



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV TELEKOMUNIKACÍ

DEPARTMENT OF TELECOMMUNICATIONS

FOREZNÍ METODA ROZPOZNÁVÁNÍ ORIGINALITY UMĚleckých děl s pomocí multispektrální analýzy

FORENSIC METHOD FOR RECOGNIZING THE AUTHENTICITY OF ARTWORKS USING MULTISPECTRAL
ANALYSIS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. David Lánský

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Radim Burget, Ph.D.

BRNO 2024



Diplomová práce

magisterský navazující studijní program **Informační bezpečnost**

Ústav telekomunikací

Student: Bc. David Lánský

ID: 253165

Ročník: 2

Akademický rok: 2023/24

NÁZEV TÉMATU:

Forenzní metoda rozpoznávání originality uměleckých děl s pomocí multispektrální analýzy

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se s problematikou rozpoznávání originality uměleckých děl s využitím multispektrální analýzy a s konvolučními neuronovými sítěmi. Proveďte rešerši ohledně současného stavu vědy a techniky v této oblasti, včetně výzkumu v oblasti radiografie a jejího využití v detekci falzifikátů. Vytvořte trénovací a testovací datovou množinu snímků různých uměleckých děl v oblasti malířství, které budou využívat vizuální a rentgenové spektrum. Navrhněte několik metod založených na různých architekturách neuronové sítě, s pomocí kterých bude možné analyzovat a rozpoznávat originalitu uměleckých děl s vysokou přesností. Tyto metody by měly být schopny identifikovat a zdůraznit potenciální nepravidelnosti nebo nekonzistence v uměleckých dílech, které by mohly naznačovat falzifikát. Navržené metody vhodným způsobem srovnajte a dosažené výsledky diskutujte s cílem vytvořit spolehlivý nástroj pro forenzní analýzu uměleckých děl.

DOPORUČENÁ LITERATURA:

podle pokynů vedoucího práce

Termín zadání: 5.2.2024

Termín odevzdání: 21.5.2024

Vedoucí práce: doc. Ing. Radim Burget, Ph.D.

doc. Ing. Jan Hajný, 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

Odhalování falzifikátů je zásadní pro ochranu trhu s uměním a zachování autentičnosti uměleckých děl. Tato práce se věnuje detekci falzifikátů, a to s využitím konvolučních neuronových sítí (CNN). Hlavním cílem bylo vyvinout pokročilé metody, které jsou schopné identifikovat anomálie v malbách za účelem potvrzení pravosti či prokázání falzifikátu. V rámci tohoto výzkumu byly aplikovány architektury U-net a techniky binární sémantické segmentace, které výrazně zpřesňují relevanci detekovaných oblastí.

Hlavním přínosem práce je 112 modelů čtyř různých architektur U-net a U-net++, které metodou binární sémantické segmentace efektivně zdůrazňují anomálie. Modely byly na trénovány na souboru obrazů s jejich synteticky vytvořenými rentgenovými snímky a uměle generovanými anomáliemi. Modely jsou tímto způsobem schopné detektovat olovnaté skvrny, hřebíky, vrstvy skrytých maleb, defekty, zatímco zároveň dokáží ignorovat nevýznamné prvky, jako jsou rámy obrazů a přeexponované rentgenové snímky.

Testování modelů probíhalo ve dvou fázích. V první fázi byly hodnoceny pomocí metriky IoU na množině 400 synteticky generovaných dat, kde v nejlepších případech dosahovaly až 83,5 % IoU. V druhé fázi byly hodnoceny subjektivním způsobem na obrazech se skutečnými rentgeny a přirozenými anomáliemi.

Tento přístup kombinuje tradiční rentgenové techniky s moderním počítačovým viděním, čímž odhaluje odchylky, které by mohly být přehlédnutý při standardní vizuální inspekci. Tímto přínosným spojením technologií práce otevírá nové možnosti pro ochranu uměleckých sbírek a poskytuje solidní základ pro další výzkum v oblasti detekce falzifikátů uměleckých děl pomocí umělé inteligence.

KLÍČOVÁ SLOVA

falzifikát, konvoluční neuronové sítě, u-net architektura, sémantická segmentace, rentgenové snímky, detekce anomálií

ABSTRACT

Detecting forgeries is crucial for protecting the art market and preserving the authenticity of artworks. This thesis focuses on forgery detection using convolutional neural networks (CNNs). The main goal was to develop advanced methods capable of identifying anomalies, and thus potential forgeries, in images with their X-ray photographs. During this research, U-net architectures and binary semantic segmentation techniques were applied, enabling successful anomaly detection.

The main contribution of this work is 112 models of four different U-net and U-net++ architectures, which effectively highlight anomalies through the method of binary semantic segmentation. The models were trained on a set of images with their synthetically created X-ray images and artificially generated anomalies. In this way, the models can detect lead spots, nails, layers of hidden paintings, and other defects, while also being able to ignore insignificant elements, such as picture frames and overexposed X-ray images.

The testing of the models occurred in two phases. In the first phase, they were evaluated using the IoU metric on a set of 400 synthetically generated data, where in the best cases, they achieved up to 83.5 % IoU. In the second phase, they were evaluated subjectively on images with real X-rays and natural anomalies.

This approach combines traditional X-ray techniques with modern computer vision, revealing deviations that might be overlooked during standard visual inspection. By bridging these technologies, this work opens new possibilities for the protection of art collections and provides a solid foundation for further research in the field of art forgery detection using artificial intelligence.

KEYWORDS

falsification, convolutional neural networks, u-net architecture, semantic segmentation, X-ray images, anomaly detection

LÁNSKÝ, David. *Forenzní metoda rozpoznávání originality uměleckých děl s pomocí multispektrální analýzy*. Semestrální práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, 2024. Vedoucí práce: doc. Ing. Radim Burget, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Bc. David Lánský

VUT ID autora: 253165

Typ práce: Semestrální práce

Akademický rok: 2023/24

Téma závěrečné práce: Forenzní metoda rozpoznávání originality uměleckých děl s pomocí multispektrální analýzy

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 semestrální práce panu doc. Ing. Radimu Burgetovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	11
1 Detekce falzifikátů v současnosti	12
1.1 Metody detekce falzifikátů	12
1.1.1 Provenience a stylistické metody	12
1.1.2 Mikroskopie a chemická analýza	12
1.1.3 Infračervená reflektografie a radiografie	13
1.2 Rozpoznání falzifikátů pomocí neuronových sítí	13
2 Neuronové sítě	14
2.1 Úvod do neuronových sítí	14
2.2 Typy neuronových sítí	15
2.3 Ztrátové a aktivační funkce	16
2.3.1 Ztrátové funkce	16
2.3.2 Aktivační funkce	16
2.4 Generalizace	17
2.5 Konvoluční neuronové sítě	17
2.5.1 Motivace	17
2.5.2 Základní principy konvolučních neuronových sítí (CNN)	18
2.5.3 Architektura a vrstvy v CNN	18
2.5.4 Konvoluční filtry	18
2.6 Sémantická segmentace	19
2.7 U-net architektura	20
2.8 Rozšířená Architektura U-Net: U-Net++	21
2.8.1 Popis architektury U-Net++	21
2.8.2 Výhody a nevýhody U-Net++	22
2.8.3 Interpolace vs. transponovaná konvoluce	22
3 Trénovací data	23
3.1 Augmentace dat	23
3.2 Syntetická data	24
4 Testovací data a hodnocení modelů	25
4.1 Metriky hodnocení	25
4.1.1 Přesnost	25
4.1.2 Průnik přes sjednocení (IoU)	25
4.1.3 Další metriky	25

5 Praktická část	26
5.1 Návrh a idea řešení	26
5.1.1 Přehledové schéma	27
5.2 Knihovny	28
5.3 Tvorba trénovací množiny	28
5.3.1 Základní množina obrazů a její augmentace	28
5.3.2 Syntetické rentgenové snímky	29
5.3.3 Syntetické anomálie	29
5.3.4 Způsob vkládání syntetických anomálií	31
5.4 Koncepční důkaz: návrh neuronové sítě	33
5.5 Zhodnocení koncepčního návrhu	34
5.6 Způsob vyhodnocení modelů	34
5.7 Porovnání modelů a shrnutí výsledků	35
6 Návrh a vývoj dalších architektur	36
6.1 Hodnocení a výběr vhodných architektur	37
6.2 Optimalizace vybraných modelů	39
6.3 Vývoj grafického uživatelského rozhraní pro zobrazení segmentačních map	41
7 Hodnocení modelů na skutečných datech	42
7.1 Problematika ruční anotace	42
7.2 Problematika (ne)univerzálnosti	42
7.3 Příklady konkrétních výsledků	42
7.3.1 Příklad 1 - zanedbání rámu obrazu	43
7.3.2 Příklad 2 - rozsáhlá detekce anomálií	45
7.3.3 Příklad 3 - detekce hřebíků	47
7.3.4 Příklad 4 - identifikace olovnatých skvrn	49
7.3.5 Příklad 5 - dlouhá expozice	51
8 Diskuze	53
Závěr	54
Literatura	55
Seznam symbolů a zkratek	58

Seznam obrázků

2.1	Neuronová síť	14
2.2	Redukce dimenze	17
2.3	Konvoluční operace	19
2.4	U-net architektura	20
2.5	U-net++ architektura	21
3.1	Demonstrace augmentace dat	23
3.2	Demonstrace syntetických dat	24
5.1	Přehledové schéma	27
5.2	Porovnání rentgenu s jeho syntetickou verzí	29
5.3	Příklady generovaných anomalií	30
5.4	Přehled jednotlivých anomalií	31
5.5	Metody vkládání anomalií	32
5.6	Masky anomalií	32
5.7	Vstupní data	33
5.8	Originální obraz s rentgenovým snímkem	34
5.9	Segmentační mapy Modelů 1 a 2	35
6.1	Graf IoU skóre modelů	38
6.2	Tabulka srovnání modelů	39
6.3	Graf IoU skóre optimalizovaných modelů	40
6.4	GUI pro zobrazování segmentačních map	41
7.1	Příklad 1	43
7.2	Detail 1 příkladu 1	44
7.3	Detail 2 příkladu 1	44
7.4	Příklad 2	45
7.5	Detail 1 příkladu 2	46
7.6	Detail 2 příkladu 2	46
7.7	Příklad 3	47
7.8	Detail 1 příkladu 3	48
7.9	Detail 2 příkladu 3	48
7.10	Příklad 4	49
7.11	Detail 1 příkladu 4	50
7.12	Detail 2 příkladu 4	50
7.13	Příklad 5	51
7.14	Detail 1 příkladu 5	52
7.15	Detail 2 příkladu 5	52
7.16	Detail 3 příkladu 5	52

Úvod

Detekce falzifikátů uměleckých děl, zejména obrazů, je klíčovým problémem pro zachování integrity a hodnoty uměleckých sbírek. V současné době se odhaduje, že se na českém trhu může vyskytovat až 50 % falzifikátů. Tato práce je zaměřena na využití pokročilých metod umělé inteligence, konkrétně konvolučních neuronových sítí (CNN), pro detekci těchto falzifikátů. CNN, které se již osvědčily ve zpracování obrazových dat v mnoha aplikacích, od rozpoznávání objektů až po generování obrazu, nabízí nové možnosti i v oblasti analýzy uměleckých děl. Speciálně je využita architektura U-net a její pokročilejší verze U-net++. V práci jsou propojeny tradiční metody zkoumání uměleckých děl, jako jsou rentgenové snímky, s moderními přístupy počítačového vidění.

Hlavním přínosem práce je vytvoření souboru metod, které jsou schopny detektovat nepřesnosti na obrazech, které by mohly naznačovat možnou falzifikaci. Jsou přitom kombinovány vizuální (RGB) snímky obrazů s jejich rentgenovými skeny (RTG), což poskytuje hlubší pohled na vrstvy pod vizuálně viditelnou vrstvou a také částečně chemické složení užitých materiálů (např. rtuť, olovo atp.). Prostřednictvím těchto metod je možné detektovat hřebíky, olovnaté skvrny, defekty a zároveň opomíjet rámy obrazů. Tento přístup umožňuje zjistit odchylky přehlédnutelné pouhým okem a odhalit vrstvy, které mohou napovídat o pravosti obrazu.

Pro tvorbu této práce byly využity pokročilé softwarové nástroje pro kontrolu gramatiky, stylizace textu či návrhu částí kódů, jako jsou MS Word a OpenAI ChatGPT. Veškeré takto získané výstupy byly manuálně validovány, uzpůsobeny pro potřeby této práce a prohlašuji, že za výslednou podobu a spolehlivost přebírám veškerou zodpovědnost.

Práce je rozdělena do několika hlavních částí. Teoretická část se věnuje současným metodám detekce falzifikátů a poskytuje základní přehled o neuronových sítích a jejich aplikacích v počítačovém vidění. Praktická část této práce se primárně soustředí na vývoj a realizaci navrhovaného řešení, zahrnující vytvoření trénovacích datových sad a následný popis konstrukce U-net neuronové sítě. Práce bude zakončena zhodnocením efektivity modelů jak na syntetických datech, tak zejména na reálných.

V práci jsou zahrnuty ilustrační obrázky, které byly vytvořeny s využitím grafického nástroje draw.io.

1 Detekce falzifikátů v současnosti

Odhalování falzifikátů je zásadní pro ochranu trhu s uměním a zachování autentičnosti uměleckých děl. Falzifikáty představují nejen ekonomické riziko pro investory a sběratele, ale především narušují důvěru v umělecký trh. Padělatelé využívají sofistikovaných metod k vytváření děl, která jsou těžko rozpoznatelná od originálů, a tím se neoprávněně obohacují na úkor původních tvůrců a historického odkazu. Záměrné vytváření a prodej padělků uměleckých děl představuje seriózní porušení umělecké integrity, a je tedy považováno za formu uměleckého zločinu. Aby bylo možné efektivně chránit autentičnost a historickou hodnotu uměleckých děl, je nezbytné neustále rozvíjet a využívat pokročilé forenzní techniky pro jejich detekci.

V současné době se odhaduje, že se na českém trhu může vyskytovat až 50 % falzifikátů [3].

1.1 Metody detekce falzifikátů

Pro efektivní detekci falzifikátů obrazů je nezbytný multidisciplinární přístup, zahrnující spolupráci mezi historiky umění a vědci. Tato spolupráce umožňuje komplexní zkoumání uměleckých děl z různých perspektiv a využívá širokou škálu technik a metod [2]. Zde jsou uvedeny některé z nich:

1.1.1 Provenience a stylistické metody

Studium provenience zahrnuje výzkum historie a původu uměleckých děl. Tato metoda se soustředí na sledování historie vlastnictví, výstav a publikací spojených s dílem, což může poskytnout klíčové informace o jeho pravosti. Důkladné prozkoumání provenience může odhalit historické nesrovnanosti nebo neobvyklé přesuny díla, které mohou naznačovat falzifikát [1]. Historik umění navíc zkoumá specifika použitých barev a styl malby, které jsou charakteristické pro jednotlivé umělce. Toto zkoumání pomáhá posoudit, zda malířské techniky a materiály odpovídají deklarovanému období vzniku díla a známému stylu autora [4].

1.1.2 Mikroskopie a chemická analýza

Pro hloubkovou analýzu a detekci falzifikátů v uměleckých dílech se klíčově uplatňuje kombinace mikroskopie a chemických analytických technik. Ačkoliv se jedná o technologicky nejvyspělejší metody detekce, nesou s sebou významné nevýhody, jako je invazivita a vysoká cena [5]. Mikroskopie poskytuje možnost detailní vizuální inspekce na mikroskopické úrovni, což umožňuje odhalit specifika v malířských

technikách a použitých materiálech. K tomu rovněž přispívá chemická analýza, která zahrnuje metody jako Ramanova spektroskopie, Fourierova transformační infračervená spektroskopie nebo masová spektrometrie. Tyto techniky dohromady poskytují komplexní informace o chemickém složení pigmentů a dalších materiálů. Detailní molekulární analýza je zvláště účinná při identifikaci složení materiálů na nejzákladnější úrovni, což je zásadní pro odhalování anachronismů a indikaci moderních falzifikátů [21] [22].

V kontextu detekce falzifikátů uměleckých děl je termín anachronismus používán k popisu nesrovnalostí nebo nepravdivostí, které vznikají, když se v díle objevují materiály nebo techniky, které nebyly v době vzniku díla k dispozici nebo běžně používány.

1.1.3 Infračervená reflektografie a radiografie

Infračervená reflektografie a rentgenové snímky jsou klíčovými technikami v procesu zkoumání vrstev uměleckých děl pod povrchem. Zatímco infračervená reflektografie umožňuje detekci skrytých kresek nebo předchozích vrstev malby, rentgenové snímky poskytují ještě hlubší pohled do struktury obrazu. Rentgenová zobrazovací technika odhaluje nejen kompoziční vrstvy a použité materiály, ale také může odhalit neviditelné opravy a úpravy. Společné použití obou těchto metod přináší komplexní přehled o technikách a postupech použitých umělcem, což je nezbytné pro ověření historického kontextu [2].

1.2 Rozpoznání falzifikátů pomocí neuronových sítí

Konvoluční neuronové sítě (CNN) jsou vhodné pro detekci falzifikátů uměleckých děl díky efektivnímu zpracování velkého množství obrazových dat a schopnosti identifikovat jemné vzory a anomálie, které mohou lidskému oku uniknout. Na rozdíl od tradičních metod nabízejí automatizovanou a objektivní analýzu. CNN se rovněž mohou naučit rozpoznávat specifické umělecké styly nebo charakteristiky, což je užitečné při detekci falzifikátů napodobujících určité umělecké techniky.

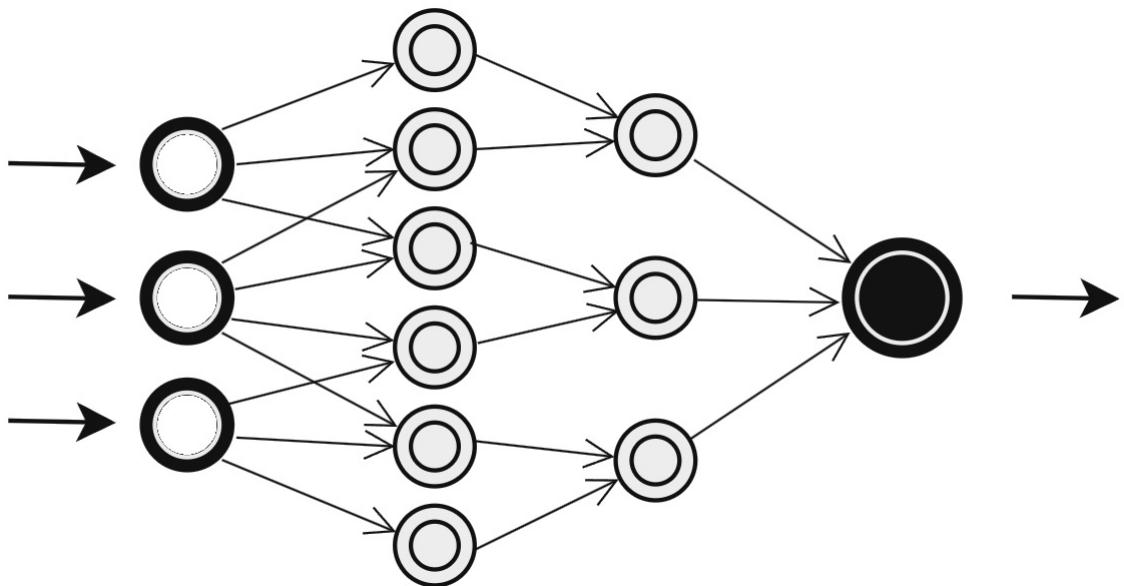
Například v práci "This AI Can Spot an Art Forgery" [24] se povedlo odlišit pomocí CNN obrazy autora od jeho napodobitelů. Tréninkový proces byl postaven na souboru dat obsahující fotografie originálních děl nizozemského malíře Rembrandta a dále fotografie děl, které Rembrandtova díla imituje nebo jsou stylizována podobným způsobem. Tento přístup umožnil neuronové síti naučit se rozlišovat mezi autentickými díly Rembrandta a díly jiných umělců nebo padělatelů, kteří se snažili napodobit jeho styl. Značnou nevýhodou je však to, že tyto sítě jsou trénované specificky na rozpoznávání děl pouze jednoho umělce.

2 Neuronové sítě

2.1 Úvod do neuronových sítí

Neuronové sítě představují základní kámen současného výzkumu a aplikací v oblasti umělé inteligence a strojového učení. Tyto sítě, které napodobují strukturu a funkci lidského mozku, se skládají z jednotek zvaných neurony. Tyto neurony jsou propojeny a komunikují mezi sebou, a vytvářejí složité sítě, které mohou zpracovávat a analyzovat informace.

Jedním z klíčových poznatků o neuronových sítích je jejich schopnost fungovat jako univerzální approximační funkce. Tato vlastnost znamená, že teoreticky mohou modelovat jakoukoli matematickou funkci, což je zásadní pro jejich schopnost učit se a přizpůsobovat se rozmanitým datům a úlohám. Tato schopnost neuronových sítí být flexibilními a všestrannými nástroji pro modelování složitých vzorců a vztahů je klíčová pro jejich rozšířené použití v různých aplikacích, od rozpoznávání obrazů a jazyka až po předpovídání a analýzu dat [6][7].



Obr. 2.1: Neuronová síť

Základy neuronových sítí byly položeny již v polovině 20. století, avšak plný potenciál těchto sítí nebyl realizován až do rozvoje vícevrstvých architektur v pozdějších dekádách. Tyto vícevrstvé sítě, často označované jako hluboké učení (deep learning), byly klíčové pro překonání omezení původních, jednovrstvých sítí, které byly v zásadě lineárními modely. Vícevrstvé struktury umožnily neuronovým sítím

zpracovávat data na mnohem hlubší a složitější úrovni, což vedlo k průlomům v mnoha oblastech umělé inteligence.

Přechod k hlubokým neuronovým sítím přinesl značný pokrok v oblastech jako je počítačové vidění a přirozený jazyk, kde složitost a variabilita dat vyžadují schopnost modelovat vysoce nelineární vztahy. Tento vývoj byl podpořen rovněž dostupností většího množství dat a zvýšením výpočetního výkonu, což umožnilo efektivní trénování těchto rozsáhlých a složitých modelů [8].

V současné době jsou neuronové sítě nejen základem mnoha pokročilých systémů umělé inteligence, ale také předmětem intenzivního výzkumu. Studují se nové architektury, metody trénování a optimalizace, aby bylo možné dále rozšířit jejich schopnosti a efektivitu.

2.2 Typy neuronových sítí

Existuje několik typů neuronových sítí, kde každý typ má své specifické vlastnosti a uplatnění. Tato diverzita umožňuje výběr ideálního modelu pro specifické úlohy a problémy.

Konvoluční neuronové sítě (CNN) patří mezi nejrozšířenější typy v oblasti zpracování obrazu. Díky konvolučním vrstvám, které dokážou extrahovat zásadní vizuální rysy z obrazů, jsou CNN ideální pro rozpoznávání objektů, detekci tváří a dokonce i pro medicínské zobrazování. Schopnost těchto sítí efektivně zpracovávat a interpretovat obrazové informace je založena na jejich schopnosti zachytávat prostorové vztahy v datech. Vedle CNN existují i další typy sítí. **Rekurentní neuronové sítě** (RNN) excelují v zpracování sekvenčních dat, jako je text nebo časové řady, díky své schopnosti zachovávat kontext [8]. **Generativní adversariální sítě** (GAN) jsou významné svou schopností generovat realistické obrázky a videa pomocí interakce mezi generátorem a diskriminátorem [10]. **Sítě hlubokého zpětnovazebního učení** (deep reinforcement learning) se osvědčují při řešení komplexních úloh v měnících se prostředích. Kombinují hluboké učení se zpětnovazebním učením pro nalezení (sub)optimálního řešení problému [9].

Dalším typem neuronových sítí jsou **Transformery**, poprvé představené v roce 2017 výzkumníky z Google Brain ve studii "Attention Is All You Need" [11], představující průlom v oblasti neuronových sítí. Jejich zásadním prvkem je mechanismus sebepozornosti (self-attention), který umožňuje modelu efektivně zpracovávat a porozumět dlouhým sekvenčním závislostem v datech. Tato schopnost je zvláště důležitá v aplikacích, jako je překlad jazyků a generování textu, kde je potřeba zachytit složité vztahy a kontext. Modely založené na transformerové architektuře, jako jsou GPT (Generative Pretrained Transformer) od OpenAI a Gemini od Google, mají významný dopad na zpracování přirozeného jazyka.

2.3 Ztrátové a aktivační funkce

Klíčové role v architektuře a funkčnosti neuronových sítí zastávají ztrátové a aktivační funkce, které jsou nezbytné pro účinné učení.

2.3.1 Ztrátové funkce

Ztrátová funkce poskytuje kvantitativní hodnocení toho, jak dobře síť předpovídá výsledek. Je to metrika, která umožňuje posoudit, jak daleko je výstup sítě od skutečné hodnoty. Tato hodnota ztráty je pak použita optimalizačními algoritmy, jako jsou SGD (stochastic gradient descent), Adam nebo jiné, které upravují váhy v síti. Procesem iterativního úpravy vah na základě výpočtů ztrátové funkce dochází k optimalizaci sítě a postupnému vylepšování její přesnosti během trénování.

V oblasti hlubokého zpětnovazebního učení jsou běžně používány ztrátové funkce jako MSE (mean squared error) a MAE (mean average error), které jsou vhodné pro úlohy s nepřetržitými hodnotami. Při práci s obrazovými daty, hlavně s využitím konvolučních neuronových sítí (CNN), se preferuje křížová entropie (cross-entropy) pro klasifikaci do více kategorií a binární křížová entropie pro binární klasifikaci [12][13].

2.3.2 Aktivační funkce

Aktivační funkce, jako jsou ReLU (rectified linear unit) nebo sigmoid, mají zásadní význam pro schopnost neuronových sítí provádět nelineární zpracování dat. Tyto funkce určují, zda a jak intenzivně se neuron "aktivuje", což ovlivňuje, jak je signál přenášen dále v síti. Aktivační funkce dodávají síti schopnost učit se a modelovat komplexní vzorce a vztahy v datech, které by byly s lineárními funkcemi nedosažitelné.

ReLU je populární díky své jednoduchosti a efektivitě, protože umožňuje rychlejší konvergenci trénování a redukuje pravděpodobnost gradientního zániku, což je častý problém při trénování hlubokých sítí. Sigmoidová funkce, která výstup normalizuje do rozmezí mezi 0 a 1, je užitečná v binární klasifikaci, ale může být náchylná k saturaci a zpomalování gradientního sestupu při použití ve skrytých vrstvách [14].

$$\text{ReLU}(x) := \max(0, x) \quad (2.1)$$

2.4 Generalizace

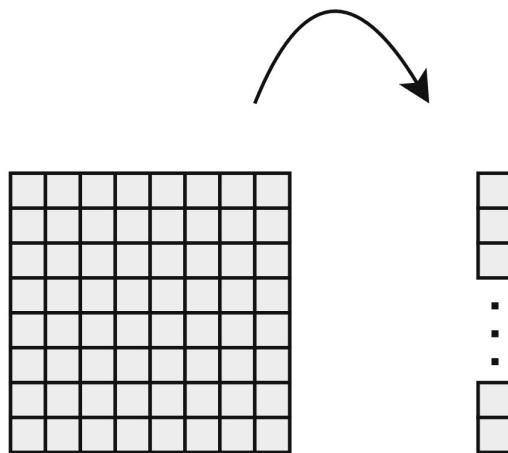
Generalizací se rozumí vlastnost, která umožňuje modelům efektivně aplikovat získané znalosti na nová, neznámá data. Tento aspekt je zásadní, neboť cílem není pouze dosáhnout vysoké přesnosti na trénovacích datech, ale také zajistit, aby model byl schopen správně fungovat i v reálných, nepředvídatelných situacích. Model, který se dobře generalizuje, je schopen identifikovat a využít obecné vzorce a pravidla získaná z trénovacích dat a aplikovat je na nové případy. Naopak, nedostatečná generalizace vede k přeúčení modelu, kdy se model příliš specializuje na trénovací data a selhává při zpracování odlišných datových sad [16].

Jedním z řešení při nedostatečné generalizaci modelu je využít tzv. dropout. Dropout je technika, která během trénování náhodně „vypíná“ část neuronů v síti, což pomáhá zabránit jejímu přeúčení na trénovací data. Tím se zvyšuje schopnost sítě generalizovat, protože se síť učí spoléhat na širší spektrum vlastností v datech, místo aby se specializovala pouze na specifické vzorce [15].

2.5 Konvoluční neuronové sítě

2.5.1 Motivace

Při zpracování dvoudimenzionálních dat, jako jsou obrázky, neuronovými sítěmi dochází k problému, že data jsou předkládána v podobě vektoru. Tím se ztrácí důležité informace o prostorových vztazích mezi jednotlivými řádky a sloupců obrázku.



Obr. 2.2: Redukce dimenze

Konvoluční neuronové sítě (CNN) přinášejí řešení tohoto problému prostřednictvím své specifické architektury, která je navržena právě pro zachování a zpracování prostorových informací (nejen) v obrazových datech.

2.5.2 Základní principy konvolučních neuronových sítí (CNN)

Základem CNN jsou konvoluční vrstvy, které aplikují filtr (kernel) na vstupní data, čímž extrahují důležité rysy, jako jsou hrany, tvary nebo textury. Tato schopnost učinit abstraktní reprezentaci vizuálních dat je klíčová pro úspěšné aplikace v počítačovém vidění, včetně rozpoznávání objektů, klasifikace obrázků a dokonce i v pokročilých aplikacích jako je analýza lékařských snímků. CNN se odlišují od tradičních neuronových sítí tím, že zachovávají prostorovou hierarchii vstupních dat, což je zásadní pro zpracování obrazů [17].

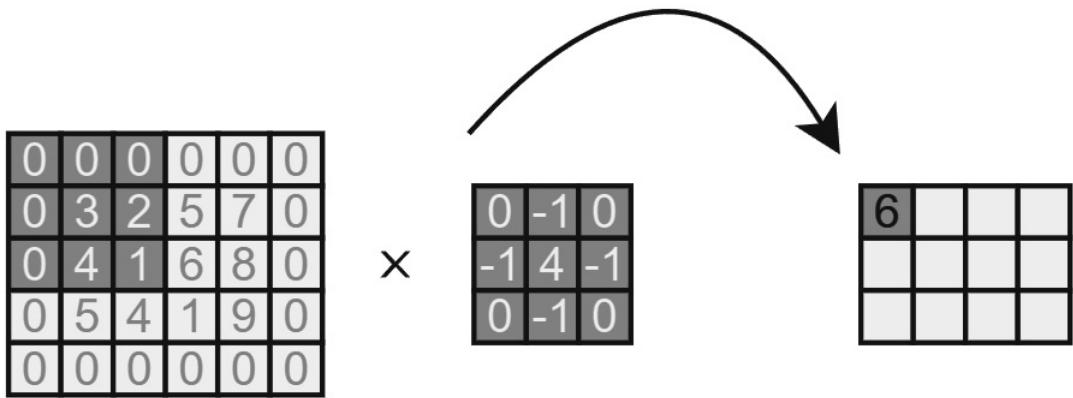
2.5.3 Architektura a vrstvy v CNN

Typická architektura CNN zahrnuje několik typů vrstev: konvoluční vrstvy, pooling vrstvy a plně propojené vrstvy. Konvoluční vrstvy slouží k identifikaci různých charakteristik obrazu (například hran nebo vzorů) pomocí speciálních operací zvaných konvoluce, které vytvářejí takzvané příznakové mapy (feature maps). Tyto vrstvy používají filtry různých velikostí (čtvercové matice, např. 3x3 nebo 5x5) a často aplikují metodu vyplnění (padding) k zajištění zachování důležitých informací na okrajích obrazu. Poolingové vrstvy následně zjednoduší tyto příznakové mapy, snižují jejich velikost a současně zachovávají klíčové informace, čímž zvyšují efektivitu zpracování. Tento proces využívá metody jako max pooling a average pooling. Nakonec plně propojené vrstvy fungují podobně jako v klasických neuronových sítích – přijímají zpracované informace z předchozích vrstev a provádějí finální klasifikaci nebo generují jiný typ výstupu [17].

2.5.4 Konvoluční filtry

Konvoluční filtry jsou malé čtvercové matice naplněné váhami. Tyto váhy se aplikují na lokální oblasti vstupního obrazu pro identifikaci specifických vzorů nebo vlastností, jako jsou hrany, textury a jiné vizuální prvky. Běžně používané velikosti zahrnují 3x3, 5x5, a 7x7. Menší filtry jsou efektivní pro zachycení detailnějších vzorů, zatímco větší filtry mohou detekovat širší a obecnější vlastnosti. Konvoluční jádra se posouvají přes celý vstupní obraz, přičemž na každém kroku provádějí elementární násobení a součet mezi hodnotami jádra a odpovídajícími hodnotami vstupu. Tento proces vytváří nové hodnoty pro příznakové mapy, přičemž zachovává prostorovou lokalizaci detekovaných vzorů v původním obrazu [17].

Na Obr 2.3 je zobrazen příklad tvorby příznakové mapy pomocí filtru 3x3 v prvním kroku. Zároveň je zde demonstrovaná metoda vyplnění vstupních dat pomocí nul.



Obr. 2.3: Ukázka konvoluční operace

2.6 Sémantická segmentace

Sémantická segmentace je proces rozdělení obrazu na několik segmentů s cílem porozumět a interpretovat obsah obrazu na pixelové úrovni. Každý pixel v obrazu je přiřazen k určité kategorii, což umožňuje přesnou lokalizaci a identifikaci různých objektů a oblastí v obrazu. Tato technika je zásadní pro počítačové vidění, protože poskytuje detailní a hluboké porozumění vizuálním datům [19].

Příkladem využití jsou autonomní vozidla, kde sémantická segmentace umožňuje vozidlům rozpoznat a rozlišit různé prvky v dopravním prostředí, jako jsou vozovky, chodci, jiná vozidla a dopravní značení [20].

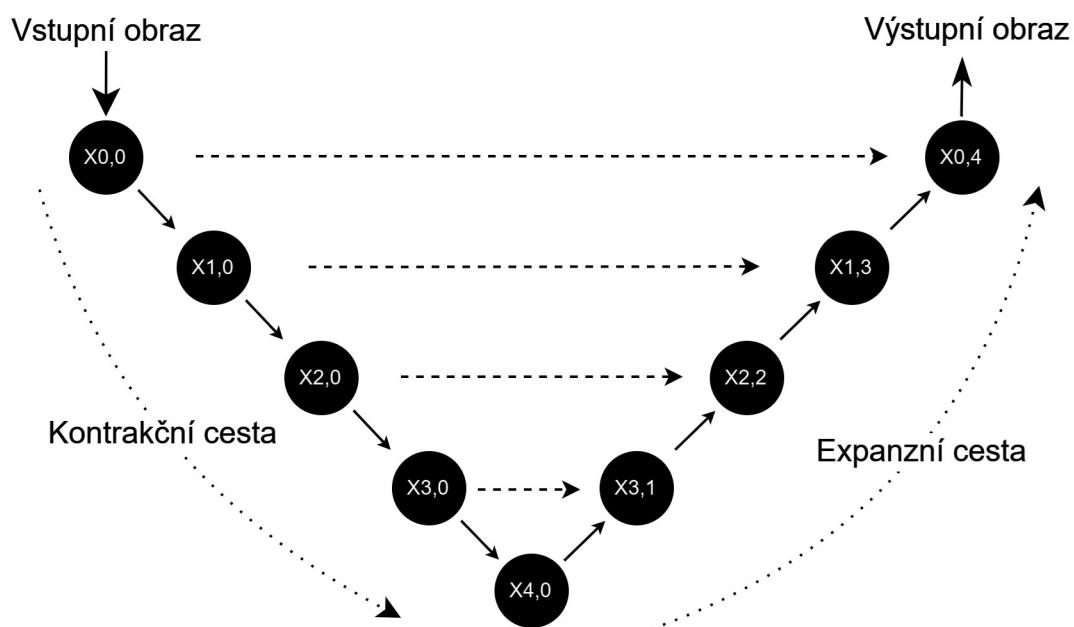
Binární sémantická segmentace je speciální forma sémantické segmentace, kde je cílem rozlišit pouze mezi dvěma kategoriemi - typicky objektem a jeho pozadím. Tato metoda je zvláště užitečná v situacích, kde je potřeba jednoduše oddělit cílový objekt od ostatních prvků v obrazu. Příkladem může být medicínské zobrazování, kde binární segmentace může pomoci identifikovat specifické anatomické struktury nebo patologické změny.

Výsledkem sémantické segmentace jsou tzv. masky (také známé jako segmentační mapy), které mají stejné rozměry jako původní vstupní data. V těchto maskách každý pixel představuje určitou kategorii objektu, přičemž v binární sémantické segmentaci se používají hodnoty 0 a 1 pro označení nepřítomnosti resp. přítomnosti objektu [18][19].

2.7 U-net architektura

U-net architektura je speciální typ konvoluční neuronové sítě, která byla původně navržena pro účely lékařského zobrazování, zejména pro segmentaci obrazů. Tato architektura je známá svou efektivností ve zpracování obrázků s vysokou přesností, i přes relativně malé množství dostupných trénovacích dat. Klíčovým prvkem U-net architektury je její symetrická struktura, která se skládá z kontrakční (downsampling) cesty a expanzní (upsampling) cesty, vytvářející tvar písmene "U". Kontrakční cesta zachytává kontextové informace obrázku, zatímco expanzní cesta umožňuje přesnou lokalizaci a segmentaci objektů v obraze.

Díky své schopnosti přesné lokalizace a zachování detailů v obrazech je U-net ideální pro úkoly, kde je potřeba rozlišit mezi různými objekty na obrázku nebo přesně segmentovat specifické části [33].



Obr. 2.4: U-net architektura

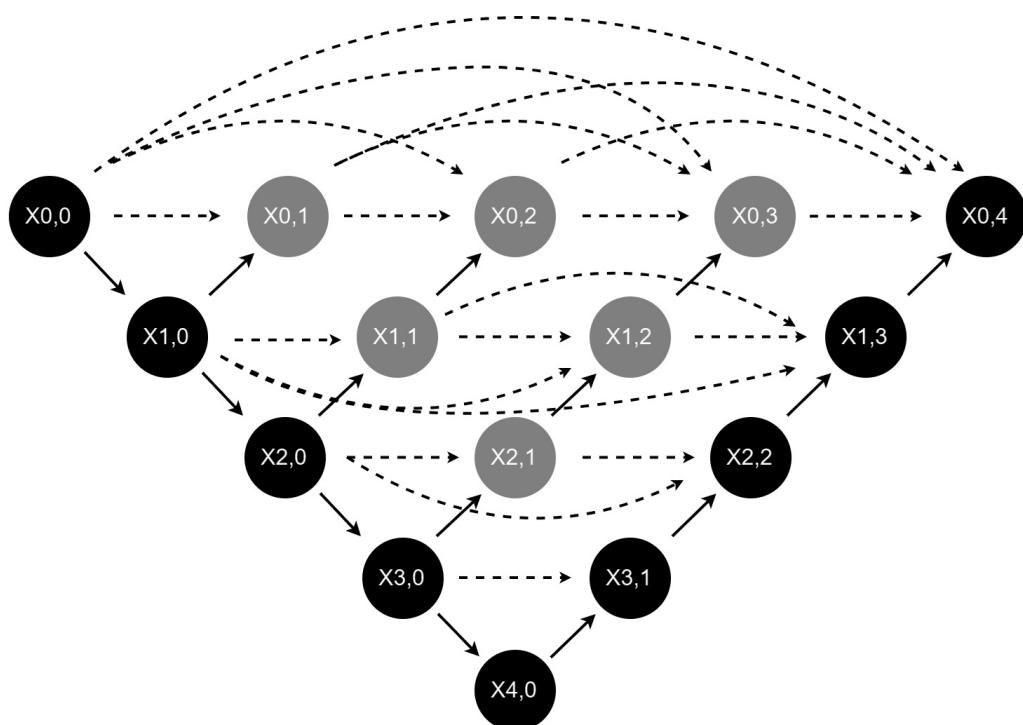
Vstupní obraz projde kontrakční cestou architektury U-Net, kde konvoluční vrstvy pomocí filtrů postupně extrahují rysy. Proces zmenšení obrazu pomocí pooling operací je znázorněn sestupnými šipkami. Zvětšování (upsampling) na expanzní cestě, zobrazený vzestupnými šipkami, pak obraz zvětšuje, přičemž čárkované šipky reprezentují propojení přeskoku (skip connections), které propojují kontrakční a expanzní cestu a zachovávají tak prostorový kontext. Tyto propojení přeskoku jsou zásadní pro přesnou rekonstrukci segmentační masky s původními rozmiery obrazu [23].

2.8 Rozšířená Architektura U-Net: U-Net++

Rozšířená architektura U-Net, známá jako U-Net++, představuje významné vylepšení tradiční architektury U-Net, které přináší pokročilé funkce pro přesnější segmentaci obrazu v různých aplikacích, včetně medicínského zobrazování a detekce objektů. U-Net++ byl navržen s cílem zlepšit propojení mezi vrstvami a optimalizovat tok informací ve struktuře sítě, což umožňuje dosáhnout lepších výsledků i v případech, kde standardní U-Net selhává.

2.8.1 Popis architektury U-Net++

U-Net++ se odlišuje od svého předchůdce především zavedením tzv. nested skip pathways, což jsou vnořené spojovací cesty mezi vrstvami. Tyto cesty propojují vrstvy nejen vertikálně, ale i horizontálně a vytváří tak mnohorstevnou síť spojení. Zmíněné vnořené spojovací cesty a struktura vnitřních bloků jsou detailně znázorněny na obrázku 2.5 [28].



Obr. 2.5: U-net++ architektura

2.8.2 Výhody a nevýhody U-Net++

V důsledku mnohonásobných spojovacích cest může U-Net++ zachovat více kontextových informací, což je zásadní pro přesnou lokalizaci a segmentaci objektů ve složitých obrazech. Zároveň díky vylepšeným propojením přeskoků dochází k efektivnějšímu tréninku modelu, protože gradienty mohou snadněji proudit skrz celou síť, což redukuje problém mizejících gradientů a umožňuje modelu lépe se učit i z velmi hlubokých datových struktur.

Za nevýhody U-Net++ lze pak považovat zvýšenou složitost modelu, což vyžaduje více výpočetních zdrojů. S tím se pojí i časově náročnější trénink oproti původní architektuře U-Net.

2.8.3 Interpolace vs. transponovaná konvoluce

V architektuře U-Net a jejích variantách se často používají dvě hlavní techniky pro zvětšování (upsampling) obrazových dat: transponovaná konvoluce (dekonvoluce) a interpolace. Obě tyto metody mají své výhody a specifické vlastnosti, které ovlivňují výkon a přesnost segmentačních modelů [32].

Transponovaná konvoluce

Transponovaná konvoluce, známá také jako dekonvoluce, používá váhy podobné těm v běžné konvoluční vrstvě, ale operace probíhá v opačném směru. To znamená, že místo redukce rozměrů obrazu se rozměry zvětšují. Tyto váhy se trénují společně s ostatními parametry sítě, což umožňuje modelu lépe se přizpůsobit specifickým rysům dat. Tato metoda umožňuje, aby síť při upsamplingu zachovala jemné detaily z předchozích vrstev, protože konvoluční operace se provádí přímo na datech. To vede k vyšší přesnosti při rekonstrukci obrazu. Je výpočetně náročnější než jednoduché upsamplingové techniky jako interpolace, což může zvýšit čas trénování a nároky na paměť.

Interpolace

Interpolace je jednodušší metoda, která zvyšuje rozměry obrazu pomocí technik, jako jsou bilineární interpolace nebo interpolace nejbližšího souseda. Tento proces je rychlý a efektivní, ale nepřidává nové informace do obrazu. Interpolace je méně náročná na výpočetní výkon a paměť než transponovaná konvoluce, což může být výhodné při práci s velmi velkými datovými sadami nebo omezenými hardwarovými zdroji. Tato metoda může ztratit některé jemné detaily, protože interpolace není schopna přidat nové informace do dat. Výsledný obraz může být méně přesný ve srovnání s použitím transponované konvoluce.

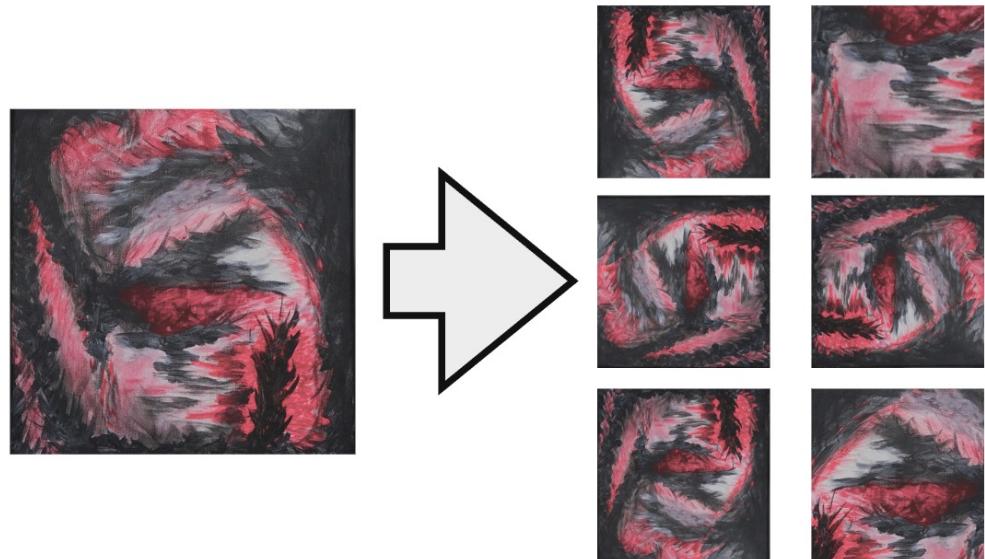
3 Trénovací data

Význam a vliv trénovacích dat na účinnost a efektivitu neuronových sítí je neměřitelný. Kvalita a rozmanitost trénovacích dat jsou rozhodujícími faktory pro schopnost modelu se učit a správně generalizovat. Vytvoření reprezentativní a rozsáhlé trénovací datové sady je základním kamenem úspěchu v jakémkoli strojovém učení, přičemž sběr a anotace takové datové sady může být časově i finančně náročný proces. Přesto je zásadní zajistit, aby datová sada zahrnovala širokou škálu příkladů a scénářů, aby model mohl efektivně fungovat v různorodých situacích. Při nedostatku trénovacích dat je proto často nevyhnutelné využít různých technik obohacení dat, jako je augmentace dat a případně použití syntetických dat [25].

3.1 Augmentace dat

Augmentace dat (data augmentation) je technika umělého rozšíření trénovacích dat, která se ukázala být velmi užitečná v případech omezené dostupnosti dat. Tato metoda zahrnuje aplikaci různých transformací, jako je rotace, změna měřítka, oříznutí, změna perspektivy nebo úprava osvětlení a barev na existujících obrazových nebo jiných typech dat.

Na Obr. 3.1 je uveden příklad augmentace dat demonstrováný na obrazu autora této práce.



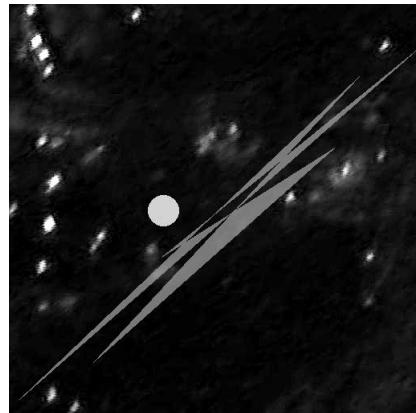
Obr. 3.1: Demontrace augmentace dat

Díky těmto transformacím je možné z jednoho vzorku vytvořit několik odlišných variant, čímž se zvyšuje rozmanitost a množství trénovacích dat bez nutnosti sběru nových dat. Je důležité, aby transformace byly realistické a odpovídaly možným variacím, se kterými se model může setkat v reálném světě. Některé typy augmentace dat jsou v závislosti na případu užití v podstatě redundantní. Například při trénování neuronové sítě na rozpoznávání pouze tvarů v obrázku, nehraje barva tak zásadní roli, jako třeba rotace [25].

3.2 Syntetická data

Vytváření syntetických dat je další metodou, jak zvýšit množství a rozmanitost trénovacích dat. Tato data jsou generována algoritmicky, a to buď na základě existujících vzorů dat, nebo úplně od základu. Použití syntetických dat je obzvláště užitečné v situacích, kde sběr reálných dat je obtížný nebo nemožný. Syntetická data mohou napodobovat různé scénáře a situace, které pomáhají modelu se naučit a adaptovat se na různorodé podmínky. Nicméně je důležité dbát na to, aby syntetická data byla relevantní a věrohodná, aby nedošlo k zkreslení výsledků učení modelu. Problém, který s sebou nesou syntetická data, bývá typicky snížená schopnost generalizace [26][27].

Na druhou stranu, jestliže model trénovaný na základě syntetických dat prokazuje pozitivní výsledky i při testech na reálných datech, je to indikátor účinné generalizace. Tento fakt naznačuje, že model se nenaučil rozpoznávat pouze specifika syntetických dat, ale je také schopen uplatnit získané znalosti na rozmanité a odlišné reálné datové sady.



Obr. 3.2: Demonstrace syntetických dat

Na obrázku 3.2 se nachází demonstrace synteticky vytvořeného obrázku v podobě vložení tvarů (kruh, polygon) - převzato z praktické části této práce.

4 Testovací data a hodnocení modelů

Pro ověření účinnosti modelů strojového učení, zejména v úlohách binární segmentace, je nezbytné použít relevantní testovací data a efektivní metriky hodnocení. Testovací data by měla poskytnout realistický základ pro měření schopnosti modelu generalizovat na nová, neviděná data. V binární segmentaci, kde je cílem odlišit pozadí od objektu, je klíčové, aby testovací sada obsahovala dostatečně variabilní příklady, které odrážejí reálné scénáře použití.

4.1 Metriky hodnocení

Pro hodnocení výkonu modelů binární segmentace se běžně používají následující metriky:

4.1.1 Přesnost

Přesnost (accuracy) je základní metrika, která udává poměr správně klasifikovaných pixelů (jak objektů, tak pozadí) k celkovému počtu pixelů v obrazu. Přestože je tato metrika intuitivní a snadno interpretovatelná, může být zavádějící v případech, kdy je rozdelení tříd v datech nevyvážené. Například v situaci, kde je většina obrazu pozadí, může model dosahovat vysoké hodnoty přesnosti, i když je schopnost identifikace objektu nízká [31].

4.1.2 Průnik přes sjednocení (IoU)

IoU, známá také jako Jaccardův index, měří poměr průniku a sjednocení mezi predikovanou a skutečnou segmentací. Tato metrika poskytuje přesnější měření účinnosti segmentace, protože zohledňuje jak chyby falešné pozitivity (objekty označené nesprávně jako pozadí), tak falešné negativity (pozadí označené nesprávně jako objekt). Hodnota IoU nabízí robustnější hodnocení, protože penalizuje jak přehnané, tak nedostatečné segmentace. Zároveň to z ní však činí velmi přísnou metriku [30].

4.1.3 Další metriky

Přesnost (precision) udává, jaká část pixelů identifikovaných jako objekt je skutečně objektem, zatímco Úplnost (recall) udává, jaká část skutečných objektů byla správně identifikována jako objekt. Tyto metriky jsou zvláště užitečné pro hodnocení výkonu v případech, kde je důležitější buď minimalizace falešné pozitivity (precision) nebo maximální detekce objektů (recall). Často jsou používány společně pro vyvážené hodnocení v rámci F1 skóre, které harmonizuje obě tyto metriky [29].

5 Praktická část

5.1 Návrh a idea řešení

V praktické části práce je cílem vytvořit nástroj, který by asistoval vědcům a technikům ve zkoumání pravosti obrazů. Běžně se spoléhají například na chemickou analýzu, která je však invazivní a finančně nákladná a z toho důvodu je nutné zefektivnit proces identifikace oblasti na obrazech, kde je vysoká pravděpodobnost nalezení nesrovonalostí. Klíčovým prvkem je rozpor mezi vizuálním a rentgenovým snímkem obrazu, což poskytuje základ pro identifikaci potenciálně problematických oblastí.

Řešení spočívá ve vývoji CNN pomocí U-net architektury pro sémantickou segmentaci. Cílem je vytvořit model, který zdůrazní nesrovonalosti mezi vizuálním a rentgenovým spektrem obrazu. Pro dosažení tohoto cíle je nejprve nutné vytvořit a připravit trénovací množinu dat zahrnující syntetické anomálie, které se daná síť bude snažit rozpoznávat.

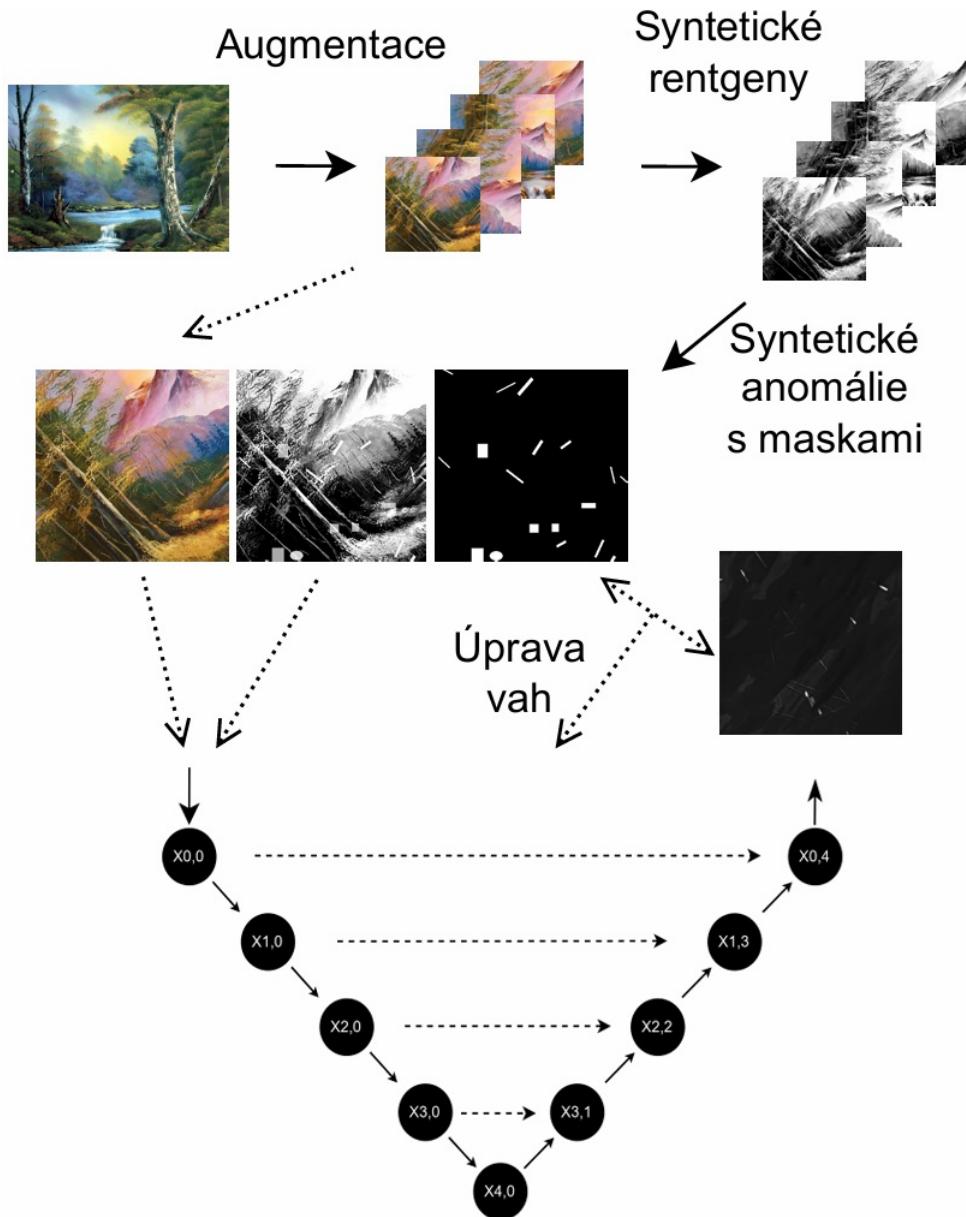
Trénovací množina byla vytvořena stáhnutím 30 fotografií obrazů z internetu. Vzhledem k nedostupnosti rentgenových snímků těchto obrazů byl zvolen přístup syntetických rentgenových snímků, simulovaných pomocí zvýšeného kontrastu a ostrosti. Tato základní sada byla dále rozšířena augmentací, čímž vzniklo více než 18000 různých obrazů.

Jako doplnění trénovací sady bylo vyvinuto 7 metod tvorby syntetických anomalií. Tyto anomálie byly specificky vloženy do syntetických rentgenových snímků a odpovídajících masek. Původní záměr vkládat některé anomálie jak do RGB, tak i do RTG snímků a vynechávat je z masek byl zavržen, jelikož existující rozdíly mezi vizuálními a RTG obrazy již poskytovaly dostatečné pokrytí pro účely trénování.

Model byl následně trénován na vstupu o velikosti 512x512x4 pixelů zahrnující RGB (512x512x3) a RTG (512x512x1) snímky. Trénování modelu bylo zaměřeno na identifikaci a zdůraznění nesrovonalostí mezi oběma spektry. Základním výstupem modelu jsou masky, které vykazují anomálie a mohou poskytovat vědcům a technikům cenné informace pro další analýzu.

Jako finální testovací množina posloužila sada snímků obrazů s příslušnými skutečnými rentgenovými snímkami, která byla poskytnuta vedoucím této práce.

5.1.1 Přehledové schéma



Obr. 5.1: Přehledové schéma

Na obrázku 5.1 je zobrazeno přehledové schéma, které ilustruje jednotlivé kroky popsané v sekci 5.1 Návrh a idea řešení. Konkrétně se jedná o augmentaci základní sady obrázků, tvorbu umělých rentgenových snímků a následné vložení syntetických anomalií a generování příslušných masek. V poslední fázi je znázorněn trénink U-net modelu, který zahrnuje úpravu vah vrstev na základě rozdílu mezi predikovanou segmentační mapou a skutečnou maskou.

5.2 Knihovny

Pro realizaci praktické části této práce byl zvolen programovací jazyk Python 3.10, který je preferován pro jeho kompatibilitu s moderními knihovnami. Klíčovou knihovnou je TensorFlow 2.10, využívanou pro návrh, trénink neuronových sítí. Dále byly použity knihovny PILLOW pro manipulaci s obrazovými daty a NumPy pro práci s multidimenzionálními poli a matematické operace. Celý trénink probíhal lokálně na grafické kartě RTX 3060 s 6GB pamětí ve verzi pro laptop, s využitím technologií CudNN a Cuda toolkit od společnosti NVIDIA.

5.3 Tvorba trénovací množiny

Cílem této kapitoly je vytvoření trénovací množiny. V ideálním případě by byly využity autentické RGB snímky obrazů spolu s odpovídajícími rentgenovými snímky. Vzhledem k nedostatku takových snímků a komplikacím spojeným s jejich získáním bylo nutné vytvořit trénovací sadu prostřednictvím augmentace dat.

Rovněž bylo rozhodnuto nevyužívat již poskytnuté obrazy s jejich rentgeny, jelikož obsahovaly již existující přirozené anomálie, které by bylo velmi obtížné efektivně maskovat. Možnost využití alespoň vizuálních snímků z testovací sady pro trénink bylo zavrhнуто, jelikož tento výběr neodpovídá požadované variabilitě a nereprezentuje dostatečně široké spektrum stylů maleb ani technické aspekty, jako jsou osvětlení a kontrast. V úvodní fázi projektu byla prozkoumána možnost využití existujících datasetů pro trénování CNN, které jsou dostupné online, včetně datasetů obsahujících obrazy. Nicméně bylo zjištěno, že kvalita těchto snímků je nedostatečná, s rozlišením pouhých 256x256 pixelů, což představovalo značné obtíže při vytváření věrohodných syntetických rentgenových snímků. V důsledku těchto omezení byl zvolen přístup vytvoření vlastního datasetu.

5.3.1 Základní množina obrazů a její augmentace

Jako základ pro tuto sadu bylo vybráno 30 fotografií obrazů o různých velikostech stažených z internetu. Tyto obrázky byly následně podrobeny různým metodám augmentace dat, aby se získalo více než 18000 variací každého obrazu velikosti 512x512 pixelů. Augmentace zahrnovala techniky jako ořezávání (cropping), otáčení (rotating), zrcadlení (flipping) a další postupy, které přispěly k vytvoření rozšířenější sady dat. Vzhledem k tomu, že hlavním cílem naší studie je zaměření na rozpoznávání tvarů v obrazových datech, není vhodné použít augmentační techniky, které by modifikovaly barevné složky obrazů.

5.3.2 Syntetické rentgenové snímky

Jako alternativa k rentgenovým snímkům byly použity černobílé verze obrazů, u nichž byl upraven kontrast a ostrost. Pro tyto úpravy byl využit balíček PILLOW, který umožňuje snadnou manipulaci s obrazem. Slouží k tomu funkce Contrast(img, w) a Sharpness(img, q), kde q a w jsou parametry určující intenzitu aplikovaných úprav. Pro kalibraci těchto parametrů byl použit skutečný rentgenový snímek z testovací množiny. Cílem bylo naladit hodnoty q a w tak, aby se černobílá verze obrazu co nejvíce podobala reálnému rentgenu. Nakonec bylo rozhodnuto o nastavení kontrastu na hodnotu 2 a ostrosti na 3.

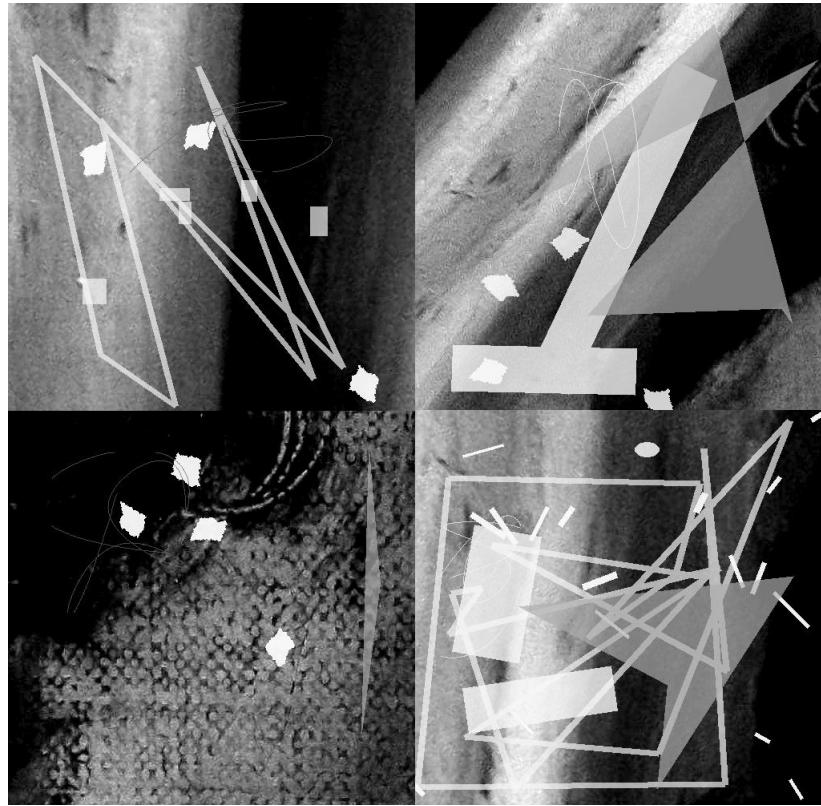


Obr. 5.2: Porovnání skutečného rentgenového snímku s jeho syntetickou verzí

5.3.3 Syntetické anomálie

Anomálií na rentgenovém snímku rozumíme defekt nebo jev na obrazu, který je viditelný pouze na rentgenovém snímku a nikoliv ve vizuálním spektru. Pro jednoduchost v tomto textu jsou uvažovány jako anomálie i přirozené jevy viditelné pouze na rentgenu, jako jsou rámy obrazu, hřebíky nebo skvrny olova.

Bylo navrhнуто 7 metod pro generování syntetických anomálií defektů inspirovaných skutečnými anomáliemi. Anomálie byly vytvořeny pomocí knihoven PILLOW a NumPy, kdy byly náhodně generovány a rozmištovány po obrazu. Mezi anomáliemi byly různé plochy a křivky vyjadřující olovnaté skvrny, rámy obrazů, tahy štětcem, elipsy, hřebíky a jiné defekty, které se mohou vyskytovat na skutečných rentgenových snímcích.



Obr. 5.3: Příklady generovaných anomálií

V této části jsou rozebrány způsoby, jak byly tvořeny anomálie. Na konci této podkapitoly se nachází obrázek (Obr. 5.3) s ukázkou jednotlivých anomálií, které jsou označené číslem odpovídajícím příslušné metodě.

Metoda 1 tvoří anomálie tím způsobem, že nejprve vybere libovolný bod na obrazu, následně zvolí náhodný rádius, ze kterého se pak náhodně vybere druhý bod. Tyto body jsou poté spojeny čarou s libovolnou šířkou (4 až 9 pixelů).

Metoda 2 generuje anomálie tak, že nejprve vybere náhodný střed elipsy na obrazu. Poté náhodně určí délky os elipsy a nakreslí elipsu v daném obdélníkovém ohraničení.

Metoda 3 vytváří anomálie tím, že v první řadě vybere náhodné souřadnice pro horní levý roh obdélníku na obrazu. Posléze určí náhodné rozměry obdélníku a nakreslí jej na dané místo. Velikost obdélníku je ohraničena velikostmi 10x10 a 40x50 pixelů.

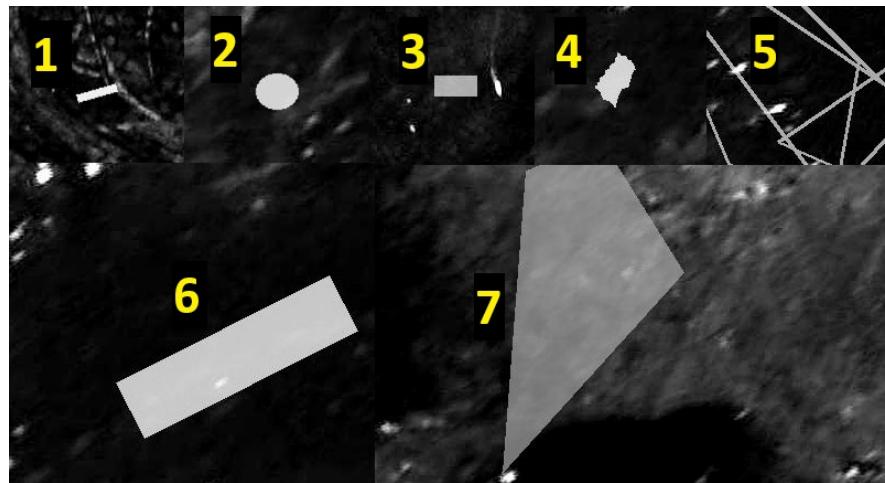
Metoda 4 generuje anomálie tím, že vytvoří obrazec o rozměrech 50x50 pixelů. Uprostřed obrazce vytvoří vodorovnou čáru přes celou šířku. Čára se z každé strany rozšířuje směrem nahoru s náhodným zmenšováním délky a posunem ve vodorovném směru, což vytváří nerovnoměrný okraj. Tento proces je opakován i z druhé strany,

ale s různými náhodnými hodnotami, čímž vzniká (typicky) asymetrický tvar. Výsledný obrazec je poté náhodně rotován.

Metoda 5 generuje anomálie tím, že nejprve náhodně určí počet bodů (3 až 20) a jejich souřadnice na obrazu. Následně je nakreslena čára spojující tyto body, přičemž koncový bod je opět spojen s prvním bodem, což vytváří uzavřený tvar. Šírka je zvolena náhodně v rozmezí od 1 do 8 pixelů.

Metoda 6 tvoří anomálie tím, že v první řadě vybere dva náhodné body na obrazu. Tyto body jsou následně spojeny čárou s libovolnou šírkou (50 až 100 pixelů)

Metoda 7 generuje anomálie tím, že náhodně určí počet bodů (3 až 10) a jejich souřadnice na obrazu. Poté nakreslí polygon spojující tyto body.



Obr. 5.4: Přehled jednotlivých anomalií

5.3.4 Způsob vkládání syntetických anomalií

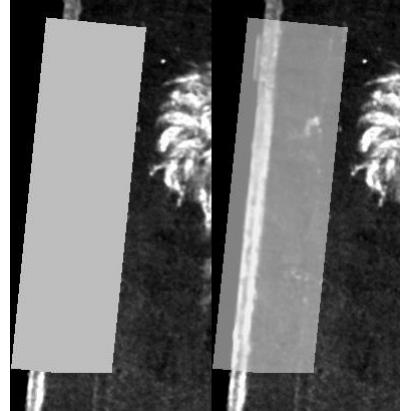
Nyní je potřeba efektivně vkládat tyto vyvinuté metody anomalií do syntetických rentgenů obrazů. Nejzákladnější přístup by spočíval ve vytváření anomalií na částech obrazů s vysokou intenzitou bary, typicky v rozmezí 240 až 255. Tento postup by však byl efektivní pouze pro omezený typ anomalií, jako jsou například skvrny způsobené vylitím olova na plátno, které jsou homogenní a v rentgenových snímcích výrazné. Homogenní v tomto kontextu znamená, že anomálie vykazuje konzistentní intenzitu napříč svou plochou. Nicméně, většina anomalií v rentgenových snímcích není homogenní a nemusí být výrazně viditelná. Z tohoto důvodu byla navrhнута jednoduchá, ale efektivní metoda pro vkládání anomalií, která zohledňuje tuto variabilitu a umožňuje reprezentativnější simulaci různých typů anomalií.

Metoda pro vytváření anomalií zahrnuje procházení jednotlivých pixelů v oblasti, kde má být anomálie umístěna. Každá hodnota pixelu je transformována lineární

funkcí tak, aby výsledná hodnota byla v rozmezí od a do b . Tento postup umožňuje efektivně vytvořit anomálie s požadovanou intenzitou a konzistencí. Zároveň tento způsob zachovává informaci ohledně tvarů, které se nacházejí pod danými anomáliemi.

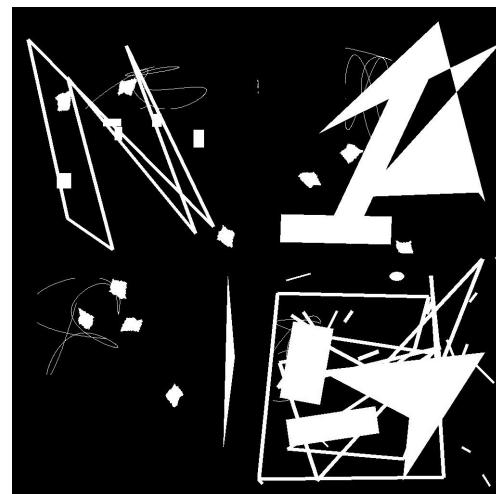
$$f(x) = \frac{(b-a) \cdot x}{255} + a$$

Volba parametrů a , b je závislá na vkládaném typu anomálie.



Obr. 5.5: Ukázka porovnání metod vkládání

Příslušné masky těchto anomálií jsou ukládány tím způsobem, že jsou identicky aplikovány na pouze černý obrázek a jsou vloženy s nejvyšší možnou intenzitou. S ohledem na zmíněný způsob by se jednalo o hodnotu 255, nicméně výsledkem jsou binární segmentační mapy s hodnotami 0 a 1.



Obr. 5.6: Masky anomálií

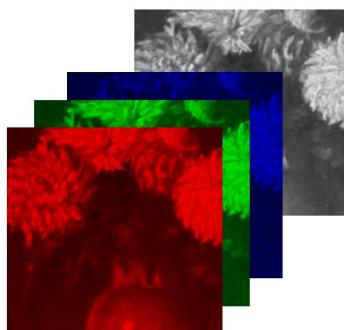
5.4 Koncepční důkaz: návrh neuronové sítě

V této sekci je popsán návrh a vývoj neuronové sítě, která slouží jako důkaz, že navrhované řešení směruje správným směrem. Tento krok je zásadní pro demonstraci realizovatelnosti a efektivity přístupu před dalším rozvojem a aplikací v praxi.

Pro potřeby modelu byla zvolena architektura U-net, vhodná pro úlohy sémantické segmentace. Konstrukce modelu byla provedena využitím modulu Keras z knihovny Tensorflow. Vstupní vrstva modelu přijímá obrazy o rozměrech 512x512 pixelů a 4 kanálech (RGB (3) + rentgenový snímek (1)). Následuje série 3 konvolučních vrstev, tvořících kontrakční cestu modelu. V každé konvoluční vrstvě je aplikována aktivace ReLU, po níž následuje vrstva MaxPooling pro redukci rozměrů a zvýšení abstrakce dat. Použité filtry jsou velikosti 3x3 a v kontrační části je použito postupně 64, 128 a 256 filtrov. Centrální část modelu, tzv. bottleneck, obsahuje další konvoluční vrstvu s 512 filtrov. Expanzní cesta modelu se skládá z vrstev Conv2DTranspose, které postupně zvyšují rozměry zpracovávaných dat a jsou doplněny o operaci konkatenace s odpovídajícími vrstvami kontrakční cesty modelu. Tato struktura zajišťuje lepší zachování kontextových informací a zlepšuje schopnost lokalizace a segmentace anomálií v modelech. Výstupní vrstva modelu je tvořena konvoluční vrstvou s jedním filtrem a sigmoidní aktivací, produkující finální masku anomálií.

Při komplikaci modelu byl použit optimizátor Adam s rychlosí učení 0,001 a ztrátová funkce binární křížové entropie. Vstupní obrazy byly normalizovány na rozsah [0,1]. Model byl trénován na sadě s 600 obrazy s příslušnými syntetickými rentgeny a jejich vygenerovanými anomáliemi. Vzhledem k nadměrné velikosti dat byla použita dávka (batch size) 1 a pouze 1 epocha, přičemž 10 % dat bylo vyhrazeno pro validaci.

Na Obr. 5.7 je naznačen vstup do daného modelu. Jedná se pouze o ilustraci, ve skutečnosti jsou všechny kanály černobílé (greyscale).



Obr. 5.7: Vstupní data

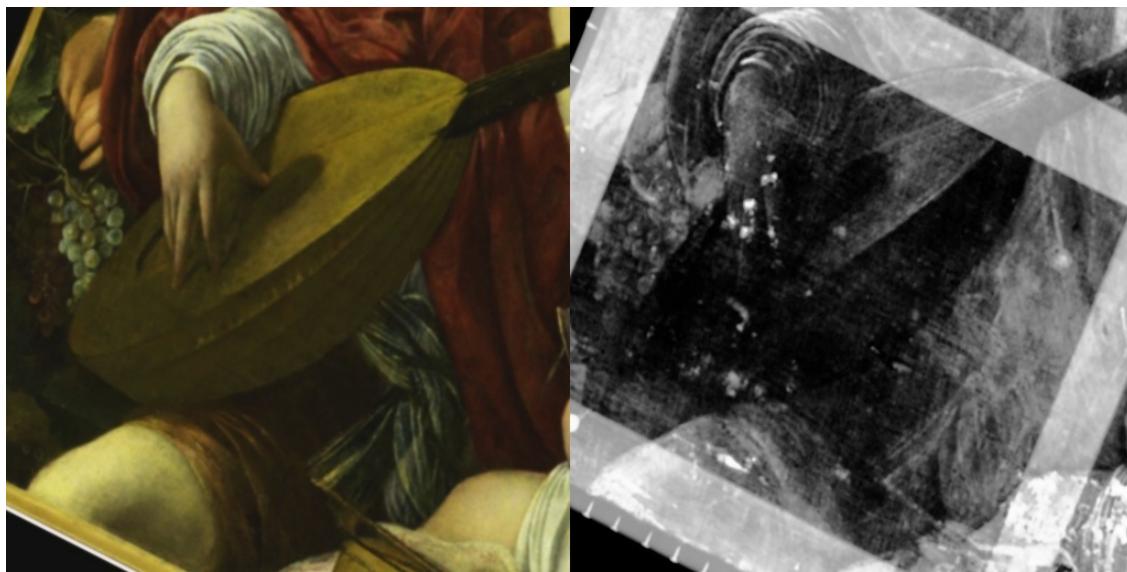
5.5 Zhodnocení koncepčního návrhu

Tato kapitola je zaměřena na hodnocení výsledků koncepčního návrhu neuronové sítě, aby bylo rozhodnuto, zda zvolené řešení dává smysl, a byly stanoveny bližší cíle pro další zlepšení. Klíčovým prvkem hodnocení je efektivita neuronové sítě v detekci anomálií v uměleckých dílech.

Během vývoje modelu byly natrénovány dvě verze neuronové sítě. První model byl trénován tím způsobem, že všech sedm anomálií z trénovacích dat bylo kromě syntetických snímků vloženo i do masek, aby se model naučil detektovat. Tento model měl však vysokou citlivost a označoval jako anomálie i rámy obrazů, což nebylo žádoucí. Z toho důvodu byl vyvinut druhý model, který byl trénován stejným způsobem, ale s jinou trénovací množinou. Anomálie představující rámy obrazů (metoda 6) a velké plochy (metoda 7) nebyly vloženy do trénovacích masek a nacházely se pouze v syntetických rentgenových snímcích. Model tímto způsobem nebude klasifikovat rámy a velké plochy jako anomálie.

5.6 Způsob vyhodnocení modelů

Vzhledem k výzvám spojených s hodnocením modelů na rozsáhlém a diverzifikovaném datasetu a limitacemi automatických metrik bylo zvoleno ruční testování a porovnání. Testování proběhlo na náhodných obrazech z testovací množiny s jejich příslušnými rentgenovými snímkami. Pro demonstraci bude uveden jeden z nich:

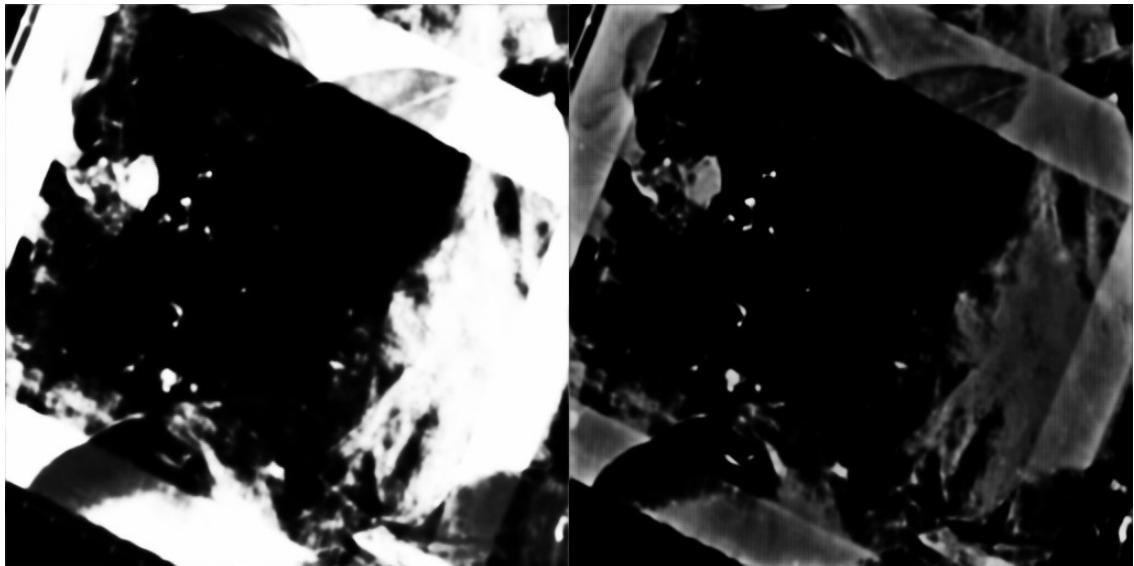


Obr. 5.8: Originální obraz s rentgenovým snímkem

5.7 Porovnání modelů a shrnutí výsledků

Model 1, jehož výsledky jsou zobrazeny vlevo na obrázku 5.9, vykazuje vysokou citlivost na detekci anomálií. Tento model detekuje i velmi malé rozdíly, což vede k tomu, že mnoho oblastí obrazu má vysokou intenzitu. Tento jev je patrný zejména u rámů obrazu, které jsou nesprávně označovány jako anomálie. Přestože tento model dosahuje svého cíle v detekci anomálií, jeho přílišná citlivost způsobuje, že výsledná segmentační mapa je přeexponovaná a obsahuje mnoho falešně pozitivních oblastí.

Naopak Model 2, jehož výsledky jsou zobrazeny vpravo, vykazuje nižší citlivost, což vede k lepším výsledkům v kontextu našich požadavků. Tento model je schopen lépe rozlišovat skutečné anomálie od běžných částí obrazu, což je patrné zejména na méně intenzivních oblastech rámů obrazů. Výsledná segmentační mapa není přeexponovaná a lépe odpovídá skutečným anomáliím, což snižuje množství falešně pozitivních nálezů.



Obr. 5.9: Segmentační mapy Modelů 1 a 2

Na základě těchto výsledků lze konstatovat, že problém detekce anomálií v uměleckých dílech lze řešit pomocí navržených neuronových sítí. Pro dosažení optimálních výsledků je však nezbytné dále zlepšit detekci anomálií a snížit citlivost neuronové sítě, aby například rámy obrazů nebyly nesprávně označovány jako anomálie. Následující kapitoly se zaměří na tyto oblasti zlepšení a optimalizace modelů. Model 2 se jeví jako vhodnější základ pro další optimalizaci a zlepšení, a proto bude dále využita jeho trénovací množina bez anomálií (vytvořených metodou 6 a 7) v masce.

6 Návrh a vývoj dalších architektur

V návaznosti na úspěšný koncepční důkaz bylo vyvinuto dalších 19 architektur neuronových sítí s cílem identifikovat optimální řešení pro specifický problém, který je předmětem této práce. Tyto architektury byly navrženy tak, aby testovaly různé aspekty a parametry, které mohou významně ovlivnit výkon a účinnost modelu v aplikovaném kontextu.

Variabilita ve velikosti kernelů a počtu filtrů

Jednou z klíčových proměnných, které byly modifikovány, byla velikost kernelů (3x3 a 5x5) a počet filtrů v konvolučních vrstvách. Experimenty s různými konfiguracemi těchto parametrů umožnily posoudit, jak velikost kernelu a počet filtrů ovlivňují úroveň detailů, které model dokáže extrahat a následně využít pro přesnější segmentaci.

Hloubka modelu: U-Net a U-Net++

Dalším zkoumaným aspektem byla hloubka modelu, kde byly testovány varianty klasického U-Netu a jeho rozšířené verze U-Net++. Hloubka modelu, tedy počet vrstev, přímo ovlivňuje schopnost modelu abstrahovat a interpretovat informace na různých úrovních složitosti.

Konfigurace konvolučních vrstev a batch normalization

Různé architektury se také lišily počtem konvolučních vrstev umístěných za sebou. Zatímco některé modely měly ve svých konvolučních blocích dvě vrstvy, jiné byly navrženy s jednou vrstvou. Další zkoumaný faktor byl vliv batch normalization, což je technika používaná k normalizaci vstupů do vrstvy s cílem zlepšit stabilitu a rychlosť konvergence trénování. Modely byly navrženy tak, aby bylo možné porovnat výkony těch, které batch normalization integrovaly, proti těm, které tuto techniku nepoužívaly.

Ztrátová funkce a UpSampling2D vs. Conv2DTranspose

Pro trénování modelů byly použity dvě různé ztrátové funkce: binární křížová entropie (BCE) a Intersection over Union (IoU). Testovány byly také různé metody pro zvětšení rozlišení obrazu v dekódovací části modelu. Některé architektury využívaly vrstvy UpSampling2D, zatímco jiné byly vybaveny vrstvami Conv2DTranspose.

6.1 Hodnocení a výběr vhodných architektur

Proces hodnocení a výběru nejvhodnějších architektur z počáteční množiny 20 modelů byl založen na následujícím experimentálním protokolu, který umožnil objektivní srovnání jejich výkonů.

Metodologie trénování

Každá z 20 architektur byla vystavena identickým trénovacím podmínkám, aby bylo zajištěno spravedlivé srovnání jejich schopností. Každý model byl natrénován 20krát, přičemž každá iterace zahrnovala trénink s 1 epochou na 500 obrázcích. Z těchto 500 obrázků bylo 10 %, tedy 50 obrázků, ponecháno pro validaci. To znamená, že celkově byla každá architektura trénována na 10 000 obrázcích během všech svých 20 iterací.

Testování a evaluace

Pro finální hodnocení bylo připraveno 400 testovacích obrázků, které nebyly součástí trénovací množiny, ale byly generovány obdobným způsobem. Tyto obrázky sloužily jako základ pro posouzení efektivity každého modelu. Kritériem pro hodnocení bylo IoU skóre, které poskytuje robustní měřítko kvality segmentace tím, že porovnává predikované masky s reálnými maskami obrázků.

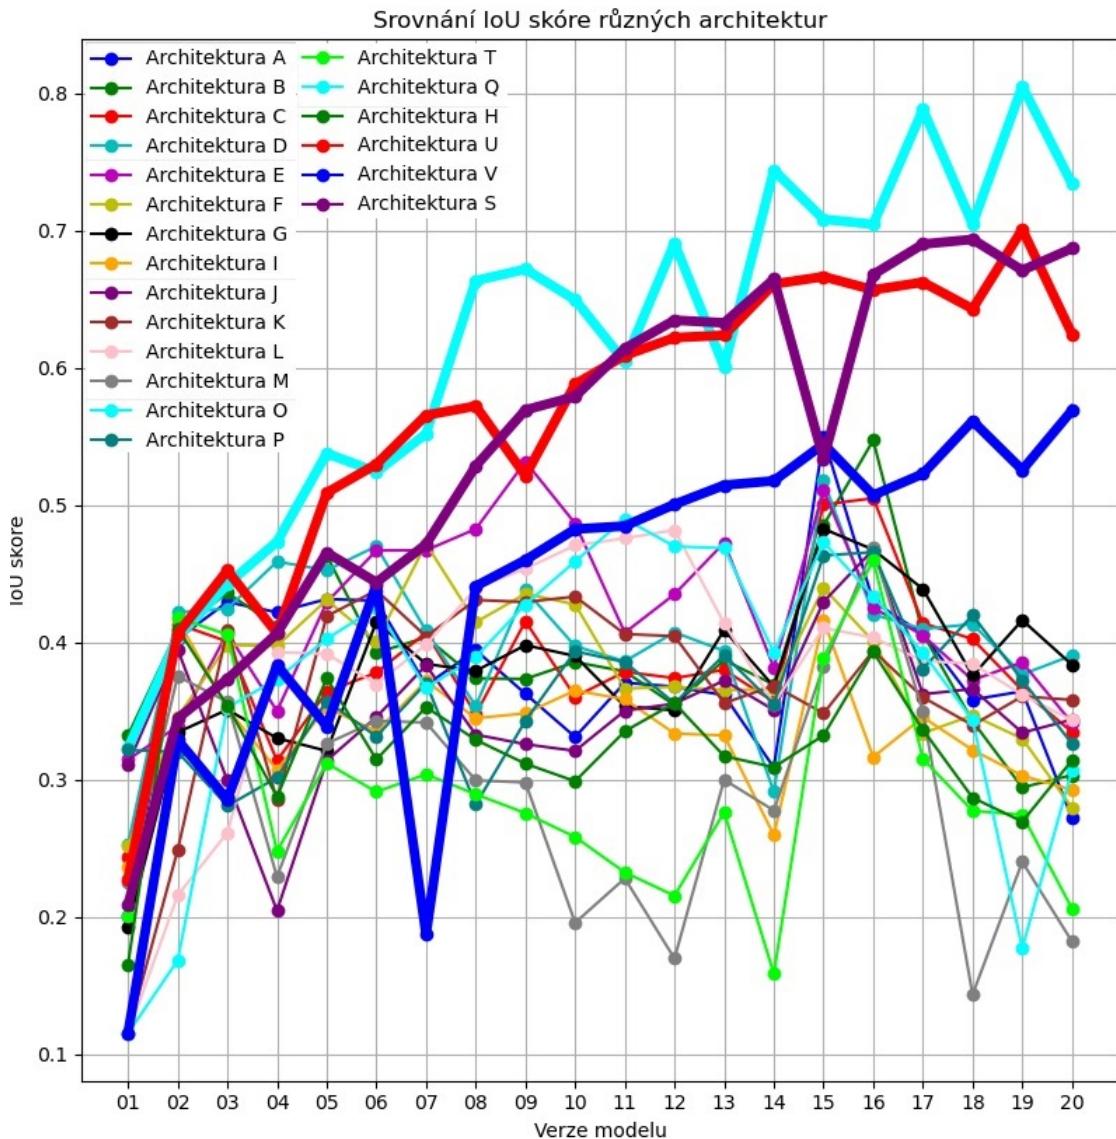
Analýza výsledků

Výsledky IoU byly zaznamenány pro každý z modelů v různých iteracích jejich trénování. Na základě těchto výsledků byl vytvořen graf, kde osa x představovala iterace modelů (od 01 do 20, každá iterace představuje 500 trénovacích dat) a osa y reprezentovala IoU skóre. V grafu bylo každé z 20 architektur reprezentováno vlastní barvou křivky, což umožnilo vizuální srovnání jejich výkonu napříč různými iteracemi.

Pro každou architekturu bylo IoU spočítáno tak, že predikce modelu na testovacích datech byly porovnány se skutečnými maskami, přičemž IoU pro každý obrázek bylo následně zprůměrováno přes všechny 400 výsledků. Toto systematické srovnání umožnilo identifikovat nejlepší modely, které vykázaly nejvyšší průměrné IoU skóre a tedy nejlepší celkovou účinnost ve segmentaci.

Na základě těchto výsledků byly vybrány čtyři architektury, které prokázaly nejvyšší potenciál pro další vývoj a optimalizaci. Tyto modely budou předmětem dalších výzkumů a úprav, aby se maximalizovala jejich efektivita a přesnost pro praktické nasazení v reálných aplikacích.

Nejlepších výsledků dosahovaly architektury značené písmeny "O", "U", "V", "S". V grafu jsou tyto architektury označeny tučnou křivkou.



Obr. 6.1: Graf IoU skóre modelů

Porovnání jednotlivých architektur v tabulce

Následující tabulka poskytuje srovnání architektur, ty jsou seřazeny od nejlepší po nejhorší na základě IoU skóre nejlepší verze modelu dané architektury. Sloupec UpSamp vrstva označuje typ vrstvy použitý pro zvětšení rozlišení obrazu v dekóduvací části. UpSamp znamená UpSampling2D, zatímco Conv2D znamená Conv2DTranspose. Počet filtrů uvádí počet filtrů v konvolučních vrstvách, přičemž hodnoty jako 64, 128, 256, 512 označují počet filtrů ve vrstvách kontrakční cesty modelu, kde poslední číslo (512) značí bottleneck. Poté vždy následuje expanzní cesta, kde se počet filtrů obrací (256, 128, 64). Varianta K měla experimentální zapojení U-Net++, zatímco

architektura H byla navržena jako standardní U-Net bez skip connections.

Varianta	Kernel	UpSamp vrstva	Ztrátová funkce	Model	Počet vrstev	Batch Norm	Počet filtrů	IoU (%)
O	3x3	Conv2D	BCE	U-net	2	ne	64,128,256,512	80.5
U	3x3	UpSamp	BCE	U-net	1	ne	64,128,256,512	70.1
S	5x5	UpSamp	BCE	U-net	1	ne	16,32,64,128,256,512	69.4
V	3x3	Conv2D	BCE	U-net++	2	ne	32,64,128,256,512	56.9
A	3x3	UpSamp	BCE	U-net	1	ano	32,64,128,256,512,1024	54.9
B	3x3	UpSamp	IoU	U-net	1	ano	32,64,128,256,512,1024	54.7
E	5x5	UpSamp	BCE	U-net	1	ano	16,32,64,128,256,512	53.2
D	5x5	UpSamp	BCE	U-net	1	ano	32,64,128,256,512	51.8
C	5x5	UpSamp	BCE	U-net	1	ano	32,64,128,256,512,1024	50.5
Q	3x3	Conv2D	BCE	U-net++	2	ano	32,64,128,256,512	49.0
G	3x3	UpSamp	BCE	U-net	1	ano	32,64,128,256,512	48.3
L	3x3	UpSamp	BCE	U-net++	1	ano	32,64,128,256,512	48.2
F	3x3	UpSamp	BCE	U-net	1	ano	16,32,64,128,256,512	47.2
M	3x3	UpSamp	BCE	U-net++	2	ano	32,64,128,256,512	46.9
J	3x3	UpSamp	IoU	U-net++	1	ano	32,64,128,256,512	46.7
P	3x3	UpSamp	IoU	U-net	2	ano	32,64,128,256,512,1024	46.6
T	3x3	Conv2D	BCE	U-net	2	ano	32,64,128,256,512,1024	46.0
K	3x3	UpSamp	BCE	U-net++ *	1	ano	32,64,128,256,512	43.8
I	3x3	UpSamp	BCE	U-net++	1	ano	32,64,128,256,512	41.7
H	3x3	UpSamp	BCE	U-net **	1	ano	64,128,256,512	41.0

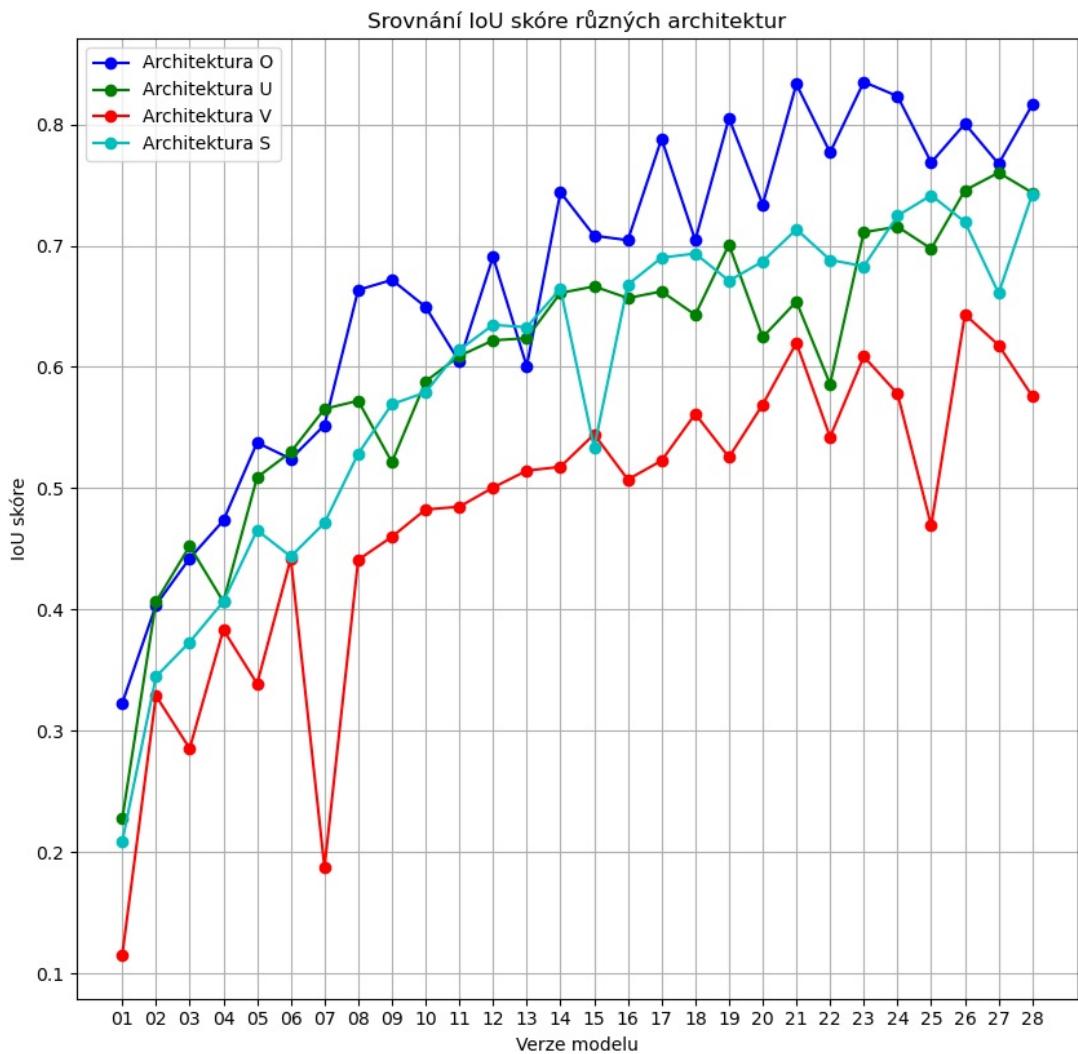
Obr. 6.2: Tabulka srovnání modelů

6.2 Optimalizace vybraných modelů

Po výběru čtyř nejlepších architektur z předchozích experimentů byly tyto modely podrobeny dalšímu tréninku. Cílem bylo dosáhnout maximální efektivity každého modelu skrze rozšíření trénovacích iterací na celkový počet 28, což odpovídá 14 000 trénovacím obrazům. Tento rozšířený tréninkový proces byl navržen tak, aby zjistil, zda další iterace tréninku mohou vést k dalšímu zlepšení výkonnosti modelů.

Vyhodnocení rozšířeného tréninku

Výsledky tohoto prodlouženého tréninkového cyklu byly analyzovány s využitím stejného mechanismu hodnocení IoU, jaký byl použit v předchozích fázích. Grafy IoU ukázaly, že modely dosáhly svého výkonostního maxima, které se v nejlepších případech pohybovalo nad 80 % IoU. Analýza dat ukazuje, že další trénink by již nepřinesl významné zlepšení, což naznačuje, že modely dosáhly svého optimalizačního stropu.



Obr. 6.3: Graf IoU skóre optimalizovaných modelů

Architektura O: Nejvyšší skóre je 83,5 %.

Architektura U: Nejvyšší skóre je 76,0 %.

Architektura S: Nejvyšší skóre je 74,3 %.

Architektura V: Nejvyšší skóre je 64,3 %.

6.3 Vývoj grafického uživatelského rozhraní pro zobrazení segmentačních map

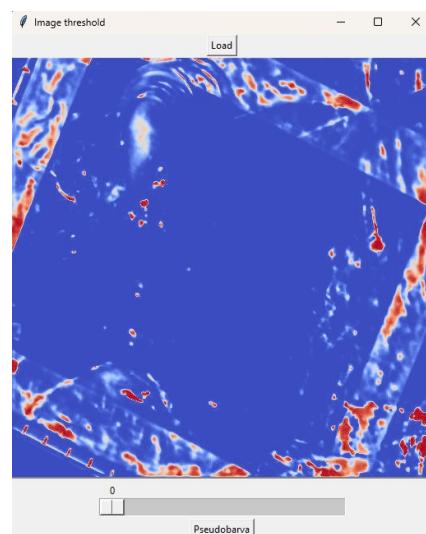
V rámci této práce dále bylo vyvinuto jednoduché grafické uživatelské rozhraní (GUI) v Pythonu, které umožňuje nahrávání a zobrazování segmentačních map s využitím pseudobarev. Hlavním účelem GUI je umožnit uživatelům nahrát segmentační mapy a interpretovat je pomocí barevného kódování, které odlišuje oblasti s vysokou a nízkou pravděpodobností výskytu anomálií. V GUI byly implementovány následující funkcionality:

Nahrávání obrázků a posuvník pro filtrování pravděpodobnosti

Uživatelé mohou snadno nahrát segmentační mapy do rozhraní, kde jsou automaticky zpracovány a zobrazeny. Pro zvýšení uživatelské přívětivosti a analytické flexibility byl do GUI integrován posuvník, který umožňuje uživatelům dynamicky upravovat prahovou hodnotu pravděpodobnosti zobrazených oblastí. Tím lze snadno eliminovat méně pravděpodobné oblasti a soustředit se pouze na ty nejvíce signifikantní.

Pseudobarevné zobrazení

Segmentační mapy je možné vizualitovat s použitím pseudobarev, kde červená barva indikuje vysokou pravděpodobnost detekce anomálie a modrá barva nízkou pravděpodobnost. Toto barevné rozlišení pomáhá uživatelům rychle identifikovat oblasti zájmu.



Obr. 6.4: GUI pro zobrazování segmentačních map

7 Hodnocení modelů na skutečných datech

Cílem této kapitoly je zhodnotit účinnost modelů na skutečných, nikoli synteticky generovaných, datech. Původní návrh vytvořit ručně anotovanou testovací množinu byl zavrhnut z důvodu popsaných dále v textu. Místo toho je tato kapitola soustředěna na subjektivní hodnocení s ukázkami, kde modely zjevně správně identifikují nesrovnalosti mezi vizuálním a rentgenovým spektrem obrazu a kde naopak selhávají.

7.1 Problematika ruční anotace

Při původním záměru přípravy reálných dat se objevil zásadní problém spojený s ruční anotací. Určení, co přesně tvoří anomálie v obrazu, bylo často předmětem diskuse a nejednotnosti. Ruční anotace obrazů přináší subjektivní element do procesu, jelikož různí anotátoři mohou mít rozdílné názory na to, co konstituuje dostatečně významnou odchylku od normálu, která by měla být označena jako anomálie. Tento problém vede k nekonzistencím v testovacích datech, což ovlivňuje evaluaci modelů. V prvotních fázích evaluace z toho důvodu docházelo k problémům, kdy na základě IoU skóre výchazely nejlépe modely, které ve skutečnosti nebyly tak vhodné jako jiné, jež vykazovaly nižší skóre IoU.

7.2 Problematika (ne)univerzálnosti

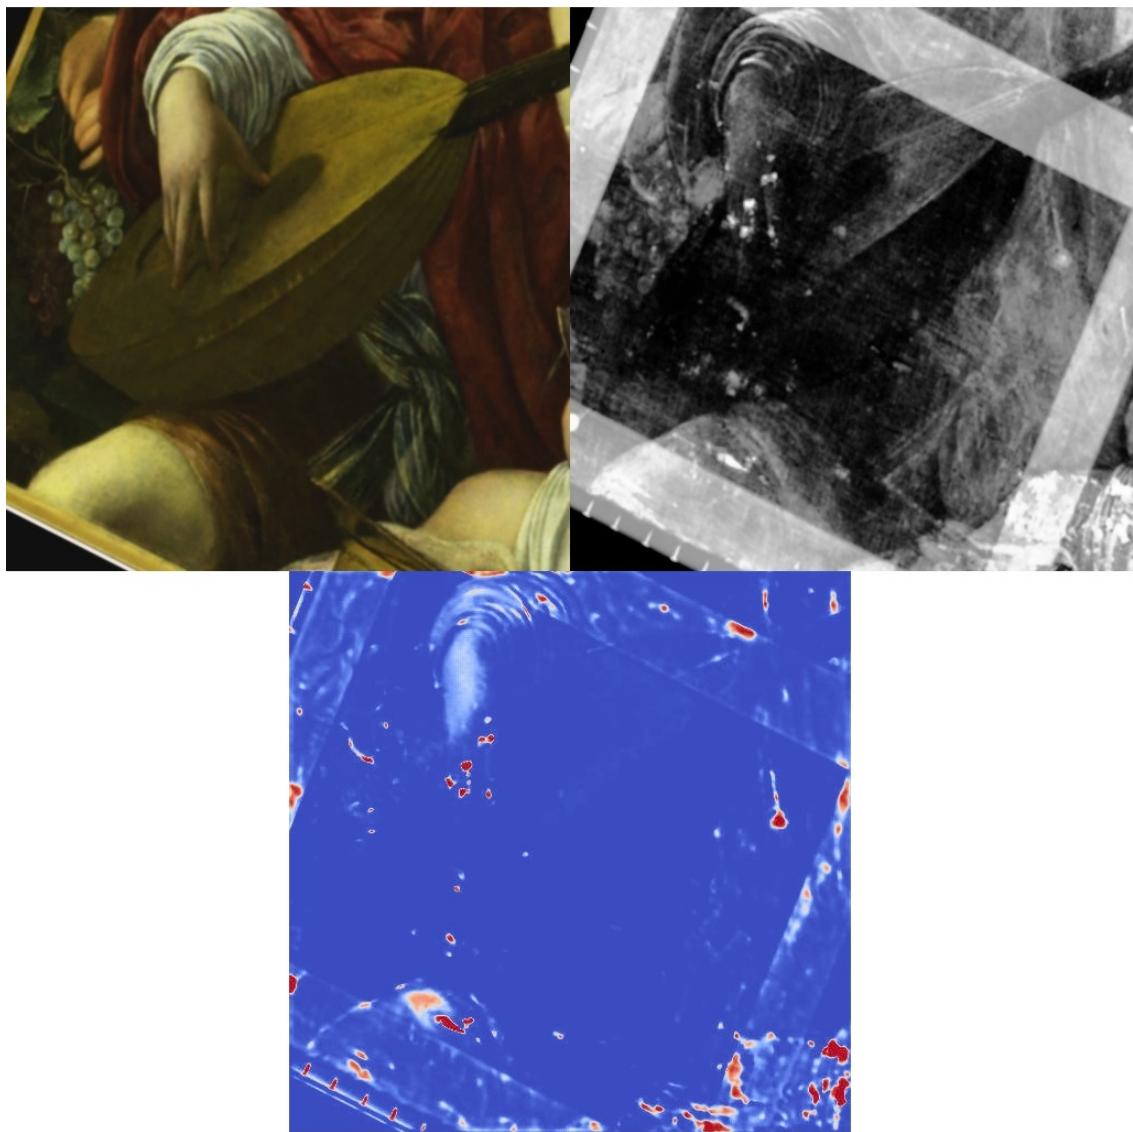
V procesu analýzy uměleckých děl je zásadní zohlednit variabilitu expozice jejich rentgenových snímků. Specifická úroveň expozice může výrazně ovlivnit vhodnost použitého modelu neuronové sítě. Při slabě exponovaných snímcích, kde jsou detaily často skryty v šumu nebo slabém kontrastu, může být vhodné použít citlivější model, který je vnímavější vůči jemným nuancím a změnám v obrazu. Naopak při přeexponovaných snímcích, kde mohou být jasné oblasti chybně interpretovány jako anomálie, je lepší volbou méně citlivý model, který může lépe filtrovat nadměrné výkyvy a zabránit falešně pozitivním detekcím. Tato nutnost adaptace modelu na konkrétní charakteristiky každého rentgenového snímku ilustruje, proč se není možné spolehnout na jediný univerzální model pro všechny typy expozicí a podmínek.

7.3 Příklady konkrétních výsledků

V práci bylo vyvinuto 112 segmentačních modelů. Tyto modely jsou rozděleny do čtyř různých architektur: O, S, U, V. Každá z těchto architektur má 28 různých

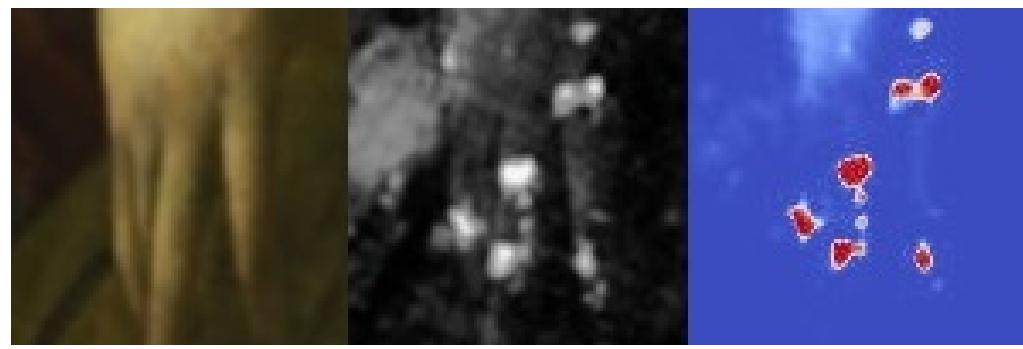
verzí, které jsou pro zjednodušení označeny písmenem a číslem (např. V27 pro 27. verzi architektury V). V každém příkladu budou uvedeny tři obrázky - vizuální spektrum obrazu, příslušný rentgenový snímek a v poslední řadě výsledná segmentační mapa daného modelu zobrazená v pseudobarvách. Vždy budou následovat detailnější snímky daného příkladu se stručným komentářem.

7.3.1 Příklad 1 - zanedbání rámu obrazu



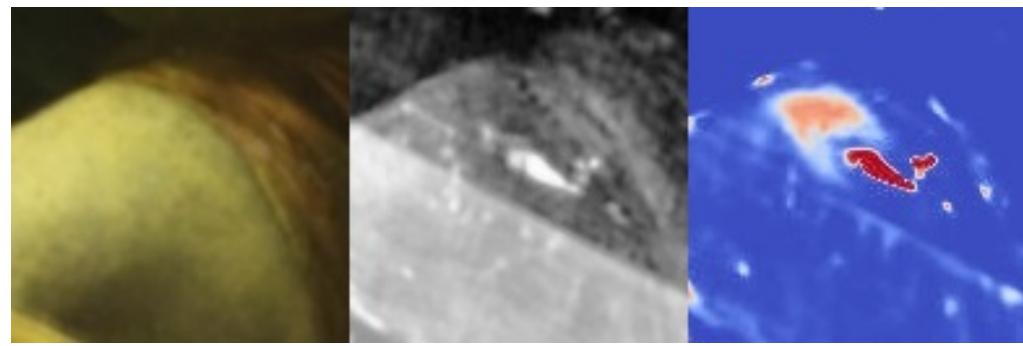
Obr. 7.1: Příklad 1

Pro tento příklad byl zvolen model V27, který efektivně zachycuje anomálie a zároveň správně neklasifikuje rámy obrazu jako odchylky.



Obr. 7.2: Detail 1 příkladu 1

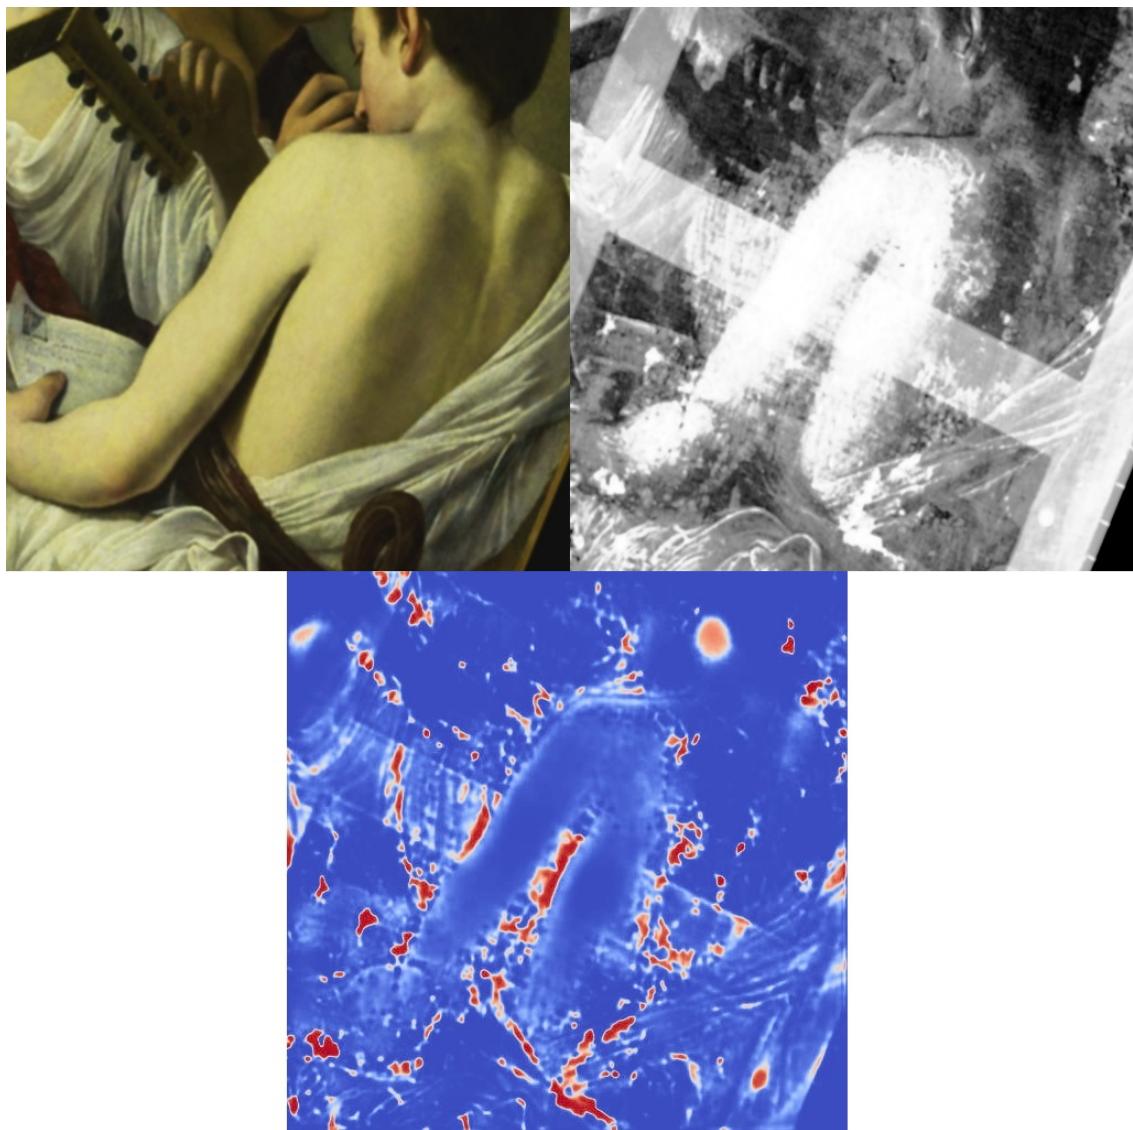
Na obrázku 7.2 si lze všimnout, že model správně identifikoval vybrané anomálie bez většího problému.



Obr. 7.3: Detail 2 příkladu 1

Na obrázku 7.3 je jasně viditelná a modelem správně zobrazená zjevná anomálie, naopak rám obrazu zůstal modelem neidentifikován. Nachází se zde však mylně klasifikovaná anomálie vlevo od červeně zvýrazněné. Tato anomálie je modelem klasifikovaná s nižší pravděpodobností - v segmentační mapě nemá tak vysokou intenzitu jako ta první.

7.3.2 Příklad 2 - rozsáhlá detekce anomalií



Obr. 7.4: Příklad 2

Pro tento příklad byl nevhodnější model S19. Příklad je specifický tím, že se zde nachází velké množství nesouladů mezi vizuálním a rentgenovým spektrem. Model na některých místech obrazu nesprávně identifikuje části rámu jako anomálie. I přes tento nedostatek však model správně zvýrazňuje podezřelá místa, která by byla vhodná pro další zkoumání.



Obr. 7.5: Detail 1 příkladu 2

Na obrázku 7.5 model správně identifikuje 3 viditelné anomálie. Zároveň korektně opomíjí oblast ve středu dolní části detailu, protože ačkoliv je na rentgenovém snímku tato oblast viditelná, nijak nerozporuje vizuálnímu spektru - jedná se o velmi podobný tvar.



Obr. 7.6: Detail 2 příkladu 2

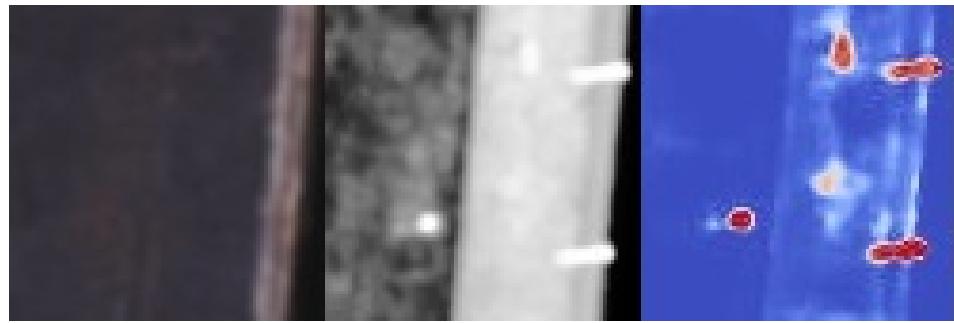
Na obrázku 7.6 model korektně identifikoval tvary, které se nachází v rentgenovém spektru, ačkoliv ve vizuálním chybí.

7.3.3 Příklad 3 - detekce hřebíků



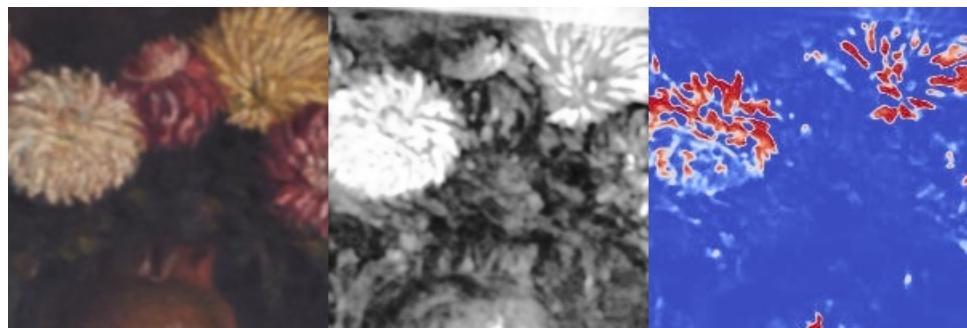
Obr. 7.7: Příklad 3

Na příklad obrázku 7.7 byl zvolen model U16, který zde správně opomíjí rámy obrazu, stejně jako identifikuje hřebíky v rámech, což představuje žádoucí klasifikaci. Model zde však selhává v několika oblastech, především v nesprávné identifikaci květů rostliny jako odchylek a rovněž u části podnosu, na kterém je na obraze namalovaná váza s kyticí.



Obr. 7.8: Detail 1 příkladu 3

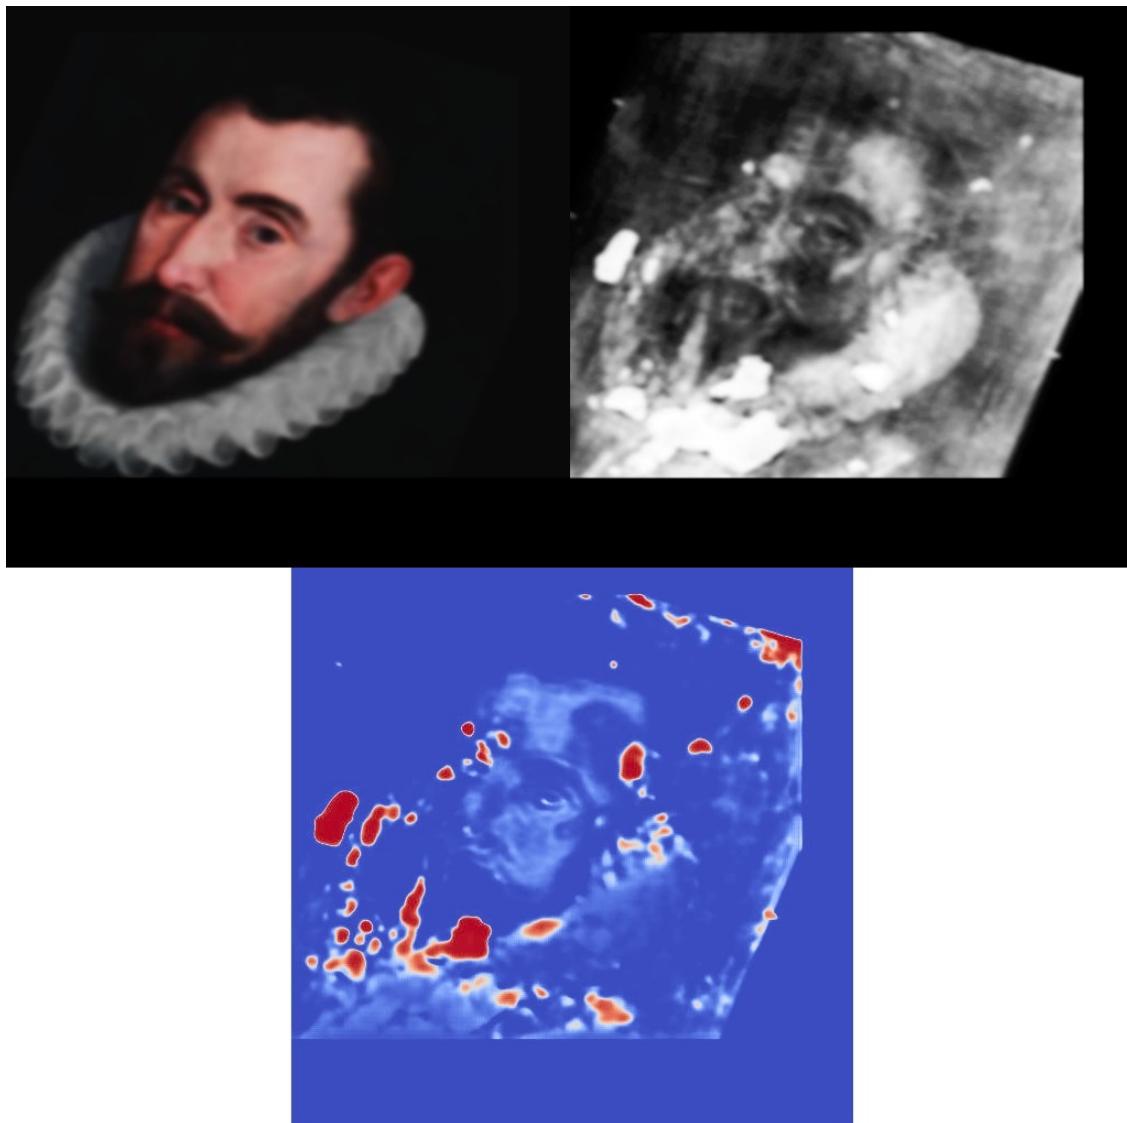
Na obrázku 7.8 jsou korektně s vysokou intenzitou určeny 4 odchylky - 2 hřebíky v rámci obrazu, viditelná tečka v levé části detailu a zjevná anomálie v horní části. Model zde však také klasifikuje s nižší pravděpodobností jako anomálii část ve středu detailu. Při bližším ohledání lze spatřit tento tvar na rentgenovém snímku. Jestli se však jedná o skutečnou anomálii hodnou dalšího zkoumání je značně diskutabilní.



Obr. 7.9: Detail 2 příkladu 3

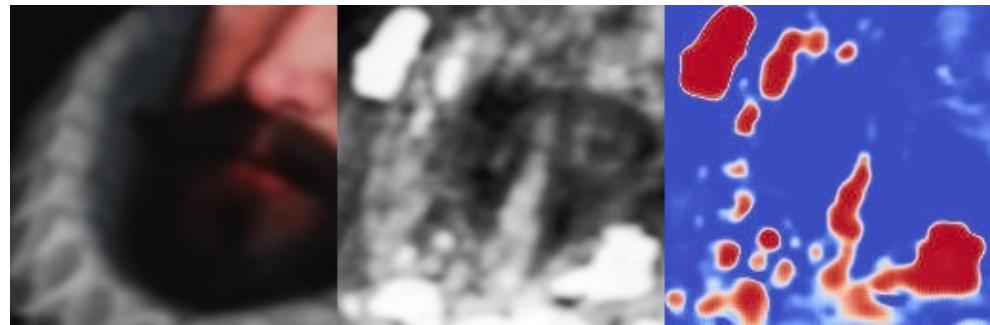
Na obrázku 7.9 je ukázka selhání modelu, kdy klasifikuje části květin jako anomálie. Model tak činí zjevně proto, že na rentgenovém snímku je tato část velmi dominantní, v tomto případě však pouze odráží vizuální spektrum dané části. Jedná se tedy o mylnou klasifikaci.

7.3.4 Příklad 4 - identifikace olovnatých skvrn



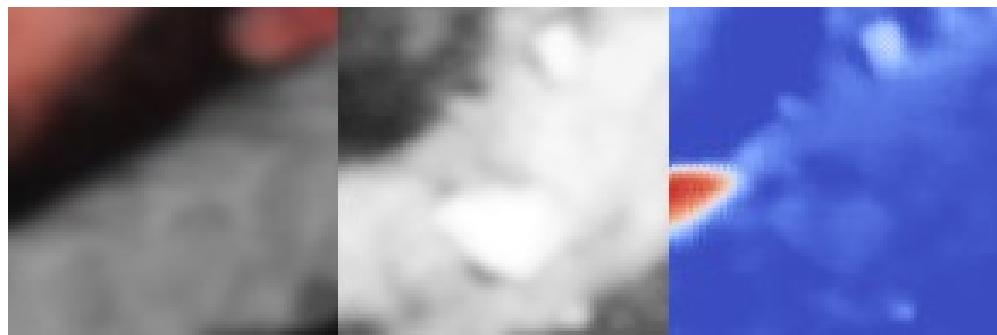
Obr. 7.10: Příklad 4

Pro tento příklad byl zvolen model V20. Model zde ve většině příkladů správně identifikuje anomálie v podobě pravděpodobných olovnatých skvrn. Avšak zároveň identifikuje oblasti v pravé horní části obrazu, které nejsou anomáliemi. Tato místa jsou nejspíše zdůrazněná důvodem nepraktického ořezu obrazu.



Obr. 7.11: Detail 1 příkladu 4

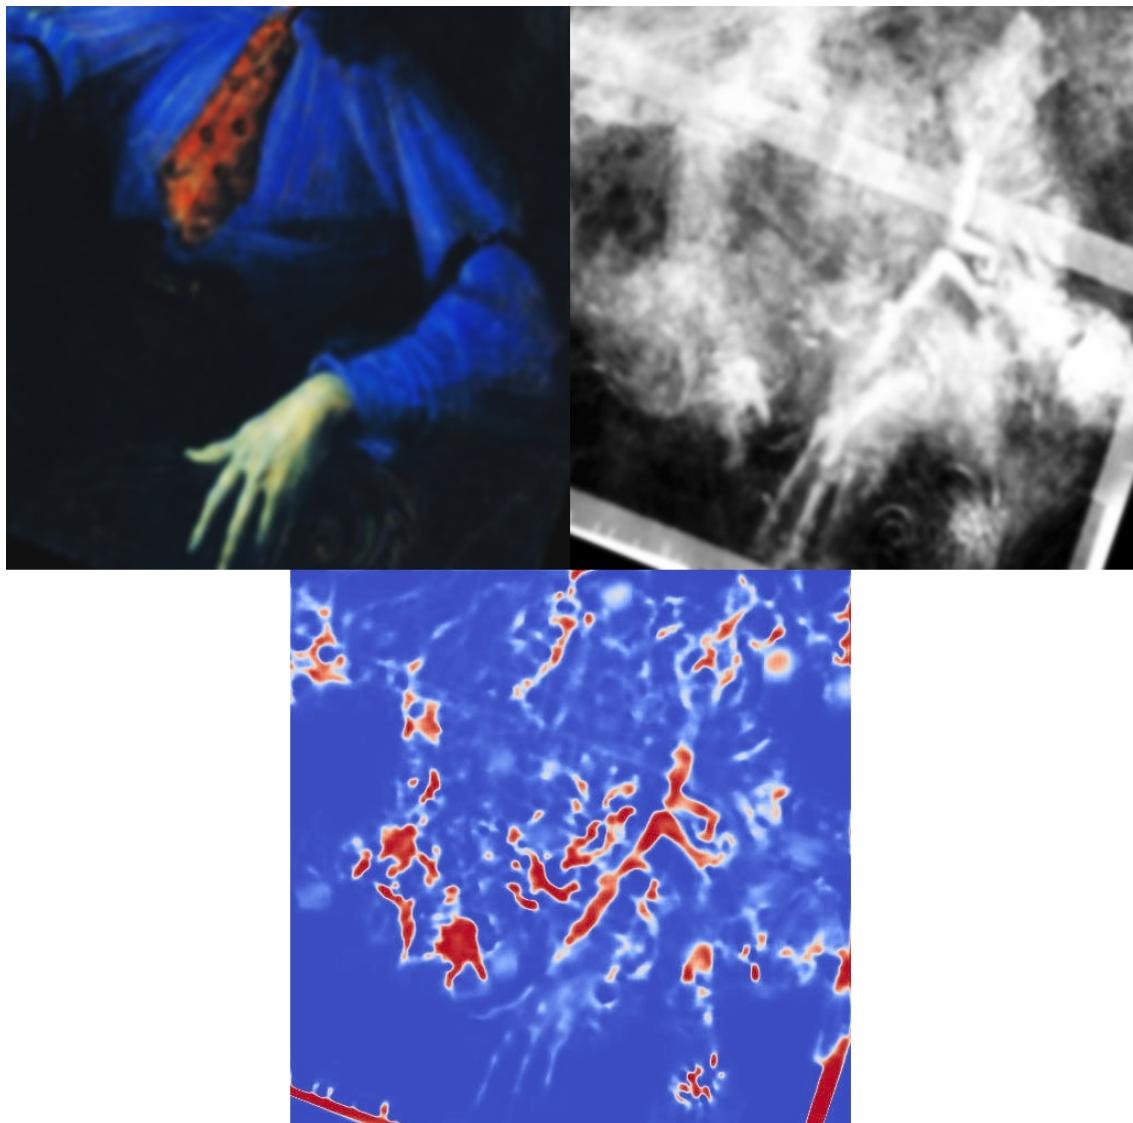
Na obrázku 7.11 je uveden detail, kde model správně určil olovnaté skrvy a další namalované obrysy viditelné na rentgenovém spektru, které ve vizuálním chybí. Tuto část lze považovat za úspěšnou segmentaci podezřelých míst na obraze.



Obr. 7.12: Detail 2 příkladu 4

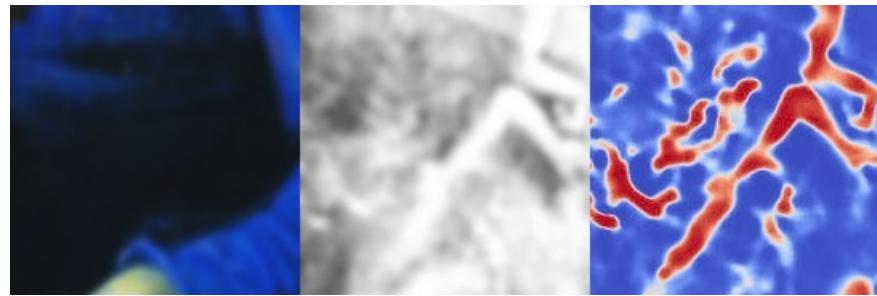
Na rozdíl od předchozího detailu je na obrázku 7.12 ukázka selhání modelu, kdy neklasifikuje zjevnou skvrnu jako anomálii. Jedná se tedy o falšeně negativní klasifikaci. Zároveň je zde uvedena i oblast v levé části obrazu, která zjevně představuje nesoulad mezi vizuálním a rentgenovým spektrem. Zda se jedná o skutečnou anomálii je opět diskutabilní.

7.3.5 Příklad 5 - dlouhá expozice



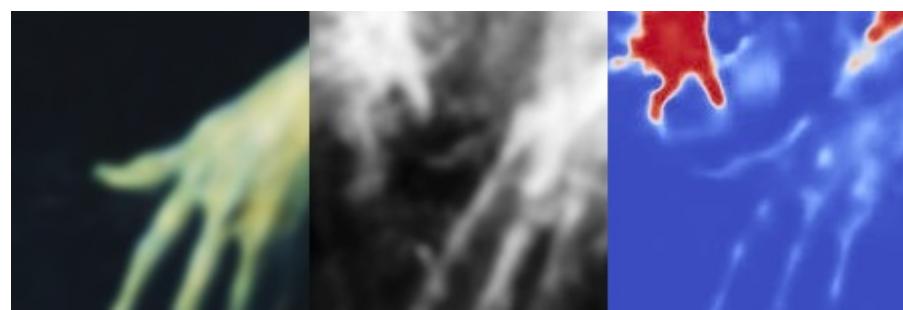
Obr. 7.13: Příklad 5

Tento příklad představuje výzvu, jelikož rentgenové spektrum je zde zjevně velmi přeexponované. Z toho důvodu byl zvolen méně citlivý model O19, který úspěšně zobrazuje pouze oblasti zájmu, aniž by klasifikoval většinu obrazu jako anomálii.



Obr. 7.14: Detail 1 příkladu 5

Na obrázku 7.14 je zobrazen detail, ve kterém jsou identifikované pouze nejvýraznější tvary. Ve středu dolní části detailu je opět opomenuta výrazná oblast v rentgenovém spektru, která je zde v souladu s vizuálním spektrem.



Obr. 7.15: Detail 2 příkladu 5

Na detailu na obrázku 7.15 je správně klasifikovaný tvar v levém horním rohu jako anomálie. Stejně tak je správně opomíjen tvar ruky, který je sice velmi viditelný a dominantní na rentgenové spektru, ale je opět pouze odrazem vizuálního spektra - nejedná se tedy o anomálii.



Obr. 7.16: Detail 3 příkladu 5

Na obrázku 7.16 je zobrazeno zjevné selhání modelu, kdy klasifikuje části, které nejsou anomáliemi.

8 Diskuze

V této práci jsme se zaměřili na navrhování a vývoj metod konvolučních neuronových sítí (CNN) pro detekci falzifikátů uměleckých děl, s důrazem na kombinaci vizuálního a rentgenového spektra obrazů. Cílem bylo navrhnout modely schopné detektovat anomálie v obrazech. Ve finální verzi bylo natrénováno 112 modelů architektur U-net a U-net++, které se liší mírou citlivosti detekce anomálií, což umožňuje jejich využití v různých scénářích detekce. Tyto modely efektivně zdůrazňují rozdíly mezi rentgenovými snímky a původními obrazy, což je klíčové pro identifikaci potenciálních falzifikátů. Na syntetických datech dosahovaly modely úspěšnosti i přes 80 % IoU. Na reálných datech probíhalo hodnocení pouze subjektivně s ukázkami vzhledem k obtížnosti objektivní evaluace.

Vyvinuté modely jsou schopny identifikovat anomálie jako jsou olovnaté skvrny, hřebíky, malby v hlubších vrstvách a různorodé defekty. Zároveň jsou schopné opomíjet rámy obrazu a přeexponované rentgenové snímky z nichž jsou schopny detektovat pouze nejvýznamnější odchylky. Rovněž ignorují výrazné tvary na rentgenovém snímku, které jsou však v souladu s vizuálním spektrem. Modely tak mohou být nápomocné při identifikování podezřelých míst při forenzní prohlídce a usnadnit výběr oblastí zájmu pro následné zkoumání, jako je například chemická analýza pigmentů.

Podle dostupné literatury nebyly na toto téma dosud publikované žádné vědecké studie. Tato práce je tedy první, která se touto problematikou zabývá. Předložené řešení v této práci bylo vyvinuto autorem nezávisle na jiných zdrojích.

Vyvinuté modely mají možnost pomoci vědcům a technikům při odhalování možných falzifikátů a to prostřednictvím úspěšné detekce anomálií na obrazech.

Práce zároveň demonstruje možnost využití syntetických dat k tréninku modelů, které je následně možné aplikovat i na reálná data.

Za nedostatek modelů lze považovat nesprávnost identifikace anomálií v některých případech – buďto modely anomálii nerozpoznají nebo naopak signalizují anomálii v místech, kde žádná není. Další nevýhodou popsaného řešení je fakt, že nelze označit jediný model jako univerzálně vhodný pro všechny situace. Namísto toho je k dispozici široké spektrum modelů, z nichž by si uživatelé měli vybrat několik nevhodnějších a pro každou situaci nechat vygenerovat predikce od každého modelu zvlášť. Následně by měli zvolit model, který se nejlépe hodí k daným okolnostem. Dále by bylo prospěšné vyvinout aplikaci, která by umožňovala generovat tyto predikce, a následně by uživatel pomocí posuvníku mohl kalibrovat výsledky. Toto by značně zefektivnilo využití modelů v praxi, zvláště v komplexních nebo proměnlivých podmírkách.

Závěr

Tato práce se zabývala vývojem a aplikací konvolučních neuronových sítí (CNN) pro detekci falzifikátů uměleckých děl, se zaměřením na integraci vizuálního a rentgenového spektra obrazů. Základní idea řešení spočívala v tom, že pokud se na rentgenovém snímku nachází nějaké anomálie/odchyly, budou zobrazeny pouze v rentgenovém spektru a nikoliv ve vizuálním - bude zde nesoulad mezi spektry. Další krok navrženého řešení spočíval v natrénování modelu, který zvládne binární sémantickou segmentací určit místa na obraze, která jsou zmíněným nesouladem. K vývoji trénovací množiny bylo využito syntetických dat obsahujících uměle generované rentgenové snímky společně s automaticky generovanými anomáliemi.

V rámci této práce bylo pomocí různorodých architektur U-net a U-net++ natrénováno 400 modelů (20 verzí dvaceti různých architektur), z nichž byly na základě skóre IoU (na testovací množině syntetických snímků) vybrány 4 nejslibnější architektury a podrobny další optimalizaci. Každá z těchto 4 architektur byla ve výsledku reprezentovaná 28 verzemi - vzniklo celkem 112 různých modelů. Vybrané modely byly z důvodu obtížné objektivní evaluace hodnoceny subjektivně na reálných datech. Modely se odlišují v míře citlivosti a v práci je diskutován způsob využití v praxi. I přesto, že tyto modely umožňují zvýraznění rozdílů mezi rentgenovými snímky a původními obrazy, v určitých situacích mohou selhat. Srovnání účinnosti modelů je komplikováno absencí srovnatelných studií v dané oblasti.

Hlavním přínosem této práce je formulace návrhu potenciálního řešení pro detekci falzifikátů uměleckých děl. Mezi další přínosy patří návrh použití syntetických dat, které zahrnovalo jejich augmentaci a rovněž tvorbu metody pro generování umělých rentgenových snímků. Dále bylo vyvinuto 7 metod pro tvorbu anomalií, včetně originálního způsobu jejich vkládání prostřednictvím lineární transformace do zmíněných syntetických rentgenových snímků. Dalším přínosem je použití binární sémantické segmentace v kontextu zdůrazňování nesouladů mezi spektry za pomoci U-net architektur. Nejvýznamnějším přínosem je však samotné vyvinutí čtyř nejpřesnějších architektur (dosahujících až 83,5 % IoU na syntetických datech), které jsou schopny detekovat olovnaté skvrny, hřebíky, vrstvy skrytých maleb a různé defekty, zatímco zároveň dokáží ignorovat nevýznamné prvky, jako jsou rámy obrazů a přeexponované rentgenové snímky. Tyto modely se zaměřují pouze na významné odchyly a opomíjejí rentgenové znaky, které jsou konzistentní s vizuálním spektrem. Modely tak nabízejí pomocný nástroj pro techniky a forenzní vědce v muzeích a galeriích, který může být využit k ověření pravosti uměleckých děl.

Zdrojové kódy, váhy modelů a přílohy jsou uloženy na adrese: https://drive.google.com/drive/folders/1e_SCZNXN1R4jZkbo6jwuJ2i82LN6jieG0?usp=sharing

Literatura

- [1] MURPHY, Aimee. *Aura, Provenance, Fakes & Forgeries. Exploring the Pitfalls of Provenance and how this Can Enhance the Agenda of Fakes and Forgeries in the Art World.* Img Journal. 2021, 3(4), 224-241.
- [2] RAGAI, Jehane. *The Scientific Detection of Forgery in Paintings.* Proceedings of the American Philosophical Society. 2013, 157(2), 164-175.
- [3] J&T Banka. *Art Report 2023.* 2023. Dostupné z: <https://sberatele.artplus.cz/wp-content/uploads/2023/06/JT-Banka-Art-Report-2023.pdf>.
- [4] NOBLE, Joseph Veach, The Editors of Encyclopaedia Britannica, ed. *Detection of forgeries in the visual arts.* Britannica.
- [5] SCHLACKMAN, Steve. *Brilliant techniques for detecting art forgeries.* Art Journal. 2018.
- [6] WU, Yu-chen a Jun-wen FENG. *Development and Application of Artificial Neural Network.* Wireless Personal Communications. 2017, 102(2), 1645-1656.
- [7] ABIODUN, Oludare Isaac, Aman JANTAN, Abiodun Esther OMOLARA, Kemi Victoria DADA, Nachaat AbdElatif MOHAMED a Humaira ARSHAD. *State-of-the-art in artificial neural network applications: A survey.* Heliyon. 2018, 4(11).
- [8] SCHMIDHUBER, Jürgen. *Deep learning in neural networks: An overview.* *Neural Networks.* 2015, 61, 85-117.
- [9] LOCKWOOD, Owen a Mei SI. *A Review of Uncertainty for Deep Reinforcement Learning.* Proceedings of the AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment. 18(1), 155-162.
- [10] CAO, Yang-Jie, Li-Li JIA, Yong-Xia CHEN, Nan LIN, Cong YANG a Bo ZHANG. *Recent Advances of Generative Adversarial Networks in Computer Vision.* IEEE Access. 2019, 7, 14985-15006.
- [11] VASWANI, Ashish, Noam SHAZER, Niki PARMAR, Jakob USZKOREIT, Llion JONES, Lukasz KAISER a Illia POLOSUKHIN. *Attention is All you Need.* Advances in Neural Information Processing Systems. 2017, 30.
- [12] TERVEN, Juan R., Diana M. CORDOVA-ESPARZA a Alfonzo RAMIREZ-PEDRAZA. *Loss function and metric in deep learning. A preview.* Computer Science Review. 2023.

- [13] RUBY, A. Usha a Prasannavenkatesan THEERTHAGIRI. *Binary cross entropy with deep learning technique for Image classification*. International Journal of Advanced Trends in Computer Science and Engineering. 2020, 9(4), 5393-5397.
- [14] SIDDHARTH, Sharma, Sharma SIMONE a Athaiya ANIDHYA. *Activation Functions in Neural Networks*. International Journal of Engineering Applied Sciences and Technology. 2020, 4, 310-316.
- [15] MIANJY, Poorya a Raman ARORA. *On Convergence and Generalization of Dropout Training*. Neural Information Processing Systems. 2020.
- [16] NEYSHABUR, Benham, Zhiyuan LI, Srinadh NHOJANAPALLI, Yann LECUN a Nathan SREBRO. *Towards Understanding the Role of Over-Parametrization in Generalization of Neural Networks*. 2018.
- [17] LI, Zewen, Wenjie YANG, Shouheng PENG a Fan LIU. *A survey of convolutional neural networks: analysis, applications, and prospects*. IEEE transactions on neural networks and learning systems. 2021.
- [18] HESAMIAN, Mohammad Hesam, Wenjing JIA, Xiangjian HE a Paul J. KENNEDY. *Atrous convolution for binary semantic segmentation of lung nodule*. IEEE International Conference on Acoustics, Speech and Signal Processing. 2019, 1015-1019.
- [19] GUO, Yanming, Yu LIU, Theodoros GEORGIOU a Michael S. LEW. *A review of semantic segmentation using deep neural networks*. International Journal of Multimedia Information Retrieval. 2018, 7(2), 87-93.
- [20] FENG, Di, Christian HAASE-SCHÜTZ a Lars ROSENBAUM. *Deep Multi-Modal Object Detection and Semantic Segmentation for Autonomous Driving: Datasets, Methods, and Challenges*. IEEE Transactions on Intelligent Transportation Systems. 2021, 22(3), 1341-1360.
- [21] VANDENABEELE, Peter, Francis VERPOORT a Luc MOENS. *Non-destructive analysis of paintings using Fouriertransform Raman spectroscopy with fibre optics*. Journal of Raman Spectroscopy. 2001, 32, 263-269.
- [22] RAGAI, Jehane. *The Scientist and the Forger: Insights into the Scientific Detection of Forgery in Paintings*. 2015.
- [23] RONNEBERGER, Olaf, Philipp FISHER a Thomas BROX. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. Medical Image Computing and Computer-Assisted Intervention. 2015, 9351, 234-241.

- [24] FRANK, Steven J. *This AI Can Spot an Art Forgery*. IEEE Spectrum. 2021.
- [25] SHORTEN, Connor a Taghi M. KHOSHGOFTAAR. *A survey on Image Data Augmentation for Deep Learning*. Journal of Big Data. 2019.
- [26] LE, Tuan Anh, Atilim Giineş BAYDIN a Robert ZINKOV. *Using synthetic data to train neural networks is model-based reasoning*. 2017, 3514-3521.
- [27] ALKHALIFAH, Tariq. *MLReal: Bridging the gap between training on synthetic data and real data applications in machine learning*. Artificial Intelligence in Geosciences. 2022, 3, 101-114.
- [28] ZHOU, Zongwei, MMR SIDDIQUEE a Nima TAJBAKHSH. *UNet++: A Nested U-Net Architecture for Medical Image Segmentation*. Deep Learn Med Image Anal Multimodal Learn Clin Decis Support. 2018, 3-11.
- [29] YANG, Mi, YANGLIU a FENGYE. *Evaluation of UNet and UNet++ Architectures in High Resolution Image Change Detection Applications*. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2020, XLIII-B3-2020, 1507-1514.
- [30] YANG, Mi, YANGLIU a FENGYE. *Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression*. CoRR. 2019.
- [31] FOODY, Giles M. *Challenges in the real world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient*. PLOS ONE. 2023, 18(10).
- [32] HOSSAIN, FMA a Youmin ZHANG. *MsFireD-Net: A lightweight and efficient convolutional neural network for flame and smoke segmentation*. Journal of Automation and Intelligence. 2023, 130-138.
- [33] BENEDETTI, Priscilla, Mauro FEMMINELLA a Gianluca REALI. *Mixed-Sized Biomedical Image Segmentation Based on U-Net Architectures*. Applied Sciences. 2023, 13, 329.

Seznam symbolů a zkratek

RGB	model červená, zelená, modrá
RTG	rentgenové zobrazení
CNN	konvoluční neuronové síťě
IoU	intersection over Union
BCE	binární křížová entropie
SGD	stochastický gradientní sestup
MSE	průměrná kvadratická chyba
MAE	průměrná absolutní chyba
ReLU	rectified linear unit
GUI	grafické uživatelské rozhraní