byly vykresleny predikce každého snímku pro každý z modelů. Výsledky zahrnovaly tři varianty: správně vysegmentovanou oblast stenózy, segmentaci horší než poskytnutá anotace způsobenou přítomností cizích předmětů, a případy, kdy model zcela selhal a segmentace dosáhla nulové úspěšnosti. Na Obr. 3.10 je uveden příklad správně vysegmentovaného snímku z testovací sady, části Stenosis.




Obr. 3.10: Ukázka procesu segmentace na snímku z testovací sady části Stenosis. Zleva: originální snímek, předzpracovaný snímek a fúze anotované a predikované masky. Zelená barva označuje anotaci, fialová oblast chybnou predikci (segmentaci navíc), bílá správnou segmentaci a černá oblasti správně ponechané bez segmentace. Predikce odpovídá anotaci, což demonstruje správně vysegmentovanou stenotickou oblast.



Obr. 3.11: Ukázka procesu segmentace na snímku z testovací sady části Stenosis. Zleva: originální snímek, předzpracovaný snímek a fúze anotované a predikované masky. Zelená barva označuje anotaci, fialová oblast chybnou predikci (segmentaci navíc), bílá správnou segmentaci a černá oblasti správně ponechané bez segmentace. Predikce je horší než poskytnutá anotace stenotické oblasti, vlivem přítomnosti katótru.

Na Obr. 3.11 je uveden příklad špatně vysegmentovaného snímku z testovací sady, části Stenosis, kde je model zmaten přítomností katétru. Na Obr. 3.12 je



Obr. 3.12: Ukázka procesu segmentace na snímku z testovací sady části Stenosis. Zleva: originální snímek, předzpracovaný snímek a fúze anotované a predikované masky. Zelená barva označuje anotaci, fialová oblast chybnou predikci (segmentaci navíc), bílá správnou segmentaci a černá oblasti správně ponechané bez segmentace. Predikce je horší než poskytnutá anotace stenotické oblasti, vlivem selhání modelu.

uveden příklad špatně vysegmentovaného snímku z testovací sady, části Stenosis, kde model dosáhl nulové úspěšnosti a celkově v predikci selhal.


3.3 Statistické vyhodnocení segmentačních modelů

Pro kvantitativní vyhodnocení úspěšnosti modelů na testovací sadě byly použity metriky Dice skóre, Jaccardův index, senzitivita a pozitivní prediktivní hodnota (PPV), která se také často označuje jako přesnost. Tyto metriky poskytují komplexní pohled na kvalitu segmentace, neboť zahrnují jak míru překryvu mezi predikcí a anotovanou maskou, tak i míru falešně pozitivních a falešně negativních detekcí. Dice skóre představuje harmonický průměr PPV a senzitivity, zatímco Jaccardův index vyjadřuje poměr průniku a sjednocení masek. Senzitivita měří schopnost modelu detekovat relevantní segmenty, a PPV vyjadřuje podíl správně pozitivně predikovaných oblastí ze všech pozitivních predikcí [4, 25].

Pro statistické vyhodnocení byl vytvořen skript *predictbatch.py*, který automatizovaně vypočítal hodnoty všech uvedených metrik pro každý snímek v testovací části datasetu ARCADE, konkrétně pro podmnožiny Syntax a Stenosis. V rámci každé části byly testovány čtyři různé konfigurace vah modelů.

U části Syntax byla první konfigurace reprezentována modelem U-Net bez předzpracování, který dosáhl Dice skóre 79,0 % na validačním datasetu. Druhá konfigurace využívala U-Net s předzpracováním (78,2 %). Třetí a čtvrtá konfigurace od-

povídaly modelu DeepLabV3+ bez předzpracování (81,0%) a s předzpracováním (80,2%). Výsledky predikcí byly ukládány samostatně pro každého pacienta a každou konfiguraci, což umožňuje následnou analýzu za pomoci krabicových grafů.



Obr. 3.13: Krabicové grafy zobrazující rozložení hodnot Jaccardova indexu, Dice skóre, senzitivity a pozitivní prediktivní hodnoty pro modely bez předzpracování (U-Netraw, DeepLabV3+raw) a s předzpracováním (U-Netpre, DeepLabV3+pre). Černá linie uvnitř každého boxu znázorňuje medián, dolní a horní hrana boxu odpovídají kvartilům q_{25} a q_{75} , vousy ukazují obvyklý rozsah hodnot a body mimo vousy představují odlehlé hodnoty.

Pro vizualizaci výkonnosti jednotlivých segmentačních modelů byly využity krabicové grafy, které umožňují přehledné a efektivní srovnání výsledků napříč kon-

figuracemi modelu U-Net bez předzpracování (U-Netraw), s předzpracováním (U-Netpre) a modelu DeepLabV3+ v obdobných verzích modelu bez předzpracování (DeepLabV3+raw) a s ním (DeepLabV3+pre).

Krabicové grafy byly sestaveny pro čtyři základní konfigurace modelů a hodnotí výkonnost pomocí metrik: Jaccardův index, Dice skóre, senzitivita a pozitivní prediktivní hodnota. Na Obr. 3.13 jsou uvedeny výsledky těchto metrik pro část Syntax. Grafy poskytují vizuální přehled o rozptylu výsledků mezi jednotlivými pacienty a umožňují detailní porovnání výkonnosti daných modelových konfigurací. Zobrazené krabicové grafy zahrnují rozsah hodnot včetně kvartilů q_{25} a q_{75} , medi-

Tab. 3.2: Výsledky průměru, mediánu a směrodatné odchylky pro modely U-Netraw, U-Netpre, DeepLabV3+raw a DeepLabV3+pre pro dané nastavení vah. Výsledky jsou vyjádřeny v procentech. Tučně jsou vyznačeny nejlepší hodnoty průměru a mediánu v rámci každé metriky.

Model - Metrika	Průměr	Medián	Směrodatná odchylka
U-Netraw - Jaccard	60,57	62,45	13,74
U-Netpre - Jaccard	55,96	57,22	15,97
DeepLabV3+raw - Jaccard	61,18	62,54	13,71
DeepLabV3+pre - Jaccard	61,13	62,29	14,59
U-Netraw - Dice skóre	74,45	76,89	11,68
U-Netpre - Dice skóre	70,31	72,79	14,37
DeepLabV3+raw - Dice skóre	74,94	76,95	11,69
DeepLabV3+pre - Dice skóre	74,74	76,77	12,74
U-Netraw - Přesnost	77,40	80,50	14,03
U-Netpre - Přesnost	78,15	81,63	14,71
DeepLabV3+raw - Přesnost	81,74	86,51	13,08
DeepLabV3+pre - Přesnost	81,01	86,03	13,81
U-Netraw - Senzitivita	73,96	76,44	13,80
U-Netpre - Senzitivita	66,25	68,69	16,99
DeepLabV3+raw - Senzitivita	70,82	73,14	13,70
DeepLabV3+pre - Senzitivita	71,11	72,90	14,38

ánu a případných odlehlých hodnot, což umožňuje rychlé a přehledné porovnání výkonnosti jednotlivých modelů. Na základě těchto vizualizací lze konstatovat, že model U-Netraw dosahuje mírně lepších výsledků než model U-Netpre v metrikách Jaccardova indexu, Dice skóre a senzitivity. Naopak v metrice pozitivní prediktivní hodnoty vykazuje lepší výkon model U-Netpre. U modelu DeepLabV3+ jsou výkonnosti variant s předzpracováním i bez něj ve všech metrikách vzájemně velmi podobné.

Pro podrobnější kvantitativní srovnání byla dále provedena popisná statistická analýza, v jejímž rámci byly pro každou metriku vypočteny průměr, medián a směrodatná odchylka. Přehled těchto výsledků je uveden v Tab. 3.2.


Jak vyplývá z Tab. 3.2, model DeepLabV3+raw dosáhl nejvyšších hodnot ve třech ze sledovaných metrik: Jaccardově indexu, Dice skóre a přesnosti. U Jaccardova indexu činí průměrná hodnota 61,18 % a medián 62,54 %. Dice skóre dosahuje průměru 74,94 % a mediánu 76,95 %. V metrice přesnost vykazuje tento model rovněž nejlepší výkonnost s průměrnou hodnotou 81,74 % a mediánem 86,51 %. Naopak nejvyšší výsledek v metrice senzitivita dosáhl model U-Netraw, a to s průměrem 73,96 % a mediánem 76,44 %. Směrodatné odchylky pro všechny varianty modelů jsou relativně podobné, což naznačuje, že výsledky modelů jsou konzistentní a neexistují žádné výrazné výkyvy v jejich výkonnosti. U všech modelů, ať už s předzpracováním, či bez něj, jsou směrodatné odchylky ve všech metrikách (Jaccard, Dice skóre, přesnost a senzitivita) podobné a pohybují se v rozmezí přibližně 11 až 17 %. To ukazuje na stabilitu jednotlivých modelů při segmentaci a na absenci výrazných variací mezi pacienty nebo jednotlivými případy, což naznačuje, že modely fungují spolehlivě bez větších fluktuací ve výkonnosti.

Pro část Stenosis byly rovněž testovány čtyři konfigurace vah modelů. Model U-Net bez předzpracování dosáhl Dice skóre 45,9 % na validačním datasetu, zatímco s předzpracováním to bylo 47,7 %. Třetí konfigurace, DeepLabV3+ bez předzpracování, dosáhla hodnoty 47,0 %, a poslední konfigurace, DeepLabV3+ s předzpracováním, vykazovala 46,9 % Dice skóre. Predikce byly ukládány samostatně pro každého pacienta a každou konfiguraci, což umožnilo následnou analýzu za použití krabicových grafů.

Na Obr. 3.14 jsou uvedeny výsledky těchto metrik pro část Stenosis. Krabicové grafy poskytují vizuální přehled o variabilitě výsledků mezi jednotlivými pacienty a umožňují srovnání výkonnosti jednotlivých modelů.

Tyto grafy zobrazují rozsah hodnot včetně kvartilů q_{25} a q_{75} , mediánu a případných odlehlých hodnot, což umožňuje rychlé porovnání výkonu jednotlivých modelů. Na základě těchto vizualizací lze konstatovat, že model U-Netraw vykazuje mírně lepší výkon než model U-Netpre v metrikách Jaccardova indexu, Dice skóre, PPV a senzitivity. U modelu DeepLabV3+ jsou výkony verzí s předzpracováním ve všech metrikách lepší než verze bez předzpracování. Pro hlubší kvantitativní porovnání byla dále provedena popisná statistická analýza, v rámci níž byl pro každou metriku vypočítán průměr, medián a směrodatná odchylka. Výsledky této analýzy jsou uvedeny v Tab. 3.3.

Z výsledků uvedených v Tab. 3.3 je patrné, že model DeepLabV3+pre vykazuje nejlepší průměrné hodnoty u metrik Jaccard, Dice skóre a senzitivity. U metriky Jaccard dosahuje průměrné hodnoty 18,92 %, což je nejlepší výkon mezi všemi tes-



Obr. 3.14: Krabicové grafy zobrazující rozložení hodnot Jaccardova indexu, Dice skóre, senzitivity a pozitivní prediktivní hodnoty pro modely bez předzpracování (U-Netraw, DeepLabV3+raw) a s předzpracováním (U-Netpre, DeepLabV3+pre). Černá linie uvnitř každého boxu znázorňuje medián, dolní a horní hrana boxu odpovídají kvartilům q_{25} a q_{75} , vousy ukazují obvyklý rozsah hodnot a body mimo vousy představují odlehlé hodnoty.

tovanými modely a podobně vyniká i u Dice skóre s hodnotou 30,22 %. V oblasti senzitivity model DeepLabV3+pre dosahuje průměrné hodnoty 21,22 % a mediánu 19,94 %, což opět ukazuje na jeho silnější výkon s ohledem na jiné použité modely.

Naopak, pro metriku pozitivní prediktivní hodnoty (PPV) vykazuje nejlepší výkon model U-Netraw, který dosahuje průměrné hodnoty 73,82 % a mediánu 79,54 %.

Tab. 3.3: Výsledky průměru, mediánu a směrodatné odchylky pro modely U-Netraw, U-Netpre, DeepLabV3+raw a DeepLabV3+pre při segmentaci stenózy. Tučně jsou vyznačeny nejlepší modely v rámci každé metriky podle průměru a mediánu.

Model - Metrika	Průměr	Medián	Směrodatná odchylka
U-Netraw - Jaccard	17,52	17,06	11,32
U-Netpre - Jaccard	16,53	15,81	11,42
DeepLabV3+raw - Jaccard	15,40	14,95	10,30
DeepLabV3+pre - Jaccard	18,92	18,34	11,65
U-Netraw - Dice skóre	28,29	29,15	15,98
U-Netpre - Dice skóre	26,77	27,31	16,48
DeepLabV3+raw - Dice skóre	25,35	26,01	15,18
DeepLabV3+pre - Dice skóre	30,22	31,00	16,45
U-Netraw - Přesnost	73,82	79,54	21,51
U-Netpre - Přesnost	68,26	74,80	25,11
DeepLabV3+raw - Přesnost	67,72	73,34	22,76
DeepLabV3+pre - Přesnost	68,84	73,50	21,04
U-Netraw - Senzitivita	18,98	18,05	13,07
U-Netpre - Senzitivita	18,24	16,84	13,36
DeepLabV3+raw - Senzitivita	16,93	15,92	12,05
DeepLabV3+pre - Senzitivita	21,22	19,94	14,03

Tento model tedy exceluje zejména v predikci pozitivních případů, zatímco model DeepLabV3+pre je celkově nejlepší ve všech ostatních metrikách. Pokud se zaměříme na směrodatné odchylky, můžeme pozorovat, že všechny modely vykazují relativně vysokou variabilitu, přičemž nejvyšší směrodatná odchylka se vyskytuje u metriky přesnost (PPV), kde model U-Netpre dosahuje hodnoty 25,11 %. To naznačuje, že u některých pacientů může být výkon modelu výrazně lepší než u jiných. Celkově lze tvrdit, že modely na části datasetu Stenosis vykazují větší variabilitu ve srovnání s částí Syntax, což může mít vliv na spolehlivost a robustnost modelů v reálných podmínkách.

3.4 Diskuze

V rámci podkapitoly 3.3 bylo provedeno statistické vyhodnocení segmentačních modelů za pomoci krabicových grafů a popisné statistiky na testovacím datasetu. V datasetu ARCADE, v části Syntax, dosáhl model DeepLabV3+raw nejvyššího Dice skóre s průměrnou hodnotou 74,94 %. V části zaměřené na segmentaci stenóz byl

nejlepším modelem DeepLabV3+pre s výsledkem 30,22 % Dice skóre. Nižší výkon při segmentaci stenóz je způsoben tím, že anotace v datasetu ARCADE byly původně určeny pro detekci stenóz, nikoliv pro jejich segmentaci, což může vést k nižší přesnosti při pokusu o segmentaci.

Na základě dosažených výsledků je provedeno srovnání s ostatními autory, kteří se zúčastnili výzvy ARCADE. V oblasti segmentace koronárních tepen dosáhl nejlepších výsledků Yikai Yang a kol. [40] s modelem nnUNet, přičemž hodnocení probíhalo dle metodiky SYNTAX. Autoři uvádějí průměrné Dice skóre 83,6% pro hlavní koronární tepnu, zatímco celkové průměrné Dice skóre napříč všemi segmenty činilo 45,0 %.

Jonghoe Ku a kol. [20] představili algoritmus MPSEg, který v první fázi klasifikoval jednotlivé cévní segmenty pomocí detekčního modelu YOLOv8m a následně prováděl segmentaci pomocí sítě UNet++ s enkodérem ResNet-34. Tento dvoufázový přístup vedl k dosažení průměrného Dice skóre 44,4% a zajistil autorům druhé místo ve výzvě.

Tom Liu a kol. [24] využili algoritmus YOLO-Angio, který byl podrobně popsán v řešeršní části podkapitoly 1.5. Tento přístup dosáhl Dice skóre 42,89 % a autoři se umístili na desátém místě.

V Tab.3.4 je uveden přehled výsledků segmentace koronárních tepen dle metodologie SYNTAX. Lze tvrdit, že vlastní implementace modelu DeepLabV3+raw dosáhla vyššího Dice skóre ve srovnání s ostatními autory. Nicméně autoři v rámci výzvy museli správně vysegmentovat jednotlivé segmenty dle SYNTAX metodologie, která vyžaduje přesné rozlišení 16 anatomických segmentů.

Tab. 3.4: Srovnání výsledků segmentace koronárních tepen na datasetu ARCADE

Autor / Model	Použitý přístup	Dice skóre [%]	Umístění
Yikai YANG a kol.	nnUNet	45,00	1.
Jonghoe KU a kol.	MPSEg	44,40	2.
Tom LIU a kol.	YOLO-Angio	42,89	10.
Vlastní implementace	DeepLabV3+raw	74,94	–

Je třeba zdůraznit, že dosažené hodnoty Dice skóre v této práci vycházejí z binární segmentace (céva vs. pozadí), což je metodicky jednodušší úloha než segmentace jednotlivých anatomických segmentů podle klasifikace SYNTAX. Ostatní autoři, kteří se zúčastnili výzvy ARCADE, hodnotili své modely právě na základě této vícetřídní segmentace, kde je každý cévní segment klasifikován zvlášť podle přesně definovaných anatomických oblastí.

Tento rozdíl v přístupu zásadně ovlivňuje dosažené výsledky. V případě binární segmentace, kde je úkolem odlišit cévní struktury od pozadí, lze dosáhnout vyš-

šího Dice skóre, protože není nutné rozlišovat jednotlivé segmenty cév. Naopak při segmentaci dle metodiky SYNTAX musí model správně identifikovat a klasifikovat až 16 anatomických segmentů, což výrazně zvyšuje obtížnost úlohy a snižuje dosažené skóre.

Proto dosažené Dice skóre v této práci (74,94 %) není přímo srovnatelné s výsledky ostatních autorů, kteří dosahovali nižších hodnot právě kvůli náročnějšímu zadání. Tento rozdíl je zásadní pro správnou interpretaci výsledků a měl by být vždy zohledněn při hodnocení výkonnosti modelů.

V rámci segmentace stenóz se výzvy ARCADE zúčastnili následující autoři: In Kyu Lee a kol. [22], kteří dosáhli nejlepších výsledků v této části díky využití modelu YOLOv8m a aplikaci datové augmentace, čímž dosáhli průměrného Dice skóre 56,9 %.

Hui Lin a kol. [23] představili model StenUNet, jenž byl v rámci řešerše vybrán pro porovnání výsledků v oblasti segmentace stenóz. Tito autoři dosáhli Dice skóre 53,5 % a ve výzvě se umístili na třetím místě.

Muhammad Bilal a kol. [5] se SOTA algoritmem, který obsahoval šest modelů včetně například DeepLabV3+, se umístili na šestnáctém místě a dosáhli Dice skóre 39,4 % pro detekci stenóz.

V Tab. 3.5 jsou uvedeny výsledky segmentace stenotických oblastí v rámci datasetu ARCADE. Nejlepšího výsledku dosáhli autoři In Kyu Lee a kol., kteří s využitím modelu YOLOv8m v kombinaci s datovou augmentací vyhráli celou výzvu a dosáhli Dice skóre 56,9 %. Tento výsledek překonal ostatní účastníky, pravděpodobně díky efektivnímu použití augmentace, která přispěla ke zvýšení robustnosti modelu.

Tab. 3.5: Srovnání výsledků segmentace stenóz na datasetu ARCADE

Autor / Model	Použitý přístup	Dice skóre [%]	Umístění
In Kyu Lee a kol.	YOLOv8m	56,90	1.
Hui Lin a kol.	StenUNet	53,50	3.
Muhammad Bilal a kol.	SOTA algoritmus	39,40	16.
Vlastní implementace	DeepLabV3+pre	30,22	—

Vlastní implementace s modelem DeepLabV3+pre dosáhla na 30,22 % Dice skóre, což je výrazně nižší hodnota než u vítězného modelu, ale stále relevantní pro porovnání. Při analýze výsledků je důležité poznamenat, že nižší výkon na segmentaci stenóz může být také způsoben tím, že anotace v datasetu ARCADE byly původně určeny pro detekci stenóz, nikoliv pro jejich segmentaci. Tento rozdíl v zaměření anotací může vést k nižší přesnosti při pokusu o segmentaci. Vlastní implementace využívala kombinaci předzpracování pomocí metody CLAHE a bílé top-hat transformace. Tento přístup přispěl k zlepšení výsledků segmentace stenóz, což ukazuje

dosažené Dice skóre. Na segmentaci koronárních tepen však předzpracování nemělo výrazný pozitivní vliv. To naznačuje, že na části datasetu Syntax nemá kombinace CLAHE a bílé top-hat transformace velký vliv a pro tuto část datasetu stačí použít originální vstupní snímky.

Na základě získaných výsledků a provedené analýzy lze formulovat několik praktických doporučení pro další výzkum i klinickou praxi.

Zlepšení kvality anotací: Výsledky segmentace stenóz ukazují, že přesnost modelů je výrazně ovlivněna kvalitou a charakterem anotací v trénovacím datasetu. Pro dosažení lepších výsledků by bylo vhodné vytvořit či rozšířit dataset s přesnějšími a podrobnějšími anotacemi stenotických oblastí, které budou určeny přímo pro segmentaci, nikoliv pouze pro detekci. Zároveň by bylo přínosné zařadit více obrazů obsahujících katétr, které se často vyskytovaly zejména ve validační a testovací sadě, protože modely tyto obrazy s katétry chybně identifikovaly jako součást cévního řečiště.

Využití datové augmentace: Jak ukázaly výsledky vítězného modelu v segmentaci stenotických oblastí, datová augmentace výrazně přispívá k vyšší robustnosti a přesnosti segmentačních modelů. Doporučuje se proto systematicky aplikovat různé techniky augmentace (např. rotace, změna kontrastu, přidání šumu), které mohou modelu pomoci lépe se generalizovat na nové případy.

Kombinace více modelů: Hybridní přístupy, které kombinují detekční a segmentační modely (například nejprve detekce stenózy a následná segmentace), mohou dosahovat lepších výsledků než samostatné modely. Do budoucna by bylo vhodné tyto přístupy dále zkoumat, optimalizovat a vyhodnocovat jejich přínos na různých typech dat.

Optimalizace předzpracování dle cílové úlohy: Výsledky ukazují, že předzpracování obrazu (např. CLAHE a bílá top-hat transformace) má různý vliv na segmentaci tepen a stenóz. Zatímco u stenóz tato forma předzpracování vedla ke zlepšení výsledků, u segmentace cévního řečiště nepřinesla očekávané zlepšení. Doporučuje se proto volit metody předzpracování individuálně podle konkrétní úlohy a typu segmentovaných struktur. Dále by bylo vhodné otestovat více variant předzpracování a případně optimalizovat jejich kombinace pro dosažení lepších výsledků.

Uvedená doporučení vycházejí z výsledků a poznatků získaných v rámci této diplomové práce.

Závěr

Tato diplomová práce se zaměřuje na návrh, implementaci a vyhodnocení segmentačních modelů pro segmentaci tepen a stenóz v kontrastních rentgenových angiografických snímcích (XCA) s využitím datasetu ARCADE. Byly zkoumány dvě architektury modelů, konkrétně U-Net a DeepLabV3+ s enkodérem ResNet-18. Oba modely byly testovány ve dvou variantách, tedy s předzpracováním vstupních dat a bez předzpracování. Použité předzpracování zahrnovalo kombinaci metody CLAHE a bílé top-hat transformace. Na základě toho byly definovány čtyři hlavní konfigurace modelů: U-Net bez předzpracování, U-Net s předzpracováním, DeepLabV3+ bez předzpracování a DeepLabV3+ s předzpracováním.

Výsledky experimentů ukazují, že model DeepLabV3+ dosahoval na části Syntax vyššího Dice skóre než modely U-Net. Nejlepší konfigurace (DeepLabV3+ bez předzpracování) dosáhla Dice skóre 81,0 % na validační sadě a průměrného Dice skóre 74,9 % na testovací sadě. Varianta s předzpracováním (DeepLabV3+ s předzpracováním) vykazovala srovnatelný výkon, konkrétně 80,2 % na validační a 74,7 % na testovací sadě. U segmentace stenóz byly výsledky všech modelů výrazně nižší, což lze přičíst jak náročnosti této úlohy, tak omezené kvalitě dostupných anotací. Nejlepšího výsledku dosáhl model DeepLabV3+ s předzpracováním s Dice skóre 46,9 % na validační sadě a 30,2 % na testovací sadě.

Statistická analýza vlivu hyperparametrů potvrdila, že klíčovým faktorem pro optimalizaci modelu DeepLabV3+ bez předzpracování je míra L2 regularizace (*weight decay*), zatímco po aplikaci předzpracování se stává důležitější velikost trénovacího batch (*batch size*). Pro modely U-Net, ať už s předzpracováním, nebo bez něj, byl nejdůležitějším hyperparametrem rovněž *weight decay*. Hodnota *learning rate* měla ve většině experimentů menší vliv, avšak její nevhodné nastavení mohlo vést k nestabilnímu trénování. Výsledky rovněž ukázaly, že předzpracování vstupních dat zvyšuje stabilitu a schopnost modelu generalizovat při segmentaci stenóz, zatímco u segmentace hlavního cévního řečiště (Syntax) tento přínos nebyl tak zásadní.

Do budoucna doporučuji zaměřit se na rozšíření trénovací množiny o snímky obsahující různé typy artefaktů a stenóz. V řadě případů se totiž ve validační a testovací sadě nacházely cizí objekty (např. katétry či jiné struktury), které modely chybně vyhodnotily jako součást cévního řečiště.

Závěrem lze konstatovat, že moderní segmentační modely hlubokého učení, zejména DeepLabV3+, představují efektivní nástroj pro analýzu angiografických snímků a mohou výrazně přispět ke zvýšení přesnosti i rychlosti diagnostiky koronárních onemocnění.

Literatura

- [1] AKIBA, T.; SANO, S.; YANASE, T.; aj.: Optuna. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019-07-25: s. 2623–2631, doi:10.1145/3292500.3330701.
- [2] ASKIN, L.; TANRIVERDI, O.: The Clinical Value of Syntax Scores in Predicting Coronary Artery Disease Outcomes. *Cardiovascular Innovations and Applications*, ročník 6, č. 4, 2022, ISSN 2009-8618, doi:10.15212/CVIA.2022.0002.
- [3] BAI, X.; ZHOU, F.; XUE, B.: Image enhancement using multi scale image features extracted by top-hat transform. *Optics & Laser Technology*, ročník 44, č. 2, 2012: s. 328–336, ISSN 00303992, doi:10.1016/j.optlastec.2011.07.009.
- [4] BERTELS, J.; EELBODE, T.; BERMAN, M.; aj.: Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory & Practice. *arXiv preprint arXiv:1911.01685*, 2019, doi:10.48550/arXiv.1911.01685.
- [5] BILAL, M.; MARTINHO, D.; SIM, R.; aj.: Multivessel coronary artery segmentation and stenosis localisation using ensemble learning. *arXiv preprint arXiv:2310.17954*, 2023, doi:10.48550/arXiv.2310.17954.
- [6] CHEN, L.-C.; PAPANDREOU, G.; KOKKINOS, I.; aj.: DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 40, č. 4, 2018: s. 834–848, doi:10.1109/TPAMI.2017.2699184.
- [7] CHEN, L.-C.; ZHU, Y.; PAPANDREOU, G.; aj.: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. *Computer Vision – ECCV 2018*, 2018: s. 833–851, doi:10.1007/978-3-030-01234-2_49.
- [8] FALCON, W.: THE PYTORCH LIGHTNING TEAM. *PyTorch Lightning (Version 1.4)*, 2019, doi:10.5281/zenodo.3530844.
- [9] GAO, Y.; AI, D.; WANG, Y.; aj.: Spatio-Temporal correspondence attention network for vessel segmentation in X-ray coronary angiography. *Biomedical Signal Processing and Control*, ročník 99, 2025, ISSN 17468094, doi:10.1016/j.bspc.2024.106792.

- [10] GAO, Z.; WANG, L.; SOROUSHMEHR, R.; aj.: Vessel segmentation for X-ray coronary angiography using ensemble methods with deep learning and filter-based features. *BMC Medical Imaging*, ročník 22, č. 1, 2022, ISSN 1471-2342, doi:10.1186/s12880-022-00734-4.
- [11] HAN, T.; AI, D.; WANG, Y.; aj.: Recursive Centerline- and Direction-Aware Joint Learning Network with Ensemble Strategy for Vessel Segmentation in X-ray Angiography Images. *Computer Methods and Programs in Biomedicine*, ročník 220, 2022, ISSN 01692607, doi:10.1016/j.cmpb.2022.106787.
- [12] HAO, D.; DING, S.; QIU, L.; aj.: Sequential vessel segmentation via deep channel attention network. *Neural Networks*, ročník 128, 2020: s. 172–187, ISSN 08936080, doi:10.1016/j.neunet.2020.05.005.
- [13] HARA, H.; SHIOMI, H.; KLAVEREN, D. V.; aj.: External Validation of the SYNTAX Score II 2020. *Journal of the American College of Cardiology*, ročník 78, č. 12, 2021: s. 1227–1238, ISSN 07351097, doi:10.1016/j.jacc.2021.07.027.
- [14] HECKBERT, P. S.: *Graphics gems 4*. Boston [etc.]: AP Professional, cop. 1994, ISBN 0-12-336156-7.
- [15] HU, L.; NAIR, V. N.; SUDJANTO, A.; aj.: Interpretable Machine Learning Based on Functional ANOVA Framework. *Applied Stochastic Models in Business and Industry*, ročník 41, č. 1, 2025, ISSN 1524-1904, doi:10.1002/asmb.2916.
- [16] ISLAM, M. M.; RIFAT, H. R.; SHADID, M. S. B.; aj.: Explainable Machine Learning for Efficient Diabetes Prediction Using Hyperparameter Tuning, SHAP Analysis, Partial Dependency, and LIME. *Engineering Reports*, ročník 7, č. 1, 2025, ISSN 2577-8196, doi:10.1002/eng2.13080.
- [17] IYER, K.; NAJARIAN, C. P.; FATTAH, A. A.; aj.: AngioNet. *Scientific Reports*, ročník 11, č. 1, 2021, ISSN 2045-2322, doi:10.1038/s41598-021-97355-8.
- [18] KINGMA, D. P.: Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014, doi:10.48550/arxiv.1412.6980.
- [19] KOONSANIT, K.; THONGVIGITMANEE, S.; PONGNAPANG, N.; aj.: Image enhancement on digital x-ray images using N-CLAHE. *2017 10th Biomedical Engineering International Conference (BMEICON)*, 2017: s. 1–4, doi: 10.1109/BMEICON.2017.8229130.

- [20] KU, J.; LEE, Y.-H.; SHIN, J.; aj.: Mpseg: Multi-phase strategy for coronary artery segmentation. *arXiv preprint arXiv:2311.10306*, 2023, doi:10.48550/arXiv.2311.10306.
- [21] LALINIA, M.; SAHAFI, A.: Coronary Vessel Segmentation in X-ray Angiography Images Using Edge-Based Tracking Method. *Sensing and Imaging*, ročník 25, č. 1, 2024, ISSN 1557-2072, doi:10.1007/s11220-024-00481-6.
- [22] LEE, I. K.; SHIN, J.; LEE, Y.-H.; aj.: Ssass: Semi-supervised approach for stenosis segmentation. *arXiv preprint arXiv:2311.10281*, 2023, doi:10.48550/arxiv.2311.10281.
- [23] LIN, H.; LIU, T.; Katsaggelos, A.; aj.: StenUNet: Automatic Stenosis Detection from X-ray Coronary Angiography. *arXiv preprint arXiv:2310.14961*, 2023, doi:10.48550/arXiv.2310.14961.
- [24] LIU, T.; LIN, H.; KATSAGGELOS, A.; aj.: YOLO-Angio: An Algorithm for Coronary Anatomy Segmentation. *arXiv e-prints*, oct 2023: arXiv:2310.15898, doi:10.48550/arXiv.2310.15898.
- [25] MAIER-HEIN, L.; MENZE, B.; aj.: Metrics reloaded: Pitfalls and recommendations for image analysis validation. *arXiv. org*, ročník 21, č. 2206.01653, 2022, doi:10.48550/arXiv.2206.01653.
- [26] MEMON, M. M.; HASHMANI, M. A.; JUNEJO, A. Z.; aj.: Unified DeepLabV3+ for Semi-Dark Image Semantic Segmentation. *SENSORS*, ročník 22, č. 14, 2022, ISSN 1424-8220, doi:10.3390/s22145312.
- [27] OU, X.; YAN, P.; ZHANG, Y.; aj.: Moving Object Detection Method via ResNet-18 with Encoder–Decoder Structure in Complex Scenes. *IEEE ACCESS*, ročník 7, 2019: s. 108152–108160, doi:10.1109/ACCESS.2019.2931922.
- [28] PAJANKAR, A.: Data Visualization with NumPy and Matplotlib. *Practical Python Data Visualization*, 2021: s. 57–79, doi:10.1007/978-1-4842-6455-3_5.
- [29] PASZKE, A.; GROSS, S.; MASSA, F.; aj.: PyTorch: An Imperative Style, High-Performance Deep Learning Library. In *Advances in Neural Information Processing Systems 32*, Curran Associates, Inc., 2019, s. 8024–8035, doi:10.48550/arXiv.1912.01703.
- [30] PIRILLO, A.; NORATA, G. D.: The burden of hypercholesterolemia and ischemic heart disease in an ageing world. *Pharmacological Research*, ročník 193, 2023, ISSN 10436618, doi:10.1016/j.phrs.2023.106814.

- [31] POPOV, M.; AMANTURDIEVA, A.; ZHAKSYLYK, N.; aj.: Dataset for Automatic Region-based Coronary Artery Disease Diagnostics Using X-Ray Angiography Images. *Scientific Data*, ročník 11, č. 1, 2024, ISSN 2052-4463, doi: 10.1038/s41597-023-02871-z.
- [32] QIN, B.; JIN, M.; DING, S.: Extracting heterogeneous vessels in X-ray coronary angiography via machine learning. In *Cardiovascular and Coronary Artery Imaging*, Elsevier, 2022, ISBN 9780128227060, s. 89–127, doi:10.1016/B978-0-12-822706-0.00008-1.
- [33] RONNEBERGER, O.; FISCHER, P.; BROX, T.: U-Net. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 2015: s. 234–241, doi:10.1007/978-3-319-24574-4_28.
- [34] SMITH, L. N.: Cyclical Learning Rates for Training Neural Networks. *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2017: s. 464–472, doi:10.1109/WACV.2017.58.
- [35] TAO, X.; DANG, H.; ZHOU, X.; aj.: A Lightweight Network for Accurate Coronary Artery Segmentation Using X-Ray Angiograms. *Frontiers in Public Health*, ročník 10, 2022-5-25, ISSN 2296-2565, doi:10.3389/fpubh.2022.892418.
- [36] VIJAYAKUMAR, A.; VAIRAVASUNDARAM, S.: YOLO-based Object Detection Models. *Multimedia Tools and Applications*, ročník 83, č. 35, 2024: s. 83535–83574, ISSN 1573-7721, doi:10.1007/s11042-024-18872-y.
- [37] XIA, S.; ZHU, H.; LIU, X.; aj.: Vessel Segmentation of X-Ray Coronary Angiographic Image Sequence. *IEEE Transactions on Biomedical Engineering*, ročník 67, č. 5, 2020: s. 1338–1348, ISSN 0018-9294, doi:10.1109/TBME.2019.2936460.
- [38] XIE, Z.; XU, Z.; ZHANG, J.; aj.: On the Overlooked Pitfalls of Weight Decay and How to Mitigate Them: A Gradient-Norm Perspective. In *Advances in Neural Information Processing Systems*, ročník 36, 2023, s. 1208–1228, doi:10.48550/arXiv.2011.11152.
- [39] YANG, S.; KWEON, J.; ROH, J.-H.; aj.: Deep learning segmentation of major vessels in X-ray coronary angiography. *Scientific Reports*, ročník 9, č. 1, 2019, ISSN 2045-2322, doi:10.1038/s41598-019-53254-7.
- [40] YANG, Y.: ARCADE 2023 Coronary Artery Splitting Competition Champion Scheme Sharing - Zhihu. 2023.
Dostupné z: <https://zhuanlan.zhihu.com/p/679501082>

- [41] ZHANG, H.; GAO, Z.; ZHANG, D.; aj.: Progressive Perception Learning for Main Coronary Segmentation in X-Ray Angiography. *IEEE Transactions on Medical Imaging*, ročník 42, č. 3, 2023: s. 864–879, ISSN 0278-0062, doi:10.1109/TMI.2022.3219126.

Seznam symbolů a zkratek

APN	Angiographic Processing Network
ARCADE	Angiographic Dataset for the Segmentation of Coronary Arteries
ASPP	Atrous Spatial Pyramid Pooling
BB	Bounding Box
BCE	Binary Cross Entropy
CAB	Channel Attention Block
CAD	Coronary Artery Disease
CLAHE	Contrast Limited Adaptive Histogram Equalization
DICOM	Digital Imaging and Communications in Medicine
fANOVA	Functional Analysis of Variance
FFO	Feature Fusion Operation Block
LAD	Left Anterior Descending Artery
LCX	Left Circumflex Artery
PPV	Positive Predictive Value
RCA	Right Coronary Artery
ReLU	Rectified Linear Unit
SHAP	Shapley Additive Explanations
XCA	X-Ray Coronary Angiography

Seznam příloh

A	Optimalizace na datasetu ARCADE, část Syntax	68
A.1	Výsledky modelu DeepLabV3+	68
A.2	Výsledky modelu U-Net	70
B	Optimalizace na datasetu ARCADE, část Stenosis	72
B.1	Výsledky modelu DeepLabV3+	72
B.2	Výsledky modelu U-Net	74

A Optimalizace na datasetu ARCADE, část Syntax

A.1 Výsledky modelu DeepLabV3+

Tab. A.1: Výsledky modelu DeepLabv3+ bez předzpracování dat pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	30	0.0002911	0.7639
2	0.0001575	6	2.0511e-05	0.8097
3	1.3067e-05	26	0.0001593	0.8056
4	0.0002607	2	0.0008706	0.7682
5	0.0004623	6	2.3102e-05	0.7923
6	2.3271e-05	10	0.0001121	0.7921
7	7.3095e-05	10	0.0001674	0.7902
8	1.9010e-05	10	5.4041e-05	0.7864
9	8.1685e-05	26	2.5081e-05	0.7877
10	0.0001068	18	1.2385e-05	0.7871
11	0.0008076	18	1.0354e-05	0.7858
12	1.0467e-05	22	0.0003507	0.7963
13	0.0002539	30	4.673e-05	0.7929
14	0.0001848	22	6.5230e-05	0.7932
15	3.7300e-05	2	0.0001854	0.7926
16	1.0966e-05	14	0.0007366	0.7901
17	0.0001189	26	3.3691e-05	0.7874
18	4.4008e-05	14	9.8193e-05	0.7876
19	0.0001800	6	0.0003848	0.7954
20	2.8463e-05	22	8.8322e-05	0.7911

Tab. A.2: Výsledky modelu DeepLabv3+ s předzpracováním dat pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	30	0.000291	0.7334
2	0.0001575	6	2.0511e-05	0.7931
3	1.3067e-05	26	0.000159	0.8010
4	0.0002607	2	0.0008706	0.7607
5	0.0004623	6	2.3102e-05	0.7940
6	2.3271e-05	10	0.0001121	0.7979
7	7.3095e-05	10	0.0001674	0.7987
8	1.9010e-05	10	5.4041e-05	0.7942
9	8.1685e-05	26	2.5081e-05	0.7975
10	0.0001068	18	1.2385e-05	0.7961
11	1.0992e-05	22	0.0005093	0.7902
12	3.8058e-05	18	0.0001557	0.7911
13	0.0007005	14	0.0002485	0.7915
14	1.0626e-05	30	6.2341e-05	0.7955
15	3.3473e-05	14	0.0001930	0.8025
16	2.7938e-05	22	6.7337e-05	0.7987
17	1.5858e-05	22	0.0003828	0.7949
18	4.0490e-05	14	0.0005542	0.7943
19	3.1250e-05	26	0.0001081	0.7933
20	1.5294e-05	26	0.0002098	0.7889

A.2 Výsledky modelu U-Net

Tab. A.3: Výsledky modelu U-Net bez předzpracování pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	6	0.0002911	0.7794
2	0.0001575	2	2.0511e-05	0.7765
3	1.3067e-05	6	0.0001593	0.7674
4	0.0002607	2	0.0008706	0.6794
5	0.0004623	2	2.3102e-05	0.7739
6	2.3271e-05	2	0.0001121	0.7819
7	7.3095e-05	2	0.0001674	0.7638
8	1.9010e-05	2	5.4041e-05	0.7755
9	8.1685e-05	6	2.5081e-05	0.7818
10	0.0001068	4	1.2385e-05	0.7875
11	0.0007767	4	1.0354e-05	0.7585
12	3.1568e-05	4	7.4330e-05	0.7804
13	3.2426e-05	4	0.0003692	0.7760
14	0.0001759	4	4.6241e-05	0.7904
15	0.0001821	4	4.8421e-05	0.7759
16	0.0003231	4	1.0711e-05	0.7850
17	0.0001332	4	3.7365e-05	0.7798
18	4.9135e-05	6	1.6269e-05	0.7860
19	0.0008224	4	3.4900e-05	0.7412
20	9.9206e-05	6	8.1863e-05	0.7826

Tab. A.4: Výsledky modelu U-Net s předzpracováním pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	6	0.0002911	0.7723
2	0.0001575	2	2.0511e-05	0.7601
3	1.3067e-05	6	0.0001593	0.7597
4	0.0002607	2	0.0008706	0.7405
5	0.0004623	2	2.3102e-05	0.7772
6	2.3271e-05	2	0.0001121	0.7716
7	7.3095e-05	2	0.0001674	0.7772
8	1.9010e-05	2	5.4041e-05	0.7721
9	8.1685e-05	6	2.5081e-05	0.7769
10	0.0001068	4	1.2385e-05	0.7789
11	0.0007767	4	1.0354e-05	0.7822
12	0.0007321	4	1.1952e-05	0.7745
13	0.0009046	4	1.1711e-05	0.7740
14	0.0002663	4	4.9967e-05	0.7639
15	3.7300e-05	4	4.6802e-05	0.7752
16	0.0001673	4	1.0195e-05	0.7798
17	0.0003963	4	3.6167e-05	0.7709
18	0.0001396	6	0.0005542	0.7521
19	0.0005359	4	1.0144e-05	0.7801
20	0.0005616	6	8.1863e-05	0.7170

B Optimalizace na datasetu ARCADE, část Stenosis

B.1 Výsledky modelu DeepLabV3+

Tab. B.1: Výsledky modelu DeepLabV3+ bez předzpracování pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	30	0.000291	0.2269
2	0.0001575	6	2.0511e-05	0.4158
3	1.3067e-05	26	0.000159	0.4087
4	0.0002607	2	0.0008706	0.0921
5	0.0004623	6	2.3102e-05	0.4666
6	2.3271e-05	10	0.0001121	0.4641
7	7.3095e-05	10	0.0001674	0.4675
8	1.9010e-05	10	5.4041e-05	0.4533
9	8.1685e-05	26	2.5081e-05	0.4517
10	0.0001068	18	1.2385e-05	0.4573
11	0.0007767	18	0.0004174	0.4697
12	0.0007321	18	0.0004759	0.4337
13	4.0892e-05	14	0.0002620	0.4541
14	0.0009808	22	6.5036e-05	0.4585
15	0.0002421	14	0.0009183	0.4552
16	0.0003734	10	0.0004360	0.4703
17	0.0004415	22	0.0004690	0.4335
18	0.0005164	2	0.0005087	0.3699
19	0.0002668	14	0.0003019	0.4451
20	0.0009818	22	0.0007091	0.4232

Tab. B.2: Výsledky modelu DeepLabV3+ s předzpracováním dat pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	30	0.000291	0.0891
2	0.0001575	6	2.0511e-05	0.4028
3	1.3067e-05	26	0.000159	0.4129
4	0.0002607	2	0.0008706	0.4206
5	0.0004623	6	2.3102e-05	0.4608
6	2.3271e-05	10	0.0001121	0.4361
7	7.3095e-05	10	0.0001674	0.4464
8	1.9010e-05	10	5.4041e-05	0.4304
9	8.1685e-05	26	2.5081e-05	0.4471
10	0.0001068	18	1.2385e-05	0.4512
11	0.0009036	18	4.1799e-05	0.4604
12	0.0008040	18	4.7002e-05	0.4555
13	0.0009438	14	4.6729e-05	0.4547
14	0.0004618	22	1.0422e-05	0.4691
15	0.0003950	22	1.0799e-05	0.4579
16	0.0004240	2	2.0304e-05	0.4122
17	0.0002400	22	1.3184e-05	0.4542
18	0.0005230	14	2.6410e-05	0.4513
19	0.0002198	6	1.0146e-05	0.4381
20	4.0446e-05	30	7.3403e-05	0.4209

B.2 Výsledky modelu U-Net

Tab. B.3: Výsledky modelu U-Net bez předzpracování pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	6	0.000291	0.4154
2	0.0001575	2	2.0511e-05	0.4080
3	1.3067e-05	6	0.000159	0.0187
4	0.0002607	2	0.0008706	0.0000
5	0.0004623	2	2.3102e-05	0.4321
6	2.3271e-05	2	0.0001121	0.4326
7	7.3095e-05	2	0.0001674	0.4546
8	1.9010e-05	2	5.4041e-05	0.4116
9	8.1685e-05	6	2.5081e-05	0.4456
10	0.0001068	4	1.2385e-05	0.4314
11	0.0007767	4	0.0004174	0.0031
12	4.9397e-05	6	4.8723e-05	0.3645
13	5.6196e-05	4	4.6729e-05	0.4376
14	0.0001938	6	0.0001835	0.0761
15	3.4932e-05	4	7.8828e-05	0.4257
16	9.2600e-05	4	1.0425e-05	0.4595
17	0.0001202	4	0.0004395	0.2959
18	0.0003817	2	0.0002258	0.0000
19	2.8178e-05	4	1.0273e-05	0.4230
20	8.4768e-05	4	0.0001071	0.3936

Tab. B.4: Výsledky modelu U-Net s předzpracováním pro různé kombinace hyperparametrů.

Pokus	Learning Rate	Batch Size	Weight Decay	Validační F1 skóre
1	5.6115e-05	6	0.000291	0.4270
2	0.0001575	2	2.0511e-05	0.4196
3	1.3067e-05	6	0.000159	0.3711
4	0.0002607	2	0.0008706	0.0000
5	0.0004623	2	2.3102e-05	0.4172
6	2.3271e-05	2	0.0001121	0.4370
7	7.3095e-05	2	0.0001674	0.4022
8	1.9010e-05	2	5.4041e-05	0.4223
9	8.1685e-05	6	2.5081e-05	0.4486
10	0.0001068	4	1.2385e-05	0.4708
11	0.0007767	4	1.0354e-05	0.4442
12	4.9397e-05	4	3.7029e-05	0.4517
13	3.7744e-05	4	4.6729e-05	0.4648
14	2.9508e-05	4	1.0280e-05	0.4296
15	0.0001513	4	7.1729e-05	0.4287
16	4.3308e-05	4	1.5051e-05	0.4563
17	0.0001332	4	4.2608e-05	0.4659
18	0.0001462	6	3.5397e-05	0.4772
19	0.0002826	6	1.6313e-05	0.4012
20	0.0002654	6	2.7131e-05	0.4345