



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

AUTOMATICKÁ KONTROLA KVALITY VÝROBY LAKOVANÝCH KOVOVÝCH DÍLŮ S POMOCÍ NEURONOVÝCH SÍTÍ

AUTOMATIC QUALITY CONTROL OF PAINTED METAL PARTS PRODUCTION USING NEURAL NETWORKS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Štěpán Ježek

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Radim Burget, Ph.D.

BRNO 2022

Diplomová práce

magisterský navazující studijní program **Telekomunikační a informační technika**

Ústav telekomunikací

Student: Bc. Štěpán Ježek

ID: 203730

Ročník: 2

Akademický rok: 2021/22

NÁZEV TÉMATU:

Automatická kontrola kvality výroby lakovaných kovových dílů s pomocí neuronových sítí

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se s technikami pro rozpoznávání anomálií v obraze (či také učení z jedné třídy), konkrétně se zaměřte na metody založené na konvolučních neuronových sítích. Zpracujte aktuální stav vědy a techniky v této oblasti a metody vzájemně srovnajte. Diskutujte, v čem spočívají nedostatky současných metod a co je jejich příčinou. Proveďte experiment s několika možnými existujícími přístupy, výsledky vhodně srovnajte v podobě tabulky a dosažené výsledky. Vhodně diskutujte případy, kde je metoda úspěšná a kde naopak selhává. Navrhněte neuronovou síť, která bude sloužit pro potřeby monitorování kvality lakovaných dílů.

DOPORUČENÁ LITERATURA:

[1] Li, Chun-Liang, et al. "CutPaste: Self-Supervised Learning for Anomaly Detection and Localization." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021.

[2] Tang, T. W., Kuo, W. H., Lan, J. H., Ding, C. F., Hsu, H., & Young, H. T. (2020). Anomaly detection neural network with dual auto-encoders GAN and its industrial inspection applications. Sensors, 20(12), 3336.

Termín zadání: 7.2.2022

Termín odevzdání: 24.5.2022

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

prof. Ing. Jiří Mišurec, CSc.
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 práce je zaměřena na problematiku vizuální kontroly kvality při výrobě kovových lakovaných dílů. Hlavním problémem řešeným v rámci práce je návrh automatizované metody kontroly kvality, založené na moderních poznatcích z oblasti umělé inteligence a počítačového vidění. Kontrola kvality představuje významnou součást velkého množství průmyslových výrobních procesů, ve kterých je nutné zajistit splnění řady kvalitativních požadavků na vyráběné produkty. Dosud je kontrola kvality prováděna především specializovanými pracovníky, na které je k provádění kontroly kladena řada požadavků na odborné znalosti. Aktuálně známé metody vizuální kontroly kvality založené na umělé inteligenci se vyznačují vysokou náročností na velikost trénovací datové množiny a nízkou tolerancí na výraznější změnu polohy a rotace kontrolovaných objektů vůči snímacímu zařízení. Důsledkem těchto nedostatků je znemožněno nasazení automatizované vizuální kontroly kvality v řadě současných průmyslových aplikací. Hlavním přínosem této práce je návrh nové metody kontroly kvality, která vykazuje silnou schopnost spolehlivě fungovat i v případech, kdy v dané průmyslové výrobě dochází k výše uvedeným jevům změny polohy, rotace objektů a nedostatku trénovacích dat. Přesnost metody navržené v této práci je experimentálně ověřena na datové množině vycházející z problematiky kontroly kvality kovových lakovaných dílů. Dle provedeného měření překonává navržená metoda v přesnosti detekce defektů ostatní, současně známé metody o 10,25 % dle *AUROC* metriky.

KLÍČOVÁ SLOVA

detekce anomálií, defektoskopie, počítačové vidění, konvoluční neuronové sítě, průmyslová kontrola kvality, automatizace

ABSTRACT

This thesis is focused on the problem of visual quality control during painted metal parts fabrication. The main problem of the thesis is the design of automatic quality control method based on modern artificial intelligence and computer vision techniques. Quality control is an important part of a large number of industrial production processes, in which it is necessary to ensure compliance with a number of quality requirements for manufactured products. Until now, quality control is carried out mainly by specialized staff, who are subject to a number of expertise requirements. Currently known methods of visual quality control based on artificial intelligence are characterized by high demands on the size of the training data set and low tolerance for a significant change in position and rotation of the inspected objects relative to the scanning device. As a result of these shortcomings, the use of automated visual quality control in many current industrial applications is impossible. The main contribution of this thesis is the design of a new method for quality control, which shows a strong ability to function reliably even in cases where the above mentioned phenomena of change in position, rotation of objects and lack of training data occur during manufacturing. The accuracy of the method proposed in this thesis is experimentally verified on a data set based on the issue of quality control of painted metal parts. According to the measurement results of defect detection accuracy, the proposed method outperformed other, currently known methods by 10,25 % using the *AUROC* metric.

KEYWORDS

anomaly detection, defectoscopy, computer vision, convolutional neural networks, industrial quality control, automation

JEŽEK, Štěpán. *Automatická kontrola kvality výroby lakovaných kovových dílů s pomocí neuronových sítí*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, 2022, 71 s. Diplomová práce. Vedoucí práce: doc. Ing. Radim Burget, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora:	Bc. Štěpán Ježek
VUT ID autora:	203730
Typ práce:	Diplomová práce
Akademický rok:	2021/22
Téma závěrečné práce:	Automatická kontrola kvality výroby lakovaných kovových dílů s pomocí neuronových sítí

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

Obsah

Úvod	19
1 Detekce anomálií	21
1.1 Základy problematiky detekce anomálií	21
1.1.1 Složitost problému	21
1.1.2 Anotace vstupních dat	22
1.2 Současné metody detekce anomálií na vizuálních datech	24
1.2.1 Metody založené na rekonstrukci vstupních dat	26
1.2.2 Metody založené na extrakci příznaků z konvoluční neuronové sítě	29
1.2.3 Srovnání metod	34
1.3 Datové množiny pro detekci anomálií v průmyslových aplikacích . . .	35
1.4 Kontrola kvality kovových dílů pomocí metod detekce anomálií	38
2 Návrh nové metody detekce anomálií	39
2.1 Specifikace požadavků na výsledný systém	39
2.2 Navržená metoda	41
2.2.1 Syntetické defekty	43
2.2.2 Trénování modelu a detekce defektních vzorků	45
2.2.3 Architektura konvoluční sítě ResNet	46
3 Experiment	49
3.1 Datová množina	49
3.2 Parametry modelu a trénování	49
3.2.1 Metrika AUROC	53
3.3 Výsledky měření	55
3.3.1 Interpretace výsledků	56
4 Diskuze	59
Závěr	61
Literatura	63
Seznam symbolů a zkratk	71

Seznam obrázků

1.1	Detekce anomálií na dvojrozměrných datech	22
1.2	Blokové schéma trénování řízených metod	23
1.3	Blokové schéma trénování samořízených metod	24
1.4	Blokové schéma trénování neřízených metod	24
1.5	Blokové schéma rekonstrukčních metod	26
1.6	Rekonstrukční metody s použitím autoenkodéru	27
1.7	Generativní soupeřící sítě	28
1.8	Princip metod založených na extrakci příznaků konvoluční neuronovou sítí	29
1.9	Schéma k-NN metod	31
1.10	Schéma pravděpodobnostního modelu	32
1.11	Ukázka metody CutPaste	33
1.12	Ukázka vzorků datové množiny MVTec AD	36
1.13	Ukázka vzorků datové množiny Kolektor SDD	37
2.1	Ukázka variability defektů	40
2.2	Ukázka typů defektů	41
2.3	Blokové schéma trénování modelu pro extrakci příznaků	42
2.4	Blokové schéma detekce defektů	42
2.5	Segmentace kovového dílu a pozadí	43
2.6	Ukázka syntetických defektů na černobílých snímcích	44
2.7	Ukázka syntetických defektů CutPaste	45
2.8	Ukázka syntetických defektů na barevných snímcích	46
2.9	Blokové schéma reziduálního modulu	47
2.10	Blokové schéma použitého modelu	48
3.1	Datová množina - černobílá	50
3.2	Datová množina - barevná	51
3.3	Ukázka transformací pro zamezení přeučení	52
3.4	Graf změny parametru learning rate v průběhu učení	53
3.5	Schéma matice záměn	54
3.6	Graf ROC	55
3.7	Graf průběhu AUROC během učení	56
3.8	Třída s nízkou přesností detekce	58
3.9	Třída s nejvyšší přesností detekce	58

Seznam tabulek

1.1	Srovnání současných metod detekce anomálií	34
1.2	Počty vzorků v datové množině MVTec-AD	36
3.1	Počty vzorků ve vytvořené datové množině	50
3.2	Parametry generování defektů	53
3.3	Výsledky měření	56

Úvod

Mezi základní součásti průmyslových výrobních procesů patří fáze kontroly kvality vyráběných produktů. V rámci výroby musí produkty typicky splňovat řadu kvalitativních požadavků, nutných pro zajištění bezpečnosti či správné funkce produktu nebo naplnění očekávání a nároků zákazníků. K nejčastějším způsobům zajištění kvality patří vizuální kontrola výrobků v průběhu nebo na konci výrobního postupu. Tento typ kontroly je obvykle vykonáván specializovanými pracovníky, kteří k provádění této činnosti musí často splnit řadu požadavků na odborné znalosti, specifické pro daný typ výroby. Proces kontroly je dále obvykle nutné provádět opakovaně, po dlouhou dobu a pro velký počet výrobků, čímž vzniká riziko, že kvalita provedení kontroly bude negativně ovlivněna únavou pracovníků.

S využitím moderních poznatků z oblasti zpracování vizuálních dat pomocí neuronových sítí vzniká řada přístupů, kterými lze proces kontroly kvality provádět automatizovaně. V rámci výroby tak nemusí vznikat odborné nároky na pracovníky, je možné také omezit chyby v kontrole způsobené vlivem únavy a lze redukovat čas nutný k provedení kontroly. Použití automatizovaného přístupu pro kontrolu kvality tak může přinášet výrazné zvýšení kvality vyráběných produktů a také snížení celkových nákladů na výrobní proces.

Současné metody automatizované kontroly kvality obvykle kladou vysoké požadavky na množství a kvalitu vstupních trénovacích dat, což není možné v řadě výrobních procesů zajistit. K případům, kdy jsou tyto požadavky obtížně splnitelné patří také problém řešený v rámci této práce.

Hlavním přínosem této práce je návrh nové metody pro automatizovanou kontrolu kvality v podmínkách, kde nelze získat velké množství trénovacích dat a získaná data jsou v průběhu snímání ovlivněna řadou nepříznivých vlivů, mezi které patří např. výrazná změna polohy snímaných objektů či nestabilní světelné podmínky. V rámci práce je pro modelování uvedených vlivů vytvořena nová datová množina vycházející z problematiky kontroly kvality kovových lakovaných dílů. Na této datové množině je experimentálně ověřena účinnost navržené metody, která v přesnosti detekce defektů překonává doposud známé přístupy.

Zbytek práce je členěn následovně, první kapitola práce je věnována obecnému úvodu do problematiky detekce anomálií a souhrnu aktuálních detekčních metod založených na konvolučních neuronových sítích, pro které je zhodnocena možnost jejich využití k problému řešenému v rámci této práce. Druhá kapitola je zaměřena na detailní rozbor problému detekce defektů kovových lakovaných dílů a komplexních podmínek, které je nutné v rámci detekce uvažovat. Dále je ve druhé kapitole proveden návrh nové metody, zohledňující uvedené komplexní podmínky. Ve třetí kapitole je experimentálně ověřena přesnost navržené metody detekce defektů. K

tomuto účelu je v rámci práce vytvořena nová datová množina, která je představena v úvodu třetí kapitoly. Následně jsou v kapitole uvedeny parametry měření a výsledné naměřené hodnoty. Závěr práce je věnován diskuzi, ve které jsou zhodnoceny naměřené výsledky, potenciál navržené metody z hlediska praktického využití a také uvedeny případy, kdy metoda nemusí zaručit dostatečnou přesnost.

1 Detekce anomálií

Problém kontroly kvality kovových lakovaných dílů lze z obecného pohledu datové analýzy popsat jako tzv. *detekci anomálií*, která označuje proces hledání datových instancí, neodpovídajících definovanému stavu normality [1]. V analýze dat představuje detekce anomálií již řadu let důležitý výzkumný problém s významným potenciálem pro praktické aplikace ve velkém množství oborů. Již v současnosti se techniky detekce anomálií používají např. ve finančnictví (detekce podvodných plateb), počítačové bezpečnosti (detekce neoprávněného průniku do počítačové sítě) nebo lékařství (detekce onemocnění) [2].

1.1 Základy problematiky detekce anomálií

Základní princip detekce anomálií na dvojrozměrných datech je znázorněn na obr. 1.1, kde jsou jako anomálie označeny body, které neleží uvnitř shluků představujících normální datové vzorky. Tento princip lze zobecnit také na data s více dimenzemi.

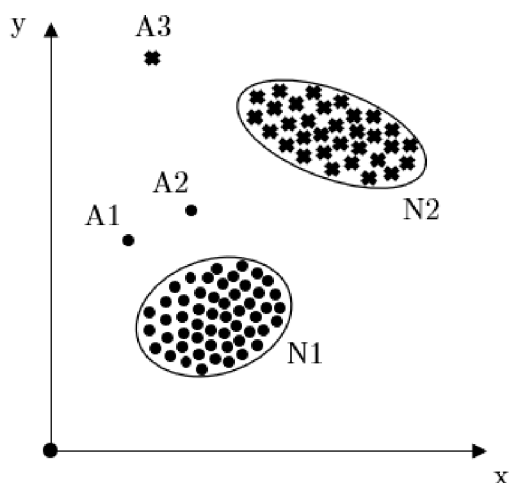
Před samotnou detekcí anomálních instancí je nutné definovat, které vzorky představují normální stav a nejsou považovány za anomálie (tzv. *normální vzorky*). V závislosti na použité metodě detekce anomálií může být normální stav popsán např. shlukem normálních vzorků, pravděpodobnostním modelem nebo veličinami využívanými v oblasti *teorie informace* (např. *entropie*). Za *anomálie* se následně označí vzorky, které se odchyľují od normálního stavu o více než stanovenou prahovou hodnotu, tedy např. mezní vzdálenost od shluku normálních vzorků, nízkou pravděpodobnost datové instance v použitém pravděpodobnostním modelu, apod. [2].

1.1.1 Složitost problému

I přes poměrně jednoduchou základní formulaci detekce anomálií může rozlišení anomálních a normálních vzorků u praktických aplikacích představovat velmi komplexní problém [6].

Prvotní důvod složitosti vyplývá z definice normálního stavu, která nemusí být jednoznačná, poté je velmi komplikované normální stav definovat tak, aby bylo zaručeno, že jsou zde zahrnuty skutečně všechny stavy, které mohou v rámci daného problému nastat. Normální stav se také může v průběhu detekce měnit, metody se na tyto změny musí adaptovat. V závislosti na konkrétní doméně může být míra odlišnosti normálního stavu a anomálie velmi rozdílná, v některých případech lze však za anomálii pokládat i velmi malou odchylku od normálního stavu. Z toho důvodu může být problematické vyvíjet univerzální techniky, které by bylo možné aplikovat na více domén.

Další důvod komplexnosti problému detekce anomálií vyplývá z povahy vstupních dat. V reálných aplikacích data typicky obsahují šum, který se může jevit jako anomálie. Množství dat dále nemusí být pro efektivní funkci detekčních metod dostatečné. Dostupná data také v mnoha případech neobsahují anotace, tím je omezeno spektrum použitelných metod, které by mohly problém detekce účinně řešit [4, 2].



Obr. 1.1: Ukázka detekce anomálií na dvojrozměrných datech. Oblasti $N1$ a $N2$ představují normální vzorky, anomálie jsou reprezentovány body $A1$, $A2$ a $A3$.

1.1.2 Anotace vstupních dat

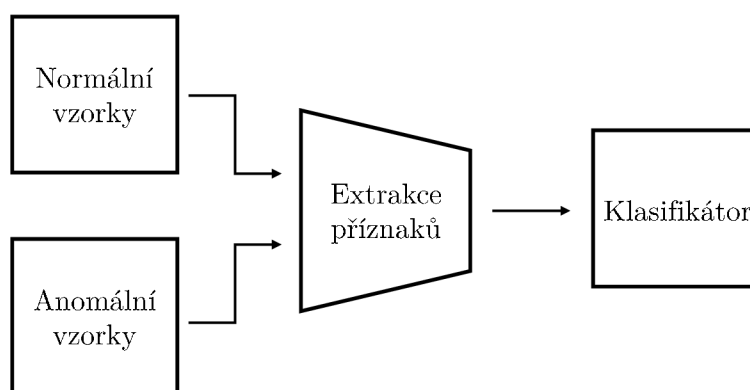
Mezi základní charakteristiky konkrétního problému detekce anomálií patří způsob anotací vstupních dat. V závislosti na tom, zda vstupní data obsahují anotace (informaci, jestli daný vzorek je *normální* či *anomální*) vznikají různá omezení pro volbu konkrétní detekční metody. Podle dostupnosti anotací u vstupních dat jsou dle [2] nejčastěji rozlišovány tři následující přístupy.

Řízené metody

Pro *řízené* (*supervised*) metody se předpokládá, že vstupní data obsahují anotace. Detekce anomálií lze následně realizovat pomocí metod založených na *řízeném učení* (*učení s učitelem, supervised learning*). Vzhledem k dostupným anotacím je tyto metody typicky jednodušší kvalitně natrénovat, výsledkem toho může také být spolehlivější funkce během nasazení metody v provozu. Hlavním nedostatkem je především nutnost anotací dat, která je obvykle časově a finančně náročná. Dále je u velké části reálných případů složité získat dostatek anomálních vzorků, tak aby podmnožina

normálních a anomálních vzorků, byli přibližně vyvážené. U řady praktických aplikací výrazně převažují *normální* vzorky, tato nevyváženost má obecně nepříznivý vliv na trénování metod, čímž se může ztížit, případně znemožnit použití *řízených* metod.

U konkrétních aplikací dále nemusí být vždy předem známé všechny typy anomálií, které se mohou během provozu vyskytnout. Pro řadu případů je naopak typické, že se během provozu mohou vyskytnout nové, předem neznámé typy anomálií. Tato skutečnost opět může znemožnit použití *řízených metod*.




Obr. 1.2: Blokové schéma trénování řízených metod

Obecný princip trénování řízených metod je znázorněn na obr. 1.2, příznaky jsou extrahovány ze známých normálních a anomálních dat. Pomocí těchto příznaků je následně trénován klasifikátor, který označuje vzorky obsahující či neobsahující anomálie.

Samořízené metody


Kategorie *samořízených* (*semi-supervised*) metod využívá data, kde jsou anotace k dispozici pouze pro normální vzorky. Metody mají následně větší potenciál pro praktické využití, při kterém je často normálních vzorků k dispozici výrazně větší množství. *Samořízené* metody se obvykle realizují pomocí modelů, které se v průběhu trénování naučí reprezentaci stavu normality (*normálních* vzorků), jak je znázorněno na obr. 1.3. Tato reprezentace může být vytvořena přímo extrahovanými příznaky, jejich statistickým zpracováním, či dalšími způsoby, které budou popsány v kapitolách 1.2.1 a 1.2.2. Během nasazení metody se jako anomálie označí vzorky neodpovídající modelu reprezentujícímu normální stav.



Obr. 1.3: Blokové schéma trénování samořízených metod

Neřízené metody

Pro *neřízené* (*unsupervised*) metody se nevyžadují žádné anotace vstupních dat. Metoda se následně trénuje na datech, kde se společně mohou nacházet normální a anomální vzorky. Pro úspěšné natrénování modelu se předpokládá, že normální vzorky jsou na vstupu ve výrazné převaze oproti anomálním vzorkům. Implementace *neřízených* metod je typicky založena na modelech využívaných pro *samořízené* metody, modely se pouze trénují na vstupních datech, které mohou obsahovat anomálie, jak lze vidět na obr. 1.4. Pro současné metody obvykle platí, že s vyšším podílem anomálií ve vstupních datech klesá schopnost efektivně rozlišovat anomálie.



Obr. 1.4: Blokové schéma trénování neřízených metod

1.2 Současné metody detekce anomálií na vizuálních datech

Kontrola kvality lakovaných kovových dílů, řešená v rámci této práce využívá vizuální vstupní data, která jsou zprostředkována systémem kamer instalovaným na výrobní lince. Metody detekce anomálií se v závislosti na typu vstupních dat mohou

významně lišit, v následující části tedy budou popsány aktuální techniky zaměřené pouze na obrazový vstup.

Problém detekce anomálií v obrazovém vstupu je typicky spojen také s problémem *segmentace anomálií*, resp. vyznačením oblastí, ve kterých se na snímku vyskytuje defekt. Tato vyznačení se obvykle realizují formou teplotní mapy, k jejímu vygenerování se nejčastěji využívá mírně modifikovaná forma modelu použitého pro detekci. Konkrétní modifikace modelu pro účely segmentace budou popsány u jednotlivých metod.

Hluboké učení pro detekci vizuálních anomálií

Techniky pro detekci anomálií na vizuálních datech zaznamenaly v posledních letech značný vývoj, související především s pronikáním *hlubokého učení* (*deep learning*) do oblasti počítačového vidění. Hluboké učení se postupně prosadilo jako velmi efektivní nástroj pro řešení dříve značně obtížných vizuálních problémů, včetně detekce anomálií [3].

Metody detekce anomálií byly (podobně jako řada dalších metod využívajících strojové učení) před nástupem *hlubokého učení* založeny především na *mělkém učení*, např. *metodě podpůrných vektorů* (*support vector machine – SVM*). Tyto přístupy však nejsou schopné optimálně zachytit komplexní strukturu vícerozměrných dat, kterými jsou např. obrazy. Pro vyšší efektivitu *mělkých* přístupů ke zpracování obrazu je tak nutné manuální extrahování příznaků, pomocí kterých se následně budou učit. Použití mělkých metod je důsledkem toho časově náročné a vyžaduje odborné znalosti pro extrahování příznaků, což představuje omezení pro rozsáhlejší nasazení těchto metod v praktických aplikacích [5].

V současných metodách je proces extrahování příznaků ze vstupních obrazových dat automatizován pomocí *hlubokých konvolučních neuronových sítí*. Extrahované příznaky se následně používají jako vstup pro model či algoritmus, který provádí detekci anomálií. Tento krok je typicky realizován pomocí obvyklých algoritmů strojového učení (např. *k*-nejbližších sousedů (*k*-NN) nebo *k*-means), pravděpodobnostních modelů nebo neuronových sítí [4].

Aktuálně nejmodernější přístupy pro detekci vizuálních anomálií lze rozdělit do dvou hlavních kategorií – rekonstrukční metody, u kterých se pro účel detekce učí neuronová síť obnovit původní vstupní obraz a metody založené na extrakci příznaků z konvoluční neuronové sítě, kde se extrahované příznaky využívají jako vstup pro algoritmus strojového učení nebo prováděpodobnostní model. Tyto dvě kategorie budou popsány v následujících podkapitolách.


1.2.1 Metody založené na rekonstrukci vstupních dat

Rekonstrukční (*reconstruction-based*) metody se pro detekci anomálií nejprve naučí rekonstruovat normální data. Následně se během detekce předpokládá, že data s anomáliemi nebude schopen model rekonstruovat, rozdíl mezi vstupním anomálním snímkem a rekonstruovaným snímkem by tak měl být výrazný. Naopak rozdíl mezi normálním vstupním snímkem a jeho rekonstrukcí by měl být minimální. Tento rozdíl vstupu a jeho rekonstrukce se přímo využije jako metrika pro rozlišení anomálií. Metriku lze označit jako *anomální skóre* A , formálně definované vztahem

$$A(\mathbf{x}) = |\mathbf{x} - G(\mathbf{x})| \quad (1.1)$$

kde G označuje použitý rekonstrukční model. Vztahem pro anomální skóre je získána dvojrozměrná mapa anomálií, kde jsou anomální oblasti reprezentovány vysokou hodnotou bodů. Mapu anomálií lze následně využít také pro klasifikaci anomálních vzorků, pro tuto operaci se obvykle uvažuje maximální hodnota mapy anomálií.

Obecný princip rekonstrukčních metod je znázorněn na obr. 1.5. K rekonstrukci vstupních obrazů se nejčastěji využívají generativní modely jako např. různé verze *autoenkodérů* (*autoencoders – AE*) nebo *generativních soupeřících sítí* (*generative adversarial networks – GAN*) [3].




Obr. 1.5: Obecné blokové schéma rekonstrukčních metod

Autoenkodéry

Mezi prvními modely využívanými pro rekonstrukce byly *autoenkodéry* [13], tato architektura je tvořena bloky označovanými *enkodér*, který tvoří vstup modelu a mapuje vstupní data do tzv. *latentního prostoru* a *dekodér*, realizující rekonstrukci dat z latentního prostoru (viz obr. 1.6).

Pro naučení užitečné reprezentace, která umožní generování vzorků se vstupní data uměle degradují např. přidáním šumu, autoenkodér se učí tyto nedostatky

odstranit a získat původní data (tzv. *denoising autoencoder*) [7]. Mezi nejzákladnější přístupy degradace dat patří přidání šumu do celého obrazu, pokročilejší metody vkládají šum pouze do specifických oblastí, případně využívají různé speciální druhy šumu [20].



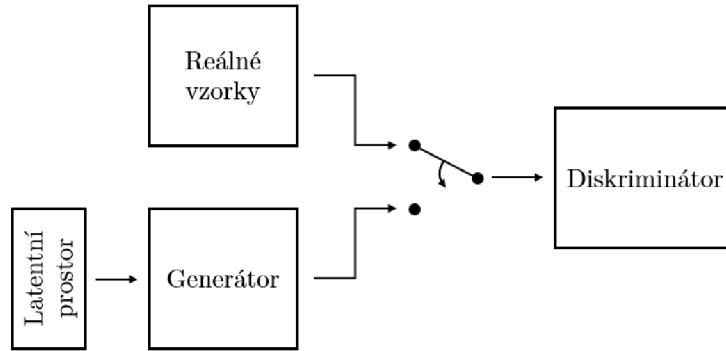
Obr. 1.6: Rekonstrukční metody s použitím autoenkodéru

Mezi nejčastěji používané varianty autoenkodéru používané v rekonstrukčních metodách patří *variální autoenkodér (VAE)*, *konvoluční autoenkodér (CAE)* [57], případně se namísto autoenkodéru využívá síť s architekturou *U-Net* [10], proces učení je shodný jako v případě použití autoenkodéru.

Metody založené na autoenkodéru jsou popsány např. v [11, 12, 14, 15]. Hlavní odlišnosti mezi uvedenými metodami obvykle spočívají ve využití různých variant autoenkodéru nebo odlišných vrstev modelu, podle kterých je vypočteno *anomální skóre*. V určitých případech je toto skóre vypočteno z reprezentací v latentním prostoru, jiné přístupy využívají rozdíl mezi rekonstrukcemi získanými *dekodérem*.

Generativní soupeřící síť

V současných rekonstrukčních metodách se obvykle využívají modely založené na *generativních soupeřících sítích*. (*generative adversarial networks – GAN*) [16]. Základní součástí architektury *GAN* tvoří *síť generátoru*, ve které je z náhodně zvoleného latentního prostoru vygenerován výstupní vzorek a *síť diskriminátoru*, kde je výstupní vzorek generátoru ohodnocen z hlediska míry podobnosti reálným datům (viz obr. 1.7). Pro detekci anomálií pomocí tohoto modelu se síť *GAN* trénuje generovat data bez anomálií. V průběhu testování se předpokládá, že síť nebude schopna generovat anomálie a skóre dle vztahu 1.1 bude výrazně vyšší pro anomální vzorky. Mezi první metody využívající *generativní soupeřící síť* pro detekci anomálií patří *AnoGAN* [8], ve které je pomocí tohoto modelu realizována detekce abnormálních oblastí na snímcích optické koherentní tomografie oční sítnice. Metoda *AnoGAN* nejprve natrénovala síť *GAN* na *normálních* vzorcích. Během testování



Obr. 1.7: Architektura generativních soupeřících sítí

se iterativně procházel latentní prostor, tak aby byl vygenerován snímek maximálně podobný vstupnímu snímku. *Anomální skóre* bylo následně stanoveno jako vážený součet rozdílu vstupního a generovaného snímku a rozdílu reprezentací vstupního a generovaného snímku získaných z *diskriminátoru* dle vztahu

$$A(\mathbf{x}) = (1 - \alpha) \cdot |\mathbf{x} - G(\mathbf{x})| + \alpha \cdot |\mathbf{f}(\mathbf{x}) - \mathbf{f}(G(\mathbf{x}))| \quad (1.2)$$

kde \mathbf{x} je vektor reprezentující vstupní snímek, G je generátor, f je výstupem vnitřní vrstvy diskriminátoru (může být zvolena libovolná vrstva) a α představuje *váhový koeficient*, kterým lze stanovit, jaký člen bude pro celkové anomální skóre upřednostněn. Obvykle se na anomálním skóre metod založených na *GAN* podílí výrazně více rozdílu vstupního a vygenerovaného vzorku (koeficient α je nejčastěji v rozsahu 0,1 až 0,02).

K hlavním nedostatkům metody *AnoGAN* patří nutnost velkého počtu iterací v průběhu testování, čímž vzniká poměrně velká časová prodleva, která pro určité praktické aplikace může představovat výrazné omezení. Následné metody inspirované *AnoGAN* ([17, 18]) proto doplňují architekturu o další modely neuronových sítí, které eliminují potřebu iterací během testování, čímž se tento proces výrazně zrychluje. Další navazující rekonstrukční metody zavádí změny v architektuře a využívají např. novější verze generativních soupeřících sítí ([59, 21]), u kterých lze docílit stabilnějšího tréninku s menším počtem trénovacích vzorků.

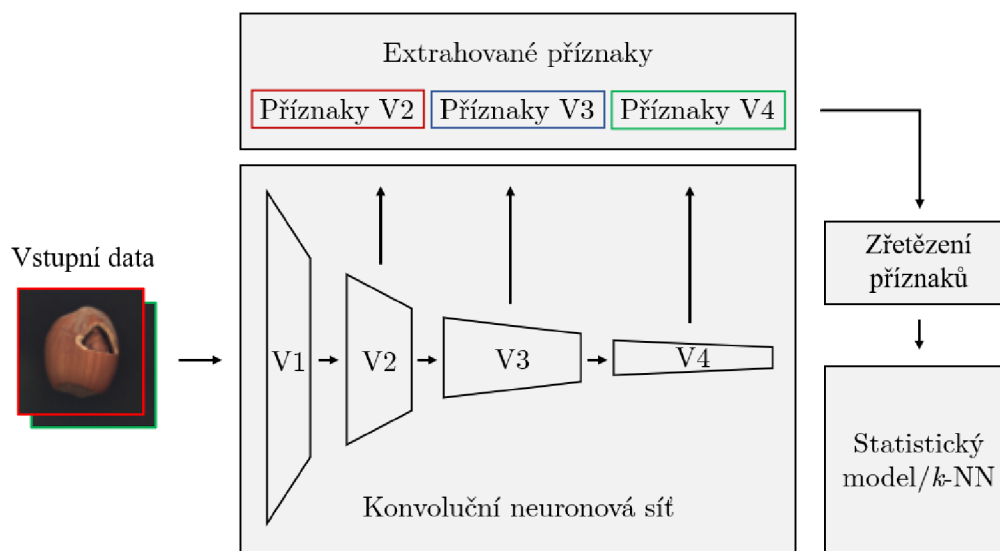
Nedostatky rekonstrukčních metod

Přestože princip rekonstrukčních metod je poměrně jednoduchý, jejich efektivnímu využití často brání schopnost generativních modelů vytvářet v některých případech vzorky s anomáliemi [34]. Následně dle vztahu 1.1 není možné dostatečně rozlišit skóre pro normální a anomální vzorky.

Generativní modely typu GAN nebo autoenkodéry dále pro naučení kvalitní reprezentace typicky vyžadují velké množství trénovacích vzorků. Při použití modelů GAN je také obvykle nutné řešit řadu problémů spojených s jejich tréninkem, který obecně může vykazovat nízkou stabilitu, v rámci trénování může docházet k tzv. *kolapsu modů*, při kterém se model nenaučí kvalitní reprezentace pro všechny třídy obsažené v trénovací datové množině. Dále je trénování modelů GAN typicky spojeno s pomalou konvergencí či příliš obecnou naučenou reprezentací trénovací množiny [60, 61].

1.2.2 Metody založené na extrakci příznaků z konvoluční neuronové sítě

Další skupina metod využívá pro detekci anomálií kombinace příznaků extrahovaných z konvoluční neuronové sítě, které jsou následně použity jako vstup do dalších typů modelů – např. tradičních algoritmů strojového učení (k -NN, k -means) nebo statistických modelů (viz obr. 1.8). Do této skupiny patří většina aktuálně nejpřesnějších metod.



Obr. 1.8: Princip metod založených na extrakci příznaků konvoluční neuronovou sítí

Pro extrakci příznaků se obvykle využívají konvoluční sítě založené na architekturách *ResNet* [23], *Wide-ResNet-50-2* [24] nebo *EfficientNet* [25]. Ve většině případů je použit model předtrénovaný na datové množině *ImageNet* [26]. Některé metody však provádí trénink modelu s náhodně inicializovanými parametry, případně využívají *jemné doladění* (*fine-tuning*) modelů předtrénovaných na množině *ImageNet*.

Mezi první publikované metody založené na extrakci příznaků patří [27], kde jsou využívány příznaky extrahované z modelu s architekturou *ResNet-18*, předtrénovaném na datové množině *ImageNet*, pro detekci defektů na mikroskopických snímcích nanomateriálů. Detekce defektů je realizována pomocí shlukové analýzy algoritmem *k-means*. Pro zkrácení času nutného na shlukovou analýzu je dimenze extrahovaných příznaků redukována metodou *analýzy hlavních komponent (principal component analysis – PCA)*.

Současné nejpřesnější metody využívající extrakci příznaků lze podle algoritmu, kterým je realizována detekce na úrovni příznaků rozdělit do kategorií uvedených v následujících podkapitolách.

Metody založené na algoritmu *k-NN*

Tato skupina metod analyzuje extrahované příznaky pomocí algoritmu *k-NN*. Mezi první práce, kde byl prezentován tento algoritmus pro detekci vizuálních anomálií patří [28], která prezentuje metodu s označením *DN2*. Metoda pro extrakci příznaků využívá model architektury *ResNet* předtrénovaný na datové množině *ImageNet*. Anomální vzorky jsou detekovány na základě průměrné euklidovské vzdálenosti testovaného vzorku od *k* nejbližších vzorků z trénovací množiny podle vztahu [28]

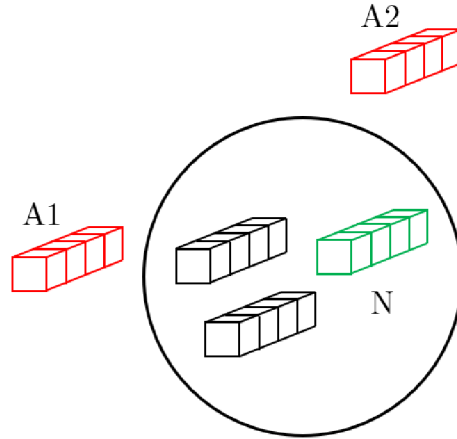
$$d(y) = \frac{1}{k} \sum_{f \in N_k(f_y)} \|f - f_y\|^2 \quad (1.3)$$

kde *y* je testovaný snímek, *f* jsou extrahované příznaky nejbližších sousedů a *f_y* extrahované příznaky testované ho snímku (viz obr. 1.9). Optimální hodnota *k* je dle experimentů provedených v práci stanovena na *k = 2*, může se však lišit v závislosti na konkrétním problému.

Uvedená metoda realizuje pouze detekci anomálií na úrovni celého snímku, není schopna anomálie na snímku segmentovat. Rozšíření metody *DN2* o segmentaci se věnuje [29], kde je prezentována metoda označovaná *SPADE*. Tato metoda v první fázi provádí detekci způsobem shodným s *DN2*, pouze vzorky označené jako anomální jsou dále zpracovány blokem, který porovnává příznaky extrahované z podoblastí vyříznutých ze vstupního snímku a referenčních trénovacích snímků.

Aktuálně nejpřesnější metoda, kde je využit algoritmus *k-NN* je označena *PatchCore* [30]. Metoda opět využívá model architektury *ResNet* předtrénovaný na datové množině *ImageNet*. Během fáze trénování jsou extrahovány a následně uloženy (do tzv. *banky*) příznaky z druhé a třetí vrstvy *ResNet* modelu. Počet příznaků uložených v bance se následně redukuje pomocí algoritmu *coreset* [31], který odstraní příznaky obsahující informaci nacházející se již v jiných podobných příznacích, čímž je pomocí nižšího počtu vzorků zachována reprezentativnost původních příznaků. Detekce anomálií na extrahovaných příznacích se následně realizuje pomocí algoritmu *k-NN*, vzhledem

k redukovanému počtu příznaků je výpočet tohoto algoritmu rychlejší v porovnání např. s metodou *SPADE* nebo *DN2*, kde je výpočetní čas lineárně závislý na počtu vzorků. Dle [30] lze využít i poměrně výraznou, stonásobnou redukci původního počtu příznaků, aniž by docházelo k výraznějšímu zhoršení přesnosti detekce anomálií.



Obr. 1.9: Schéma metod založených na algoritmu k -NN, ze vstupních dat jsou pomocí hluboké neuronové sítě extrahovány vektory příznaků, ty jsou následně porovnávány z hlediska vzdálenosti od vektorů příznaků trénovací datové množiny vzorků bez defektů (na obr. vyznačeny černou barvou). V případě, že vzdálenost vektorů příznaků vstupních dat přesahuje určitý práh, jsou vzorky označeny jako anomální (na obr. vektory *A1* a *A2*).

Metody založené na pravděpodobnostním modelu

Metody v této kategorii pro detekci anomálií využívají modelování datové množiny pomocí rozložení pravděpodobnosti. Toto rozdělení může být stanoveno tradičními metodami nebo s využitím modelů hlubokých neuronových sítí.


K základním postupům metod z této kategorie patří výpočet *vícerozměrného normálního rozdělení* odpovídajícímu trénovacím vzorkům bez anomálií, které je dáno vztahem

$$\phi_{\mu, \Sigma}(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^d |\det \Sigma|}} e^{-\frac{1}{2}(\mathbf{x}-\mu)^T \Sigma^{-1}(\mathbf{x}-\mu)} \quad (1.4)$$

kde \mathbf{x} je vstupní vektor, μ je vektor středních hodnot a Σ je kovarianční matice [34]. Během testování se anomálie stanoví výpočtem *Mahalanobisovy vzdálenosti* [35] testovacího vzorku od pravděpodobnostního rozdělení trénovacích dat. Vzorky přesahující určitou prahovou vzdálenost jsou vyhodnoceny jako anomální. Ekvivalentní

alternativou výpočtu *Mahalanobisovy vzdálenosti* je v tomto případě také výpočet logaritmu vztahu pro *vícerozměrné normální rozdělení (log-likelihood)* [4]. Pokud pro testovaný vzorek bude vypočtena nízká hodnota pravděpodobnosti pro dané rozdělení, bude označen jako anomální. Příklad modelování dvourozměrné datové množiny pomocí gaussovského rozložení je znázorněn na obr. 1.10.

Mezi aktuálně nejpřesnější metody využívající *vícerozměrné normální rozdělení* patří např. *Gaussian-AD* [33] a *PaDiM* [34] (který rozšiřuje předchozí metodu o schopnost segmentace anomálií). Obě uvedené metody pro extrakci příznaků používají modely s architekturou *ResNet* nebo *EfficientNet* předtrénované na datové množině *ImageNet*. Dále k metodám do skupiny metod využívajících *normální rozdělení* patří tzv. *CutPaste* [32], kde se oproti předchozím metodám nevyužívá předtrénovaný model, ale síť je natrénována na pomoci samořízeného učení a speciálně navržené úlohy, která bude popsána v následující podkapitole.



Obr. 1.10: Ukázka detekce anomálií pomocí dvourozměrného gaussovského rozdělení, normální data uvnitř zelené oblasti jsou modelovány gaussovským rozdělením, jako anomálie (červené body) jsou označena data, která přesahují stanovenou vzdálenost od daného gaussovského rozdělení.

Přímé modelování distribuce trénovacích dat pomocí *normálního rozdělení* nemusí být vždy z hlediska detekce anomálií vhodné. V řadě případů může být skutečná rozdělení dat výrazně komplexnější [4, 36]. Proto některé metody detekce anomálií využívají tzv. normalizační sítě *normalizing flows*, které pomocí vícenásobných invertibilních transformací vytvářejí zobrazení komplexního rozdělení extrahovaných příznaků na jednodušší a známé (např. normální) rozdělení. Detekce anomálií se


následně provádí v rámci tohoto jednoduššího rozdělení např. výpočtem *Mahalanobisovy vzdálenosti*.

Využití normalizačních sítí pro detekci anomálií na vizuálních datech bylo poprvé prezentováno v metodě *DifferNet* [36], na tento přístup navazují také metody *CFLOW-AD* [37], *CS-FLOW* [38] a *FastFlow* [39], které přidávají možnost segmentace anomálií.

Samořízené učení modelů pro detekci anomálií

Většina zde uvedených metod detekce anomálií používala pro extrakci příznaků modely předtrénované na datové množině *ImageNet*. V řadě praktických problémů detekce anomálií často není možné získat velké množství trénovacích dat, které by bylo možné využít pro efektivní učení modelů neuronové sítě. Předtrénované modely proto nabízí účinnou alternativu, pomocí které je možné extrahovat příznaky využitelné pro detekci anomálií. Zároveň se dle aktuálních publikací [30, 34, 33, 37] ukazuje, že lze tímto přístupem dosáhnout velmi kvalitních výsledků.

Dalším způsobem, který také některé ze současných metod [32, 40] využívají je trénování vlastního modelu pro extrakci příznaků od začátku, s náhodně inicializovanými parametry. Pro trénování sítě se využívá úloha speciálně navržená tak, aby se model naučil užitečné reprezentace, využitelné při detekci anomálií. Trénovací úlohou může být např. predikce rotace [41] nebo dalších geometrických transformací [42] vstupních snímků, dále úloha může být realizována jako klasifikace dvou či více uměle vytvořených tříd. Tento přístup se využívá např. u metody *CutPaste* [32], kde se u části vstupních snímků vybere náhodná podoblast, která je následně vložena opět na náhodně zvolené místo uvnitř snímku, čímž se simuluje anomální (defektní) vzorek (viz obr. 1.11). Model má následně klasifikovat, které snímky obsahují či neobsahují tyto umělé defekty. Výsledky této metody ukazují, že lze dosahovat přesnosti srovnatelné s metodami využívajícími modely předtrénované na datové množině *ImageNet*.



Obr. 1.11: Ukázka metody pro samořízené učení *CutPaste*

Metoda *CutPaste* dále svůj přístup generování anomálních snímků porovnává s jinými způsoby, založenými např. na vkládání barevné plochy do náhodných podoblastí snímku (*Confetti Noise* [43]) či smazání náhodně zvolené podoblasti (*Cutout* [44]). Umělé defekty generované těmito metodami však nejsou tak blízké skutečným defektům v porovnání s metodou *CutPaste* a dle prezentovaných výsledků [32] má tato skutečnost výrazný vliv na výslednou přesnost modelu v detekci anomálií. Na základě těchto výsledků tak lze hypoteticky uvažovat, že pokud budou umělé defekty více blízké defektům, které se v dané doméně skutečně mohou vyskytovat, bude se zvyšovat přesnost detekce. Tato hypotéza je experimentálně ověřena a podrobněji popsána v kapitole 2.

1.2.3 Srovnání metod

Pro ilustraci přesnosti současných metod detekce defektů je v tab. 1.1 uvedeno srovnání výsledků naměřených s využitím metriky *AUROC* [58] na úrovni celých snímků a datové množiny *MVTec-AD* (viz kap. 1.3). Tato veřejně dostupná množina je zaměřena na problematiku detekce defektů v průmyslových aplikacích a v určitých aspektech se přibližuje problému řešenému v rámci této práce.

Z výsledků lze pro většinu případů pozorovat vyšší přesnost u metod založených na extrakci příznaků z konvoluční neuronové sítě. Některé metody [20] založené na rekonstrukčním principu však dosahují srovnatelných výsledků. Aktuálně nejpresnější na datové množině *MVTec-AD* je metoda *PatchCore* [30] a následně *CFLOW-AD* [37].

Druh metody	Název metody	Princip detekce anomálií	MVTec AUC
rekonstrukční	DRAEM	-	98,00 [20]
	Skip-GANomaly		80,52 [59]
	GANomaly		78,19 [59]
	AnoGAN		50,29 [59]
extrakce příznaků	PatchCore	k -NN	99,10 [30]
	SPADE		85,50 [29]
	Gaussian-AD	Gaussovské rozdělení	95,80 [33]
	PaDiM		97,90 [34]
	CutPaste		97,10 [32]
CFLOW-AD	normalizační síť	98,26 [37]	

Tab. 1.1: Porovnání současných metod detekce anomálií


Jedná se o metody založené na extrakci příznaků z modelu konvoluční neuronové sítě *ResNet* předtrénovaného na datové množině *ImageNet*. Podobně předtrénovaný

model na množině *ImageNet* používají pro extrakci příznaků i ostatní metody uvedené v tabulce. Většina metod předtrénovaný model nechává beze změny a může se lišit pouze ve volbě konkrétních konvolučních vrstev, ze kterých jsou příznaky převzaty. Výjimku tvoří metoda *CutPaste*, u které je předtrénovaný model použit pouze pro nastavení počátečních hodnot parametrů, které jsou dále dotrénovány s využitím trénovacího postupu *CutPaste* (viz kap. 1.2.2). V případě, že trénování pomocí *CutPaste* probíhá na modelu s náhodně inicializovanými parametry, dosažená přesnost není příliš odlišná (96,1 *AUC* [32]). Nelze tedy jednoznačně konstatovat, který z přístupů převažuje, v současných publikacích je však obvykle využíván model předtrénovaný na množině *ImageNet* bez dalších úprav.

Většina uvedených rekonstrukčních metod v porovnání s metodami využívajícími extrahované příznaky dosahuje poměrně nízké přesnosti. Přesto však některé z přístupů (např. *DRAEM*) mohou dosahovat velmi podobných výsledků. Také z tohoto důvodu rekonstrukční metody stále patří k přístupům, kterým je v současné literatuře v této oblasti věnována pozornost [62, 63].

1.3 Datové množiny pro detekci anomálií v průmyslových aplikacích

K hodnocení metod z hlediska přesnosti detekce anomálií byly tradičně využívány standardní datové množiny obecně známé i v dalších oblastech počítačového vidění (např. *MNIST* [45] nebo *CIFAR-10* [46]), u kterých se jedna ze tříd zvolila jako normální a ostatní byly považovány za anomálie. Přestože se s tímto přístupem lze setkat i v současnosti, stále častěji je porovnání nových metod realizováno také s využitím datových množin zaměřených speciálně na problematiku detekce defektů v konkrétních praktických aplikacích. Mezi nejvíce používané datové množiny z této skupiny patří *MVTec-AD* (*MVTec Anomaly Detection Dataset*) [6], ve které je k dispozici 10 tříd objektů a 5 tříd textur vycházejících z běžných průmyslových aplikací. Přesný počet vzorků pro jednotlivé třídy v datové množině je uveden v tab. 1.2, ukázka vzorků z datové množiny je na obr. 1.12. Ve třídách objektů se nachází např. výrobky z elektrotechnického průmyslu (elektroinstalační kabel), potravinářství (lískový ořech) nebo zdravotnictví (tablety s léčivý). Objekty jsou na snímku vždy zachyceny celé a typicky jsou také zarovnané na střed snímku. Třídy v kategorii textur obsahují výrobky, které jsou charakteristické opakujícím se vzorem, např. kovová mřížka, kobercová tkanina nebo dřevěné desky. Rozměry snímků v datové množině se pohybují v rozsahu od 700×700 do 1024×1024 pixelů. Součástí datové množiny jsou také segmentační masky defektů, pomocí kterých je možné hodnotit metody také z hlediska lokalizace anomálií.



Obr. 1.12: Ukázka vzorků datové množiny MVTec AD, v horní řadě jsou zobrazeny vzorky bez defektu, spodní řadu tvoří vzorky s vyznačeným defektem. Vzorky v prvních třech sloupcích zleva pochází z kategorie objektů, zbývající vzorky jsou z kategorie textur.


Datová množina *MVTec-AD* obsaženými třídami pokrývá poměrně široké spektrum výrobků z různých průmyslových odvětví. Způsob, kterým jsou snímky pořízeny (zarovnání na střed, objekty celé obsaženy ve snímku) však nemusí být v řadě reálných aplikací (např. kvůli podmínkám dané výroby) dosažitelný.

	Třída	Trénovací vzorky	Testovací vzorky normální	Testovací vzorky defektní
Textury	Carpet	280	28	89
	Grid	264	21	57
	Leather	245	32	92
	Tile	230	33	84
	Wood	247	19	60
Objekty	Bottle	209	20	63
	Cable	224	58	92
	Capsule	219	23	109
	Hazelnut	391	40	70
	Metal Nut	220	22	93
	Pill	267	26	141
	Screw	320	41	119
	Toothbrush	60	12	30
	Transistor	213	60	40
	Zipper	240	32	117
	Total	3629	467	1258

Tab. 1.2: Počty trénovacích a testovacích vzorků pro jednotlivé třídy v datové množině MVTec-AD [6]

Mezi další datové množiny zaměřené na problematiku detekce defektů v prů-

myslových aplikacích patří např. *Kolektor SDD* [47], ve které jsou obsaženy snímky komutátorů elektrických motorů a segmentační masky defektů. Dále je veřejně dostupná také datová množina *Kolektor SDD2* [48], která obsahuje v porovnání s první verzí datové množiny *Kolektor* větší množství snímků (celkem 3335). Jako další datovou množinu z průmyslového prostředí lze zmínit *Magnetic Tile Defects Dataset* [49], která zachycuje defekty na povrchu magnetických plátů, množina opět obsahuje také segmentační masky defektů. Pro uvedené datové množiny (*Kolektor SDD*, *Kolektor SDD2* a *Magnetic Tile Defects Dataset*) platí, že na snímcích jsou zachyceny pouze povrchy. Problém řešený v rámci těchto datových množin je tedy podobný jako pro kategorii textur množiny *MVTec-AD*, naopak problém řešený u kategorie objektů *MVTec-AD* v uvedených datových množinách reprezentován není. Jako příklad, který podobně jako *MVTec-AD* také obsahuje snímky s objekty lze uvést datovou množinu *BeanTech Anomaly Detection Dataset* [51], ve které jsou obsaženy dvě třídy zachycující objekty a jedna třída tvořená snímky povrchu dřevěných panelů. Oproti *MVTec-AD* nabízí tato datová množina větší počet vzorků na jednotlivé třídy.



Obr. 1.13: Ukázka vzorků datové množiny *Kolektor SDD*, zeleně ohraničené snímky jsou bez defektu, snímky s vyznačeným defektem jsou ohraničené červeně.

Mezi další používané množiny pro detekce anomálií patří *Shanghai Tech Campus Dataset* [50], která nevychází z průmyslového prostředí, ale obsahuje kamerové záznamy z veřejných míst, kde se za anomálie považuje nestandardní nebo zakázané chování na veřejném prostoru (např. jízda motocyklu po chodníku). Přestože, datová množina neobsahuje vzorky z průmyslových aplikací, využívá se také poměrně často v současných publikacích zaměřených na detekci anomálií.

Pro uvedené datové množiny typicky platí, že se zaměřují na konkrétní doménu

a obsahují oproti *MVTec-AD* výrazně nižší počet tříd. V aktuálních publikacích se proto metody nejčastěji testují především na datové množině *MVTec-AD* a případně pro doplnění také na některé z uvedených množin. Popsané datové množiny jsou si také poměrně blízké z hlediska složitosti problému, který zachycují. Žádná z množin např. neobsahuje snímky ze závěsného dopravníku, který je využíván v řadě typů průmyslové výroby, a kde mohou být podmínky pro detekci anomálií odlišné a komplexnější. Celkově tedy s pomocí veřejně dostupných datových množin není možné modelovat poměrně významnou část aktuálních průmyslových aplikací, tvorba nových datových množin v této oblasti tak představuje jednu z možností přispění k současnému stavu vědy a techniky.

1.4 Kontrola kvality kovových dílů pomocí metod detekce anomálií

V současné době je obecně řešení problému detekce defektů v průmyslových aplikacích pomocí hlubokých neuronových sítí věnováno poměrně významné množství publikací ([64, 65, 66, 67]). Na oblast defektů u kovových dílů se specificky zaměřují např. metody prezentované v [52] a [53], kde autoři využívají hluboké neuronové sítě pro detekci povrchových závad na hliníkových profilech. Obě publikace jsou však oproti problému řešenému v této práci založené na učení s učitelem, v rámci trénování prezentovaných metod se tak využívají data z kategorie vzorků bez defektů a vzorků s defektem. Přestože metody pro svou funkci nevyžadují velký počet vzorků s defekty, je nutné mít při jejich aplikaci určitý počet těchto vzorků k dispozici. Což se u problému řešeném v této práci nepředpokládá, že bude možné.

Podobně byly hluboké neuronové sítě využity v [54] pro detekci defektů na lisovaných kovových součástkách. I v tomto případě byla metoda založena na učení s učitelem a vyžadovala pro trénování normální i defektní vzorky.

Využití strojového učení bez učitele pro detekci defektů na kovových součástkách pro automobilový průmysl je prezentováno v [55], kde je detekce realizována pomocí autoenkodéru a je založena na principu rekonstrukčních metod. V porovnání s problémem řešeným v rámci této práce však obsahují vstupní snímky výrazně nižší variabilitu z hlediska polohy a rotace dílů na jednotlivých snímcích.

Jak vyplývá z uvedených příkladů, lze v současných publikacích nalézt řadu případů využití hlubokých neuronových sítí v oblasti detekce defektů při výrobě kovových dílů. Oproti problému řešenému v této práci však publikace vykazují množství odlišností, mezi které patří především nižší variabilita dat z hlediska polohy dílů vůči snímacímu zařízení a také nízký počet trénovacích vzorků, jak bude podrobněji popsáno v kap. 3.

2 Návrh nové metody detekce anomálií

Přestože do současné doby byla publikována již řada detekčních metod s kvalitními výsledky měřenými např. na datové množině *MVTec-AD*, jak bude uvedeno v kapitole 3, nemusí být podobné výsledky vždy dosažitelné pokud je metoda aplikována na nový typ problému, který se do určité míry odlišuje od množiny *MVTec-AD*. Problém řešený v této práci obsahuje oproti této množině řadu odlišností, v této kapitole proto bude navržena metoda nejvhodnější právě k řešenému problému.

2.1 Specifikace požadavků na výsledný systém

Cílem metody navržené v této práci je automatická detekce různých typů defektů při výstupní kontrole v rámci výroby lakovaných kovových dílů. Tato kontrola bude probíhat v posledních fázích výrobního procesu, kdy se díly nachází v chladícím tunelu poté co na nich byla vypálena prášková barva. Po provedení kontroly budou díly odebrány z dopravníku a zabaleny k expedici.

Variabilita při snímání

Součástky na snímku mohou vykazovat poměrně vysokou variabilitu v poloze a natočení (viz obr. 2.1), což obvykle není v současných datových množinách na detekci defektů příliš zohledněno. Prostředí pro pořízení snímku kvůli omezenému prostoru dále neumožňuje používání komplexnějšího systému osvětlení, který by zajistil kvalitní a stabilní světelné podmínky. Součástky tak mohou být zachyceny také včetně nežádoucích odlesků případně stínů způsobených pohybem obsluhy v okolí snímací kamery.

Typ a počet součástek, které se mohou objevit při výrobě není předem obvykle možné přesně stanovit. Počet dílů ve vyráběné sérii se může lišit. Tvar, velikost a celková složitost dílů je závislá na požadavcích zákazníků a může se také výrazně odlišovat.

Typy defektů

Typy defektů budou známy pouze částečně, výrobce dílů předem slovním popisem stanoví, které druhy defektů se nejčastěji v provozu objevují, jaká je jejich závažnost a zda je možné je zanedbat. Pro trénování metody ale většinou nebudou k dispozici snímky s defekty vůbec případně pouze v omezeném počtu, nebude proto možné využít řízené (*supervised*) metody, které jsou v případě nevyváženého počtu normálních a anomálních vzorků méně účinné. Dále by se účinnost *řízených* metod snižovala pokud by se v rámci výroby objevily nové defekty, které nebyly přítomné v




Obr. 2.1: Příklad změn polohy a natočení dílů na vstupních snímcích

trénovací množině. Použité metody tedy budou založeny na principu *samořízených* (*semi-supervised*) nebo *neřízených* (*unsupervised*) metod, které budou trénovány na množině s normálními vzorky (*semi-supervised*) případně množině obsahující pouze malý počet defektních vzorků (*unsupervised*). Tímto způsobem bude zachycen stav normálních vzorků a metoda následně bude moct odlišit libovolný a tedy i nový, dříve neobjevený typ defektu.

Velikost datové množiny

Počet vzorků pro trénování a testování metody se bude obvykle pro jednotlivé typy součástek lišit. V případě dílů vyráběných v malých sériích bude možné očekávat i velmi nízký počet trénovacích dat, metoda by však i přesto měla stále vykazovat dostatečnou schopnost detekce defektů.

Pokud se uvažuje celkový počet snímků, které lze v průběhu provozu získat, může být velikost datové množiny výrazně vyšší. Přestože v této datové množině budou obsaženy různé typy dílů, bude možné ji využít např. k prvotnímu natrénování modelu pro extrakci rysů pomocí samořízeného učení (podobně jako jsou modely předtrénovány např. na datové množině *ImageNet*).



Obr. 2.2: Ukázka typů defektů


Požadavky na rychlost detekce

Případný defekt musí být signalizován do doby, než budou díly odebrány z dopravníku, aby bylo možné vyřadit defektní díly. Konkrétní časový interval v rámci kterého musí použitá metoda detekci realizovat se může lišit v závislosti na velikosti dílů, rychlosti dopravníku a rychlosti obsluhy provádějící odebrání dílu, většinou však budou pro výpočet algoritmu k dispozici časové intervaly v řádu jednotek až desítek sekund, což musí být zohledněno při celkové výpočetní náročnosti navržené metody.

2.2 Navržená metoda


Metoda navržená v rámci této práce je založena na samořízeném učení konvoluční neuronové sítě s architekturou *ResNet-18* pomocí nově navržené metody generování syntetických defektů. Natrénovaný model je následně použit pro extrakci příznaků, na kterých je realizována samotná detekce defektů. Obecný postup pro detekci defektů pomocí extrahovaných příznaků je znázorněn na obr. 1.8. Princip detekce vychází z metody pravděpodobnostního modelu (viz kapitola 1.2.2), pomocí příznaků normálních vzorků je vypočtena hustota pravděpodobnosti reprezentující normální stav. Defekty jsou následně detekovány podle *Mahalanobisovy vzdálenosti* extrahovaných příznaků vstupního snímku od hustoty pravděpodobnosti normálních příznaků.

Proces trénování modelu pro extrakci příznaků je znázorněn na obr. 2.3. Trénovací data jsou náhodně (s pravděpodobností 0,5) ponechána beze změny nebo znehodnocena synteticky vygenerovaným defektem. Model složený z konvoluční neuronové sítě a vícevrstvého perceptronu se následně učí klasifikovat vzorky s vygenerovaným defektem či bez defektu. Pomocí úkolu klasifikace těchto dvou tříd se model naučí parametry, se kterými je následně schopen extrahovat příznaky vhodné pro detekci defektů na testovacích datech. Proces trénování modelu pro extrakci příznaků je podrobně popsán v kap. 2.2.2. Hlavní součástí, která byla pro tuto metodu nově navržena představuje generátor syntetických defektů, který je detailně popsán v kap. 2.2.1 (na obr. 2.3 označen modře).



Obr. 2.3: Blokové schéma trénování modelu pro extrakci příznaků

Postup detekce defektů na testovacích datech je znázorněn na obr. 2.4. Pro účely detekce se z původního modelu převezme pouze blok *ResNet-18*, vícevrstvý perceptron a klasifikátor jsou odstraněny. Pomocí natrénovaného modelu *ResNet-18* jsou ze vstupních dat extrahovány příznaky, které jsou pomocí *Gaussovského statistického modelu* porovnány s referenčním normálním stavem. Statistickým modelem je získáno skóre, podle kterého je následně stanoveno, zda data obsahují defekt (v případě, že je překročena rozhodovací prahová hodnota).



Obr. 2.4: Blokové schéma detekce defektů pomocí extrahovaných příznaků

2.2.1 Syntetické defekty

Metoda generování syntetických defektů je inspirována publikacemi [32, 44, 43], kde je demonstrována účinnost modelů naučených pomocí umělých defektů pro účel detekce anomálií. Zde prezentovaná metoda předchozí postupy rozšiřuje tak, aby vzhled syntetických defektů byl bližší skutečným defektům, na které lze v rámci dané domény narazit. Základním předpokladem pro účinnost této metody je hypotéza, že model je schopen naučit se extrahovat kvalitnější příznaky pro detekci defektů, pokud bude trénován na defektech bližších skutečným defektům.

Segmentace kovového dílu a pozadí

Pro vytvoření defektních vzorků jsou využity normální snímky z trénovací sady. Prvním krokem je segmentace zachycené součástky a pozadí, aby bylo možné defekty vkládat pouze do oblasti, kde se nachází kovová součástka a ne do pozadí, na kterém defekty není žádoucí detekovat. Segmentace je realizována pomocí jednoduchého prahování snímku, kde výsledná segmentace je získána podle vztahu

$$\begin{aligned} f(x, y) &= 0, & \text{pro } f(x, y) > T \\ f(x, y) &= 255, & \text{pro } f(x, y) \leq T \end{aligned} \quad (2.1)$$

kde x a y jsou souřadnice pixelu a T je zvolený práh. Vstupní snímky jsou před samotným prahováním převedeny na stupně šedi.

Pokud povrch dílu na snímku vykazuje určitou barevnou podobnost s pozadím, budou tyto plochy klasifikovány jako pozadí a nebude tak získána segmentační maska celého dílu, pouze např. obrys dílu. Z toho důvodu se pixely na pozadí prahovaného snímku nastaví na hodnotu 255 pomocí algoritmu *flood fill* [56]. Následně se na takto upraveném snímku provede inverze barev. Výsledná segmentační maska je získána logickým součtem pixelů prahovaného snímku a snímku, který byl upraven prahováním, algoritmem *flood fill* a inverzí barev (viz obr. 2.5).




Obr. 2.5: Postup segmentace kovového dílu a pozadí

Generování defektů

Pro generování defektu se ze snímku vybere náhodná obdélníková podoblast, počátek výběru této podoblasti je vybrán z pixelů, která byly v předchozím kroku segmentovány jako kovový díl. Maximální a minimální velikost vybrané podoblasti je omezena, tak aby bylo možné se lépe přiblížit skutečnému defektu. Vybraná podoblast je následně zpracována blokem, který na obraz aplikuje *Gaussovský šum*. Dále je náhodně vybrána nová podoblast (její počátek je opět vybrán z pixelů klasifikovaných jako kovový díl), na kterou je předchozí upravená podoblast vložena.

Vložení podoblasti do původního snímku vznikají viditelné nespojité přechody na okrajích dané podoblasti. Proto do *alfa kanálu* vložené podoblasti přidá náhodně vybraná maska z předem připravené databáze, čímž vzniknou plynulé přechody, které lépe napodobují skutečné defekty. Posledním krokem je logický součin alfa kanálu vložené podoblasti provede se segmentační maskou kovového dílu, tím je zajištěno, aby plocha, na které se umělý defekt nachází, byla omezena pouze na plochu dílu a defekt se nenacházel na pozadí (viz obr. 2.6).


Velikost generovaných defektů se v průběhu trénování zmenšuje. Na počátku trénování je velikost defektů vyšší, aby se model rychleji adaptoval na trénovaný úkol. Poté se do uplynutí stanoveného počtu epoch velikost defektů lineárně snižuje, po dosažení dané epochy se následně již velikost nemění. Nastavení vhodných hranic minimální a maximální velikosti defektů bylo provedeno zvlášť pro každou třídu, aby defekty u dané třídy působily věrným dojmem.



Obr. 2.6: Ukázka syntetických defektů na snímcích v odstínech šedé

Ukázka výsledných generovaných defektů popsanou metodou pro kovové díly černé a bílé barvy je znázorněna na obr. 2.6. Pro porovnání s jinými metodami generování defektů je na obr. 2.7 ukázán výsledek generování defektů pro stejné vzorky pomocí metody *CutPaste*. Z ukázek lze pozorovat, že syntetické defekty vytvořené pomocí nově navržené metody se více blíží defektům, které lze v případě výroby kovových lakovaných dílů skutečně předpokládat. U defektů generovaných metodou *CutPaste* se objevují ostré nespojitosti na hranici defektu a dále není zaručeno, že defekt nebude vložen do oblasti pozadí kovového dílu, na kterém však detekce defektů během nasazení metody není žádoucí.

Defekty generované pomocí navržené metody na barevných snímcích datové množiny vytvořené v rámci této práce jsou znázorněny na obr. 2.8.




Obr. 2.7: Ukázka syntetických defektů vytvořených pomocí metody *CutPaste*

2.2.2 Trénování modelu a detekce defektních vzorků

Trénování modelu

Trénovací data po vygenerování syntetických defektů obsahují dvě třídy anotované podle následujícího vztahu

$$y = \begin{cases} 1, & \text{pro } x = DG(x_{in}) \\ 0, & \text{pro } x = x_{in} \end{cases} \quad (2.2)$$



Obr. 2.8: Ukázka syntetických defektů na barevných snímcích

kde x_{in} je snímek z trénovací množiny normálních dat a DG generátor defektů. V trénovacích dávkách (*batches*) se normální a anomální snímky nachází ve stejném poměru. Dávky snímků a anotací jsou přivedeny na vstup binárního klasifikátoru tvořeného konvoluční neuronovou sítí, optimalizace parametrů klasifikátoru je realizována na základě objektivní funkce ℓ dané vztahem

$$\ell = \mathbb{E}_{\mathbf{x} \sim \chi} \{ \text{CE}(g(\mathbf{x}), 0) + \text{CE}(g(DG(\mathbf{x})), 1) \} \quad (2.3)$$

kde \mathbb{E} je *střední hodnota* [57], CE ztrátová funkce známá jako *binární křížová entropie*, χ vstupní datová množina, \mathbf{x} vstupní vzorek a $g(x)$ výstup binárního klasifikátoru. Hlavním cílem optimalizace tedy je učení klasifikátoru správně rozlišit vzorky bez defektu a vzorky s uměle vytvořeným defektem.

Po ukončení trénování je model natrénované neuronové sítě použit pro extrakci příznaků, které jsou použity pro detekci defektních vzorků. Navržená metoda využívá příznaky extrahované z poslední konvoluční vrstvy použité architektury *ResNet-18*, tedy bezprostředně před posledním klasifikačním blokem tvořeným sérií plně propojených vrstev.

Detekce defektů

Před testováním defektních vzorků je provedena extrakce příznaků všech normálních trénovacích snímků. Tyto příznaky jsou následně modelovány pomocí *vícerozměrného normálního rozdělení* dle vztahu 1.4, kde jsou využity pro výpočet střední hod-

noty μ a kovarianční matice Σ . Během testování jsou defektní snímky detekovány na základě výpočtu logaritmu vztahu pro hustotu normálního rozdělení $p(x)$ [32]

$$\log p(x) \sim -\frac{1}{2}(g(x) - \mu)^T \Sigma^{-1}(g(x) - \mu) \quad (2.4)$$

kde $g(x)$ jsou extrahované příznaky. Vzorky s hodnotou pravděpodobnosti pod stanoveným prahem jsou označeny jako defektní.

2.2.3 Architektura konvoluční sítě ResNet

Architektura *ResNet* patří v současnosti mezi nejpoužívanější typy hlubokých konvolučních neuronových sítí a standardně se využívá také v aktuálních publikacích zaměřených na oblast detekce anomálií. Představení *ResNet* architektury a s ní souvisejících technik v roce 2015 umožnilo výrazně zvýšit hloubku neuronových sítí, aniž by docházelo k degradaci naučené reprezentace. Nově tak bylo možné trénovat síť tvořené např. stovkami vrstev [23].

S vyšším počtem vrstev může typicky dojít k *přeučení* modelu či *mizení gradientu* [57]. Jedním z hlavních funkčních bloků, který umožňuje výraznou hloubku *ResNet* architektury, aniž by docházelo k uvedeným jevům je tzv. *reziduální modul s přeskokovými spojeními*, který je znázorněn na obr. 2.9. S využitím tohoto bloku se uvnitř sítě v určitých bodech tok dat rozdělí do dvou paralelních větví, kde jedna větev (přeskový spoj) přeskočí daný počet vrstev sítě a je následně sečtena s druhou větví (hlavní cestou). Po součtu jsou data zpracována vrstvou typu *ReLU*. Výsledný tenzor y , tak jak je znázorněno na obr. 2.9 lze popsat vztahem

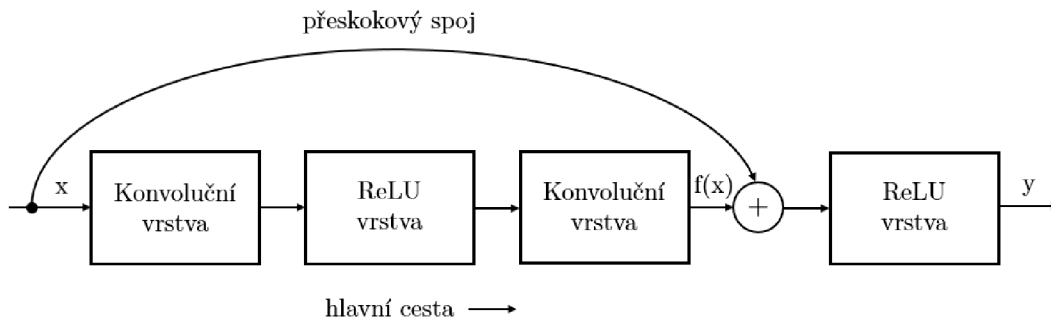
$$y = \text{ReLU}[f(x) + x] \quad (2.5)$$

kde x je tenzor z *přeskokového spoje* a $f(x)$ výstupní tenzor hlavní cesty. Použitím *přeskokových spojů* lze lépe předejít *mizení gradientu*, protože gradient při *zpětné propagaci* řadu vrstev přeskočí a nedojde k jeho snížení na hodnotu, pomocí které již nelze model efektivně učit.

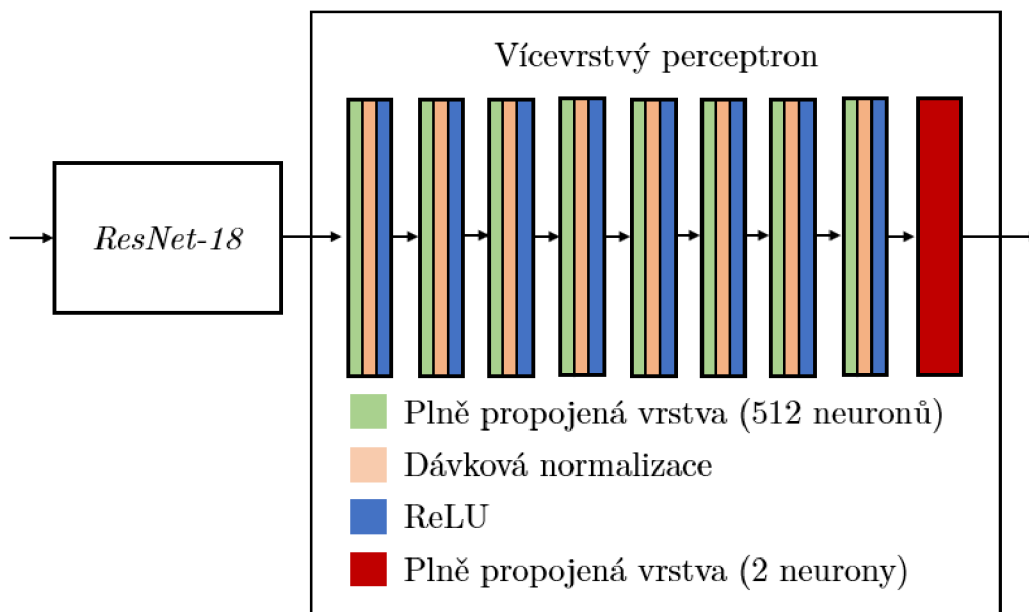
Celková architektura použitého modelu

Kompletní schéma architektury použitého modelu je znázorněné na obr. 2.10. První blok tvoří model architektury *ResNet-18*, ze kterého je pouze vyjmuta poslední plně propojená vrstva, výstupem bloku jsou tedy data z poslední konvoluční vrstvy.

Po zpracování blokem *ResNet* jsou data zpracována v bloku *vícevrstvého perceptronu*, tento blok je tvořen osmi jednotkami, které se skládají z plně propojené vrstvy o 512 neuronech, vrstvy pro dávkovou normalizaci (*batch normalization*) a vrstvy *ReLU*. Posledním blokem *vícevrstvého perceptronu* je plně propojená vrstva o dvou neuronech, pomocí které se provádí klasifikace normálních a defektních vzorků.



Obr. 2.9: Blokové schéma *reziduálního modulu* v architektuře *ResNet*



Obr. 2.10: Blokové schéma kompletní architektury použitého modelu

Uvedené schéma modelu se u navržené metody detekce defektů využívá pouze ve fázi trénování. Pro samotnou detekci defektů se z modelu převezme pouze blok *ResNet* a defekty jsou detekovány na úrovni příznaků extrahovaných tímto natrénovaným blokem.

3 Experiment

Pro ověření přesnosti detekce navržené metody byla vytvořena vlastní datová množina lakovaných kovových dílů, kde jsou zachyceny podmínky reálného provozu, ve kterém má být metoda využívána. Následně je na vytvořené datové množině provedeno experimentální měření navržené metody a také několika vybraných současných metod, které aktuálně patří mezi nejpřesnější metody detekce na datové množině *MVTec-AD*. Výsledky jednotlivých metod jsou dále porovnány z hlediska přesnosti detekce. Zdrojový kód s implementací navržené metody a popisovaného experimentu je dostupný v rámci elektronické přílohy práce.

3.1 Datová množina

Problém detekce defektů řešený v rámci této práce vykazuje poměrně specifické charakteristiky (viz kap. 2.1), které lze pouze složitě napodobit pomocí existujících veřejně dostupných datových množin (viz kap. 1.3). Pro zhodnocení, zda je navržená metoda efektivní na řešeném problému proto musela být vytvořena vlastní datová množina simulující podmínky provozu, pro který je navržená metoda určena.

Mezi specifické vlastnosti, na které je zde oproti jiným datovým množinám kladen důraz patří obecně vyšší variabilita v poloze a natočení vzorků vůči snímacímu zařízení, rozdílné velikosti jednotlivých typů dílů, nízký počet trénovacích snímků a menší rozměry defektů, které jsou tak na snímcích méně viditelné.

Snímky datové množiny byly pořízeny pomocí průmyslové kamery, která je využita také v reálném výrobním provozu řešeném v této práci. Během snímání bylo využito také umělé osvětlení tvořené bodovými LED zdroji, které zajišťuje vyšší viditelnost defektů na dílech.


Celkově bylo pro experiment vytvořeno třináct různých tříd kovových dílů, každá třída je složena z trénovacích snímků bez defektu a dále testovacích snímků s defektem a bez defektů. Pět tříd v datové množině je tvořeno snímky ve stupních šedé, zbývajících osm tříd tvoří barevné snímky. Pomocí snímků ve stupních šedi je možné ověřit, zda metoda dokáže spolehlivě fungovat i bez využití barevné kamery, která je typicky oproti černobílé kameře spojena s vyššími pořizovacími náklady. Počet trénovacích a testovacích vzorků pro jednotlivé třídy datové množiny je uveden v tab. 3.1, posledních pět tříd uvedených v tabulce obsahuje vzorky ve stupních šedi.

3.2 Parametry modelu a trénování

Model trénované konvoluční neuronové sítě je založen na architektuře *ResNet-18*, na výstup konvolučních vrstev *ResNet* modelu dále navazuje vícevrstvý perceptron,

	Třída	Trénovací vzorky	Testovací vzorky normální	Testovací vzorky defektní
Barevné	Spojka	160	30	70
	Rámeček	162	44	87
	Krycí plech	85	19	101
	Táhlo	136	35	33
	Příčka	82	21	21
	Konzole tenkostěnná	238	53	70
	Kryt světlometu	154	24	136
	Pouzdro táhla	162	39	53
Černobílé	Konzole 01	187	32	34
	Konzole 02	44	15	81
	Konzole 03	64	19	65
	Konzole 04	108	29	19
	Rozeta	82	13	27

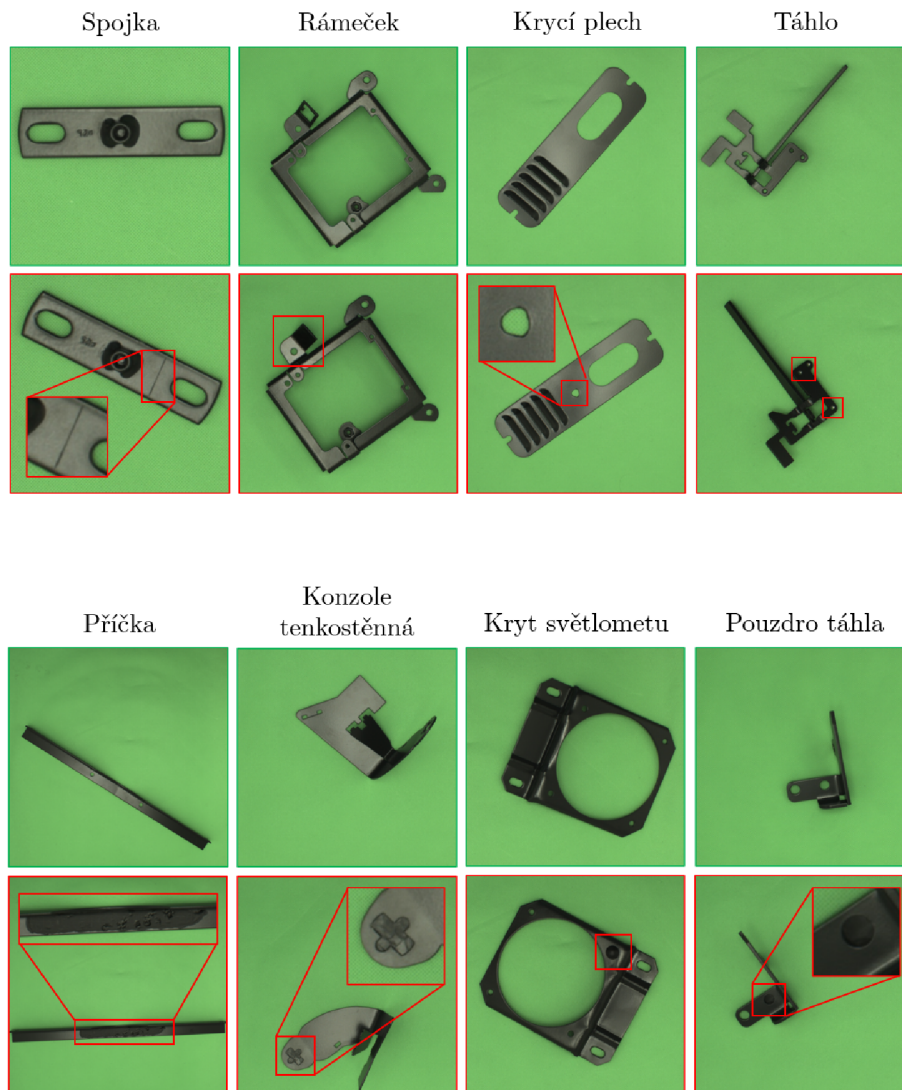
Tab. 3.1: Počty vzorků v jednotlivých třídách vytvořené datové množiny



Obr. 3.1: Ukázka vzorků černobílé datové množiny, v horní řadě (zelené ohraničení) jsou normální vzorky, spodní řada (červené ohraničení) obsahuje vzorky s defekty.

tvořený osmi bloky složenými z plně propojené vrstvy s 512 neurony, vrstvy pro dávkovou normalizaci (*batch normalization layer*) a *ReLU* vrstvy. Na vícevrstvý perceptron navazuje poslední plně propojená vrstva pro binární klasifikaci (viz kap. 2.2.3).

Trénování modelu probíhá po dobu 30000 epoch, rychlost učení je na počátku nastavena na hodnotu 0.03, v průběhu tréninku se hodnota rychlosti učení aktualizuje podle schématu *CosineAnnealing* (s počtem iterací odpovídajícím počtu epoch, viz obr. 3.4). Velikost trénovací dávky je nastavena na 64 vzorků. Pro optimalizaci parametrů je využíván algoritmus *stochastického gradientního sestupu* s hodnotou



Obr. 3.2: Ukázka vzorků barevné datové množiny, zeleně ohraničené snímky obsahují vzorky normální (bez defektu), snímky ohraničené červeně obsahují defekty.

hybnosti (*momentum*) 0.9 a slábnutím vah (*weight decay*) $3 \cdot 10^{-5}$.

Pro zamezení přeučení (*overfitting*) modelu je využito rozšíření trénovacích dat (*data augmentation*), které je založeno na náhodné úpravě jasu, kontrastu, saturace a odstínu každého snímku (*color jitter*). Ukázka snímků s náhodnou úpravou uvedených parametrů je na obr. 3.3. Velikost vstupních snímků je nastavena na 256×256 pixelů.

Pro dosažení vyšší kvality syntetických defektů bylo u jednotlivých tříd testováno nejvhodnější nastavení hodnoty pro prahování, kterým je realizován první krok segmentace dílu a pozadí. Dále bylo z hlediska segmentace vhodnější u některých barevných tříd nevyužívat algoritmus *floodfill*, segmentační maska tak byla vytvo-



Obr. 3.3: Ukázka transformací pro zamezení přeučení


řena pouze prahováním. Hodnoty prahu a údaj, zda byl využit algoritmus *floodfill* pro segmentaci jsou uvedeny v tab. 3.2

Jak bylo uvedeno v kap. 2.2.1, velikost generovaných defektů se v průběhu trénování snižuje. Pro všechny třídy se na počátku tréninku defekty generují z oblasti o velikost 70 až 140 pixelů (z tohoto rozsahu se velikost náhodně vybere). Poté se rozsah, ze kterého se náhodně zvolí velikost oblasti snižuje pro jednotlivé třídy mírně odlišně. Konkrétní hodnoty nejnižšího rozsahu pro jednotlivé třídy jsou uvedeny v tab. 3.2.

Manuální nastavení parametrů pro segmentaci dílu a pozadí bylo použito především pro možnost ověření, jaké přesnosti lze u každé třídy jednotlivě dosáhnout, pokud se předpokládá dostupnost kvalitní segmentační masky. Měření tak nebylo ovlivněno různou kvalitou masky pro různé třídy, což by mohlo nastat v případě, že by maska byla vytvářena automaticky např. pomocí algoritmů pro zpracování obrazu nebo segmentačních neuronových sítí. Pro praktické využití lze však tyto způsoby segmentace považovat za další z možných přístupů, obecně také představují jednu z možností dalšího zlepšení navržené metody.

	Třída	Spodní hranice velikosti defektu	Horní hranice velikosti defektu	Floodfill	Práh
Barevné	Spojka	20	70	ano	100
	Rámeček	10	30	ne	100
	Krycí plech	10	30	ne	120
	Táhlo	10	30	ano	100
	Příčka	10	30	ne	100
	Konzole tenkostěnná	10	30	ano	120
	Kryt světlometu	10	30	ne	110
	Pouzdro táhla	10	30	ano	100
	Konzole 01	20	40	ano	29
Černobílé	Konzole 02	20	40	ano	29
	Konzole 03	20	40	ano	29
	Konzole 04	20	40	ano	127
	Rozeta	20	40	ano	127

Tab. 3.2: Nastavení hodnoty prahu, algoritmu *floodfill* a minimálních rozsahů velikosti generovaných defektů pro jednotlivé třídy



Obr. 3.4: Změna hodnoty parametru *learning rate* v průběhu tréninku pomocí metody *CosineAnnealing*

3.2.1 Metrika AUROC

Měření přesnosti vybraných metod je založeno na metrice AUROC (*area under the receiver operating characteristics*), která v současnosti patří k nejpoužívanějším metrikám v aktuálních publikacích zaměřených na problematiku detekce anomálií.

Metrika *AUROC* obecně umožňuje zhodnotit schopnost libovolného typu klasifikátoru provádět korektní predikce. Pro popis *AUROC* metriky je nutné zavést tzv. *matici záměn*, udávající počty vzorků, které klasifikátor označí jako skutečně pozi-

tivní či negativní nebo naopak falešně pozitivní či negativní. Schéma matice záměn je uvedeno na obr. 3.5.

		Správná třída	
		pozitivní	negativní
Výsledek klasifikátoru	pozitivní	skutečně pozitivní TP	falešně pozitivní FP
	negativní	falešně negativní FN	skutečně negativní TN

Obr. 3.5: Schéma matice záměn

Pro výpočet *AUROC* jsou dle *matice záměn* definovány metriky označované jako *četnost skutečně pozitivních* (*true positive rate* – *TPR*) a *četnost falešně pozitivních* (*false positive rate* – *FPR*), pro které platí vztahy


$$TPR = \frac{TP}{TP + FN} \quad (3.1)$$

$$FPR = \frac{FP}{FP + TN}. \quad (3.2)$$

Pomocí uvedených vztahů je dále definován tzv. *ROC* (*receiver operator characteristics*) graf, který znázorňuje závislost *TPR* a *FPR* klasifikátoru na různých rozhodovacích prahových úrovních [58]. Pokud by byl uvažován např. klasifikátor využívaný v této práci, je výstupem klasifikace hodnota odpovídající pravděpodobnosti (v rozsahu 0 až 1), se kterou vstupní snímek obsahuje defekt. Pro konečné rozhodnutí, zda vstupní snímek bude považován za defektní třídu, je definován určitý *rozhodovací práh*, pomocí kterého již lze provést binární klasifikaci na kategorie 0 (snímek neobsahuje defekt) a 1 (snímek obsahuje defekt).

Graf *ROC* znázorňuje, jakých hodnot *TPR* a *FPR* klasifikátor dosahuje, pokud je snižován rozhodovací práh z hodnoty 1 na hodnotu 0. Ukázka *ROC* grafu je uvedena na obr. 3.6.

Výpočtem plochy pod *ROC* grafem je získána hodnota *AUROC*, někdy též známá pod označením *AUC* (*area under curve*). Pokud *AUROC* dosáhne hodnoty 1, predikoval klasifikátor vše bez chyby, naopak v případě, že hodnota *AUROC* dosahuje 0,5, predikuje klasifikátor čistě náhodně a neposkytuje žádnou rozhodovací sílu.




Obr. 3.6: Graf ROC

Výslednou hodnotu $AUROC$ lze interpretovat jako pravděpodobnost, že náhodně vybranému pozitivnímu vzorku bude klasifikátorem přiřazena vyšší hodnota pravděpodobnosti, než náhodně vybranému negativnímu vzorku [40]. Dále hodnota $AUROC$ indikuje, s jakou mírou je klasifikátor schopen vzájemně oddělit distribuce negativních a pozitivních vzorků [58].

Ukázka průběhu hodnoty $AUROC$ při trénování je znázorněna na obr. 3.7. V grafu lze pozorovat pokles přesnosti přibližně po překročení epochy 20000, kdy již začíná docházet k *přeučení* modelu.

3.3 Výsledky měření

Pro jednotlivé třídy datové množiny bylo provedeno měření s využitím metriky $AUROC$. Naměřené hodnoty $AUROC$ jednotlivých tříd a také průměrná hodnota $AUROC$ pro všechny třídy, jsou uvedeny v tabulce 3.3. K ověření přesnosti navržené metody bylo měření provedeno také pro další tři metody, které aktuálně patří mezi nejpřesnější na datové množině *MVTec-AD*. Dvě z těchto metod (*PatchCore* a *CFLOW-AD*) využívají pro extrakci příznaků model předtrénovaný na datové množině *ImageNet*. Třetí metoda *CutPaste* je založena na samořízeném učení modelu.



Obr. 3.7: Ukázka průběhu přesnosti detekce ($AUROC$) při trénování pro třídu *kryt světlometu*

Třída	Průměr	SDG (navržená metoda)	CutPaste	PatchCore	CFLOW-AD
Spojka	81,92	93,76	71,19	65,76	96,95
Rámeček	72,39	84,98	64,00	60,39	80,17
Krycí plech	86,57	95,52	65,14	85,82	99,79
Táhlo	85,93	99,83	100,00	76,19	67,71
Příčka	96,83	100,00	100,00	88,43	98,87
Konzole tenkostěnná	82,91	93,88	69,92	81,88	85,96
Kryt světlometu	64,32	78,13	64,77	50,88	63,51
Pouzdro táhla	72,00	93,13	76,10	31,88	86,89
Konzole 01	95,89	97,33	95,68	90,53	100,00
Konzole 02	50,03	69,91	70,62	35,14	24,44
Konzole 03	79,21	91,66	79,35	71,09	74,74
Konzole 04	92,88	93,83	89,11	88,57	100,00
Rozeta	87,18	98,86	96,30	66,67	86,89
Průměr	80,62	91,60	80,17	68,71	81,99

Tab. 3.3: Naměřené hodnoty AUROC, nejlepší dosažené skóre je vyznačeno tučně.

3.3.1 Interpretace výsledků

V tabulce výsledků lze pozorovat, že navržená metoda dosahuje nejlepších výsledků pro všechny třídy v průměru a také pro sedm ze třinácti tříd. Oproti druhé nejlepší metodě *CFLOW-AD* dosahuje navržená metoda v průměru o 10, 25 % lepšího AUROC skóre. Nejhorší průměrné skóre bylo naměřeno pro metodu *PatchCore*, rozdíl v porovnání s navrženou metodou je 22, 89 % AUROC.

Naměřená data dále ukazují poměrně výrazný rozdíl (v průměru 10, 53 % AUROC)


mezi metodami využívajícími předtrénovaný model a metodami, které model trénují na náhodně inicializovaných parametrech. Na datové množině *MVTec-AD* jsou oproti tomu získány lepší výsledky naopak metodami s předtrénovaným modelem, rozdíl ve výsledcích však není tak výrazný jako v tomto případě (průměrně 1,58 % AUROC, viz [32, 30, 37]). Pro datovou množinu použitou v této práci jsou tak vhodnější metody založené na samořízeném učení.

Úspěšné a neúspěšné případy detekce defektů


Nejnižší dosažená přesnost v průměru u všech použitých metod byla naměřena na třídě *Konzole 02*, což je nejpravděpodobněji způsobeno nízkým počtem trénovacích vzorků, kterých je v této třídě v porovnání s ostatními třídami pouze 44. Dále je pro danou třídu v datové množině k dispozici 81 snímků s defektem, což je výrazně více než normálních testovacích snímků, kterých je v této třídě 15. Model tedy dle výsledků není schopen vzorky správně klasifikovat jako defektní, s velkým počtem defektních testovacích vzorků potom dochází i k velkému počtu chybných predikcí a následně také nízkému *AUROC* skóre.

Neschopnost metod vzorky správně klasifikovat jako defektní dále může být způsobena poměrně komplexními typy závad, které jsou ve třídě zachyceny. V dílu bez defektu jsou upevněny tři šrouby s matkou v otvorech na jedné z ploch dílu (viz obr. 3.8). Defektem v této třídě je případ, kdy se šroub s matkou nachází v nesprávném otvoru, případně chybí na požadovaném místě nebo se na dílu objeví ohyb plechu. Defekty s nesprávně umístěným šroubem představují poměrně komplexní situaci, především pokud se přihlédne také k velkému počtu různých poloh, ve kterých je díl snímán.

Nejvyšší přesnosti metody v průměru dosahují na třídě *příčka*, kde je obsažen pouze jeden typ defektu (závada v laku), který je na většině snímcích zřetelně viditelný (viz obr. 3.9). Třída dále obsahuje poměrně velké množství trénovacích vzorků a především na snímcích nedochází k výrazné změně v případě posunu nebo otočení dílu, což je způsobeno jeho jednoduchým tvarem. Modely se následně učí poměrně jednoduchou reprezentaci z relativně vysokého počtu trénovacích vzorků a dosahují tak vysoké přesnosti.



Obr. 3.8: Příklad třídy (*Konzole 02*) s nízkou přesností detekce defektů, snímek vlevo reprezentuje normální stav, kdy se v příslušných třech otvorech nachází šroub s matkou. Snímek na pravé straně obsahuje defekt, kdy se šroub nachází na nesprávném místě a dále došlo k ohybu plechu.



Obr. 3.9: Příklad třídy s nejvyšší přesností detekce defektů, snímek na levé straně neobsahuje defekt, na pravé straně je zachycena závada v laku.

4 Diskuze

Z experimentálně získaných výsledků lze pozorovat, že navržená metoda založená na generování syntetických defektů a samořízeném učení dosahuje výrazně vyšší přesnosti v detekci defektů kovových lakovaných dílů v porovnání s ostatními testovanými metodami, které se aktuálně řadí mezi nejpřesnější. Na vytvořené datové množině bylo dále dosaženo obecně kvalitních výsledků metodami založenými na samořízeném učení. Z hlediska problému řešeného v této práci jsou tedy metody využívající samořízené učení vhodnější volbou, oproti modelům založeným na předtřénovaném modelu.

Navržená metoda navazuje na přístupy využívané např. v metodách *CutPaste* či *CutOut* a představuje nový způsob generování umělých defektů vizuálně podobnějších se skutečnými defekty. Na základě získaných výsledků je možné pozorovat, že model trénovaný těmito typy defektů je následně schopen extrahovat příznaky využitelné pro přesnější detekci defektů.

Dle naměřených dat metoda vykazuje v porovnání s ostatními metodami nižší rozptyl výsledků, přesnost detekce defektů tak obecně dosahuje vyšší spolehlivosti. Ke snižování přesnosti podle naměřených výsledků dochází v případech, kdy je metoda trénována na nízkém počtu vzorků nebo snímáný díl vykazuje vysokou variabilitu z hlediska polohy a natočení vůči snímacímu zařízení. Tento jev však nastává obecně pro všechny metody testované v této práci.

Hlavním nedostatkem metod založených na samořízeném učení je nutnost trénovat pro jednotlivé třídy nový model, čímž se zvyšuje celková časová náročnost a jsou také kladeny vyšší nároky na hardwarová výpočetní zařízení (např. grafické karty). Pro metodu navrženou v této práci dále platí, že lze obtížně využít v situacích, kdy není možné separovat předmět detekce defektů od pozadí snímku. V případě zde řešeného problému však tato skutečnost nepředstavuje výrazný nedostatek, protože separaci objektů od pozadí lze podpořit např. využitím barevného fotografického pozadí při snímání. Podobné podmínky pro zajištění lepší separace objektu a pozadí je možné očekávat také v ostatních typech průmyslové výroby, navržená metoda tak nabízí řadu možností pro praktické využití.

Závěr

Tato práce se zabývala problematikou detekce defektů kovových lakovaných dílů pomocí moderních metod založených na konvolučních neuronových sítích. Hlavní náplní práce byl návrh automatizované metody pro detekci defektů kovových lakovaných dílů.

V rámci práce byl proveden souhrn aktuálně nejpřesnějších metod detekce defektů a současně nejpoužívanějších datových množin v této oblasti. Souhrnem aktuálních datových množin bylo zjištěno, že se problém řešený v této práci v určitých ohledech odlišuje od problémů řešených v současných datových množinách, hlavní rozdíly jsou především ve vyšší variabilitě z hlediska polohy a rotace kovového dílu vůči snímací kameře a také nedostatku většího počtu trénovacích vzorků. Z důvodu těchto odlišností byla vytvořena nová datová množina zachycující podmínky zde řešeného problému, na které byly testovány vybrané současné metody detekce defektů a také nová metoda navržená v rámci této práce.

Hlavním přínosem práce je návrh nové metody pro generování syntetických defektů, pomocí které bylo možné na problému detekce defektů řešeném v této práci dosáhnout vyšší přesnosti v porovnání s ostatními současnými přístupy. Navržená metoda slouží k samořízenému učení modelu pro extrakci příznaků, model je trénován na úkolu klasifikace vzorků normálních a vzorků s uměle vygenerovanými defekty. Pomocí navržené metody je dosaženo vyšší podobnosti umělých defektů s defekty, se kterými se lze v rámci výroby kovových dílů setkat. Natrénovaný model je následně schopen extrahovat příznaky umožňující lépe rozlišit normální a defektní vzorky.

Dle výsledků měření na vytvořené datové množině dosahuje navržená metoda v průměru 91,60 % AUROC skóre. Dále byla v rámci práce testována metoda *Cut-Paste* (80,17 % AUROC), *PatchCore* (68,71 % AUROC) a *CFLOW-AD* (81,99 % AUROC), které se aktuálně řadí z hlediska detekce vizuálních anomálií mezi nejpřesnější. Navržená metoda překonává tyto metody o 10,25 % AUROC, vykazuje tak potenciál pro využití v řadě praktických aplikací, především situacích, kdy nelze v rámci dané aplikace provádět sběr velkého objemu dat ve vysoké kvalitě, což typicky ostatní současné metody pro dosažení vyšší přesnosti vyžadují.

Literatura

- [1] D. Hawkins, “Identification of Outliers,” Chpaman and Hall, London, 1980.
- [2] CHANDOLA, Varun, Arindam BANERJEE a Vipin KUMAR. Anomaly detection: A survey [online]. 30. 7. 2009 [cit. 2021-11-13]. Dostupné z: <<https://dl.acm.org/doi/10.1145/1541880.1541882>>
- [3] PANG, Guansong, Chunhua SHEN, Longbing CAO a Anton VAN DEN HENGEL. Deep Learning for Anomaly Detection: A Review [online]. 5. 12. 2020 [cit. 2021-11-13]. Dostupné z: <<https://arxiv.org/abs/2007.02500>>
- [4] RUFF, Lukas, Jacob R. KAUFFMANN, Robert A. VANDERMEULEN, Grégoire MONTAVON, Wojciech SAMEK, Marius KLOFT, Thomas G. DIETTERICH a Klaus-Robert MÜLLER. A unifying review of deep and shallow anomaly detection [online]. 24. 8. 2020 [cit. 2021-11-13]. Dostupné z: <<https://arxiv.org/abs/2009.11732/>>
- [5] CHALAPATHY, Raghavendra a Sanjay CHAWLA. Deep Learning for Anomaly Detection: A Survey. ArXiv.org [online]. 23. 1. 2019 [cit. 2021-11-13]. Dostupné z: <<https://arxiv.org/abs/1901.03407/>>
- [6] BERGMANN, Paul, Michael FAUSER, David SATTLEGGER a Carsten STEGER. MVTEC AD — A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection [online]. 9.1.2020 [cit. 2021-11-13]. Dostupné z: <<https://ieeexplore.ieee.org/document/8954181/>>
- [7] VINCENT, Pascal, Hugo LAROCHELLE, Isabelle LAJOIE, Yoshua BENGIO a Pierre-Antoine MANZAGOL. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion [online]. 1. 12. 2010 [cit. 2021-11-13]. Dostupné z: <<https://dl.acm.org/doi/10.5555/1756006.1953039>>
- [8] SCHLEGL, Thomas, Philipp SEEBOCK, Sebastian M. WALDSTEIN, Ursula SCHMIDT-ERFURTH a Georg LANGS. Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery [online]. 17. 3. 2017 [cit. 2021-11-13]. Dostupné z: <<https://arxiv.org/abs/1703.05921>>
- [9] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. Deep Learning [online]. Cambridge, MA: MIT Press, 2016 [cit. 2021-11-14]. Dostupné z: <<https://www.deeplearningbook.org/>>

- [10] RONNEBERGER, Olaf, Philipp FISCHER a Thomas BROX. U-Net: Convolutional Networks for Biomedical Image Segmentation [online]. 15. 5. 2015 [cit. 2021-11-14]. Dostupné z: <<https://arxiv.org/abs/1505.04597>>
- [11] SAKURADA, Mayu a Takehisa YAIRI. Anomaly Detection Using Autoencoders with Nonlinear Dimensionality Reduction [online]. 2. 12. 2014 [cit. 2021-11-16]. Dostupné z: <<https://dl.acm.org/doi/10.1145/2689746.2689747>>
- [12] HAWKINS, Simon, Hongxing HE, Graham WILLIAMS a Rohan BAXTER. Outlier Detection Using Replicator Neural Networks [online]. 2002 [cit. 2021-11-16]. Dostupné z: <https://link.springer.com/content/pdf/10.1007%2F3-540-46145-0_17.pdf>
- [13] RUMELHART, David E. a James L. MCCLELLAND. Learning Internal Representations by Error Propagation [online]. 1987 [cit. 2021-11-16]. Dostupné z: <<https://ieeexplore.ieee.org/document/6302929>>
- [14] AN, Jinwon a Sungzoon CHO. Variational Autoencoder based Anomaly Detection using Reconstruction Probability [online]. 27. 12. 2015 [cit. 2021-11-16]. Dostupné z: <<http://dm.snu.ac.kr/static/docs/TR/SNUDM-TR-2015-03.pdf>>
- [15] ZHOU, Chong a Randy C. PAFFENROTH. Anomaly Detection with Robust Deep Autoencoders [online]. 4. 8. 2017 [cit. 2021-11-17]. Dostupné z: <<https://dl.acm.org/doi/10.1145/3097983.3098052>>
- [16] GOODFELLOW, Ian J., Jean POUGET-ABADIE, Mehdi MIRZA, Bing XU, David WARDE-FARLEY, Sherjil OZAIR, Aaron COURVILLE a Yoshua BENGIO. Generative Adversarial Networks [online]. 10. 6. 2014 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/1406.2661>>
- [17] SCHLEGL, Thomas, Philipp SEEBÖCK, Sebastian M. WALDSTEIN, Georg LANGS a Ursula SCHMIDT-ERFURTH. F-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks [online]. 31. 1. 2019 [cit. 2021-11-17]. Dostupné z: <<https://www.sciencedirect.com/science/article/pii/S1361841518302640>>
- [18] AKCAY, Samet, Amir ATAPOUR-ABARGHOUEI a Toby P. BRECKON. GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training [online]. 13. 11. 2018 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/1805.06725>>

- [19] TANG, Ta-Wei, Wei-Han KUO, Jauh-Hsiang LAN, Chien-Fang DING, Hakiem HSU a Hong-Tsu YOUNG. Anomaly Detection Neural Network with Dual Auto-Encoders GAN and Its Industrial Inspection Applications [online]. 12. 6. 2020 [cit. 2021-11-17]. Dostupné z: <<https://www.mdpi.com/1424-8220/20/12/3336>>
- [20] ZAVRTANIK, Vitjan, Matej KRISTAN a Danijel SKOČAJ. DRÆM – A discriminatively trained reconstruction embedding for surface anomaly detection [online]. 27. 9. 2021 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/2108.07610>>
- [21] AKÇAY, Samet, Amir ATAPOUR-ABARGHOUEI a Toby P. BRECKON. Skip-GANomaly: Skip Connected and Adversarially Trained Encoder-Decoder Anomaly Detection [online]. 25.1.2019 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/1901.08954>>
- [22] DEFARD, Thomas, Aleksandr SETKOV, Angelique LOESCH a Romaric AUDIGIER. PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization [online]. 17. 11. 2020 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/2011.08785>>
- [23] HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN. Deep Residual Learning for Image Recognition [online]. 10. 12. 2015 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/1512.03385>>
- [24] ZAGORUYKO, Sergey a Nikos KOMODAKIS. Wide Residual Networks [online]. 14. 6. 2017 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/1605.07146>>
- [25] TAN, Mingxing a Quoc V. LE. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks [online]. 11. 9. 2020 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/1905.11946>>
- [26] DENG, Jia, Wei DONG, Richard SOCHER, Li-Jia LI, Kai LI a Li FEI-FEI. ImageNet: A large-scale hierarchical image database [online]. 18. 8. 2009 [cit. 2021-11-17]. Dostupné z: <<https://ieeexplore.ieee.org/document/5206848>>
- [27] NAPOLETANO, Paolo, Flavio PICCOLI a Raimondo SCHETTINI. Anomaly Detection in Nanofibrous Materials by CNN-Based Self-Similarity [online]. 12. 1. 2018 [cit. 2021-11-17]. Dostupné z: <<https://www.mdpi.com/1424-8220/18/1/209>>

- [28] BERGMAN, Liron, Niv COHEN a Yedid HOSHEN. Deep Nearest Neighbor Anomaly Detection [online]. 24. 2. 2020 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/2002.10445>>
- [29] COHEN, Niv a Yedid HOSHEN. Sub-Image Anomaly Detection with Deep Pyramid Correspondences [online]. 3. 2. 2021 [cit. 2021-11-17]. Dostupné z: <<https://arxiv.org/abs/2005.02357>>
- [30] ROTH, Karsten, Latha PEMULA, Joaquin ZEPEDA, Bernhard SCHOLKOPF, Thomas BROX a Peter GEHLER. Towards Total Recall in Industrial Anomaly Detection [online]. 15. 6. 2021 [cit. 2021-11-23]. Dostupné z: <<https://arxiv.org/abs/2106.08265>>
- [31] AGARWAL, Pankaj K., Sarel HAR-PELED a Kasturi R. VARADARAJAN. Geometric Approximation via Coresets [online]. 22. 10. 2004 [cit. 2021-11-23]. Dostupné z: <<https://users.cs.duke.edu/~pankaj/publications/surveys/coreset-survey.pdf>>
- [32] LI, Chun-Liang, Kihyuk SOHN, Jinsung YOON a Tomas PFISTER. CutPaste: Self-Supervised Learning for Anomaly Detection and Localization [online]. 8. 4. 2021 [cit. 2021-11-23]. Dostupné z: <<https://arxiv.org/abs/2104.04015>>
- [33] RIPPEL, Oliver, Patrick MERTENS a Dorit MERHOF. Modeling the Distribution of Normal Data in Pre-Trained Deep Features for Anomaly Detection [online]. 23. 8. 2020 [cit. 2021-11-29]. Dostupné z: <<https://arxiv.org/abs/2005.14140>>
- [34] DEFARD, Thomas, Aleksandr SETKOV, Angelique LOESCH a Romaric AUDIGIER. PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization [online]. 17. 11. 2020 [cit. 2021-11-29]. Dostupné z: <<https://arxiv.org/abs/2011.08785>>
- [35] MAHALANOBIS, P. C. On the Generalised Distance in Statistics [online]. 4. 1. 1936 [cit. 2021-11-29]. Dostupné z: <<https://link.springer.com/article/10.1007/s13171-019-00164-5>>
- [36] RUDOLPH, Marco, Bastian WANDT a Bodo ROSENHAHN. Same Same But DifferNet: Semi-Supervised Defect Detection with Normalizing Flows [online]. 28. 8. 2020 [cit. 2021-11-29]. Dostupné z: <<https://arxiv.org/abs/2008.12577>>

- [37] GUDOVSKIY, Denis, Shun ISHIZAKA a Kazuki KOZUKA. CFLOW-AD: Real-Time Unsupervised Anomaly Detection with Localization via Conditional Normalizing Flows [online]. 27. 7. 2021 [cit. 2021-11-29]. Dostupné z: <<https://arxiv.org/abs/2107.12571>>
- [38] RUDOLPH, Marco, Tom WEHRBEIN, Bodo ROSENHAHN a Bastian WANDT. Fully Convolutional Cross-Scale-Flows for Image-based Defect Detection [online]. 6. 10. 2021 [cit. 2021-11-29]. Dostupné z: <<https://arxiv.org/abs/2110.02855>>
- [39] YU, Jiawei, Ye ZHENG, Xiang WANG, Wei LI, Yushuang WU, Rui ZHAO a Liwei WU. FastFlow: Unsupervised Anomaly Detection and Localization via 2D Normalizing Flows [online]. 16. 11. 2021 [cit. 2021-11-29]. Dostupné z: <<https://arxiv.org/abs/2111.07677>>
- [40] YI, Jihun a Sungroh YOON. Patch SVDD: Patch-level SVDD for Anomaly Detection and Segmentation [online]. 13. 7. 2020 [cit. 2021-11-23]. Dostupné z: <<https://arxiv.org/abs/2006.16067>>
- [41] GIDARIS, Spyros, Praveer SINGH a Nikos KOMODAKIS. Unsupervised Representation Learning by Predicting Image Rotations [online]. 21. 3. 2018 [cit. 2021-11-23]. Dostupné z: <<https://arxiv.org/abs/1803.07728>>
- [42] GOLAN, Izhak a Ran EL-YANIV. Deep Anomaly Detection Using Geometric Transformations [online]. 9. 11. 2018 [cit. 2021-11-23]. Dostupné z: <<https://arxiv.org/abs/1805.10917>>
- [43] LIZNERSKI, Philipp, Lukas RUFF, Robert A. VANDERMEULEN, Billy Joe FRANKS, Marius KLOFT a Klaus-Robert MULLER. Explainable Deep One-Class Classification [online]. 18. 3. 2021 [cit. 2021-11-29]. Dostupné z: <<https://arxiv.org/abs/2007.01760>>
- [44] DEVRIES, Terrance a Graham W. TAYLOR. Improved Regularization of Convolutional Neural Networks with Cutout [online]. 29. 11. 2017 [cit. 2021-11-23]. Dostupné z: <<https://arxiv.org/abs/1708.04552>>
- [45] DENG, Li. The MNIST Database of Handwritten Digit Images for Machine Learning Research [online]. 18. 10. 2012 [cit. 2021-12-06]. Dostupné z: <<https://ieeexplore.ieee.org/document/6296535>>
- [46] KRIZHEVSKY, Alex, Vinod NAIR a Geoffrey HINTON. CIFAR-10 (Canadian Institute for Advanced Research) [online]. [cit. 2021-12-06]. Dostupné z: <<http://www.cs.toronto.edu/~kriz/cifar.html>>

- [47] TABERNIK, Domen, Samo ŠELA, Jure SKVARČ a Danijel SKOČAJ. Segmentation-Based Deep-Learning Approach for Surface-Defect Detection [online]. 11. 6. 2019 [cit. 2021-12-06]. Dostupné z: <<https://arxiv.org/abs/1903.08536>>
- [48] BOŽIČ, Jakob, Domen TABERNIK a Danijel SKOČAJ. Mixed supervision for surface-defect detection: from weakly to fully supervised learning [online]. 20. 4. 2021 [cit. 2021-12-06]. Dostupné z: <<https://arxiv.org/abs/2104.06064>>
- [49] HUANG, Yibin, Congying QIU, Yue GUO, Xiaonan WANG a Kui YUAN. Surface Defect Saliency of Magnetic Tile [online]. 20. 4. 2018 [cit. 2021-12-06]. Dostupné z: <<https://ieeexplore.ieee.org/document/8560423>>
- [50] ZHANG, Yingying, Desen ZHOU, Siqin CHEN, Shenghua GAO a Yi MA. Single-Image Crowd Counting via Multi-Column Convolutional Neural Network [online]. 12. 12. 2016 [cit. 2021-12-06]. Dostupné z: <<https://ieeexplore.ieee.org/document/7780439>>
- [51] MISHRA, Pankaj, Riccardo VERK, Daniele FORNASIER, Claudio PICIARELLI a Gian Luca FORESTI. VT-ADL: A Vision Transformer Network for Image Anomaly Detection and Localization [online]. 20. 4. 2021 [cit. 2021-12-06]. Dostupné z: <<https://arxiv.org/abs/2104.10036>>
- [52] ZHANG, Defu, Kechen SONG, Jing XU, Yu HE a Yunhui YAN. Unified detection method of aluminium profile surface defects: Common and rare defect categories [online]. 1. 3. 2020 [cit. 2021-11-28]. Dostupné z: <<https://en.x-mol.com/paper/article/1234222623767941120>>
- [53] CHENG, Jiahui, Bin GUO, Jiaqi LIU, Sicong LIU, Guangzhi WU, Yueqi SUN a Zhiwen YU. TL-SDD: A Transfer Learning-Based Method for Surface Defect Detection with Few Samples [online]. 16. 8. 2021 [cit. 2021-11-28]. Dostupné z: <<https://arxiv.org/abs/2108.06939>>
- [54] BLOCK, Sylvio Biasuz, Ricardo Dutra da SILVA, Leyza Baldo DORINI a Rodrigo MINETTO. Inspection of Imprint Defects in Stamped Metal Surfaces Using Deep Learning and Tracking [online]. 9. 4. 2020 [cit. 2021-12-06]. Dostupné z: <<https://ieeexplore.ieee.org/document/9062515>>
- [55] KOZAMERNIK, Nejc a Drago BRAČUN. Visual Inspection System for Anomaly Detection on KTL Coatings Using Variational Autoencoders [online]. 9. 10. 2020 [cit. 2021-12-06]. Dostupné z: <<https://www.sciencedirect.com/science/article/pii/S2212827120307496>>

- [56] PARKER, J. R. Algorithms for Image Processing and Computer Vision [online]. 2nd Edition. Wiley, 2010 [cit. 2021-12-03]. ISBN 978-1-118-02188-0.
- [57] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. Deep Learning [online]. MIT Press, 2016 [cit. 2021-12-03]. Dostupné z: <<http://www.deeplearningbook.org>>
- [58] FAWCETT, Tom. ROC graphs: Notes and practical considerations for researchers [online]. 7. 1. 2003 [cit. 2021-12-04]. Dostupné z: <<https://www.hpl.hp.com/techreports/2003/HPL-2003-4.pdf>>
- [59] TANG, Ta-Wei, Wei-Han KUO, Jauh-Hsiang LAN, Chien-Fang DING, Hakiem HSU a Hong-Tsu YOUNG. Anomaly Detection Neural Network with Dual Auto-Encoders GAN and Its Industrial Inspection Applications [online]. 12.6.2020 [cit. 2022-04-18]. Dostupné z: <<https://www.mdpi.com/1424-8220/20/12/3336>>
- [60] KODALI, Naveen, Jacob ABERNETHY, James HAYS a Zsolt KIRA. How to Train Your DRAGAN [online]. 2017, 10.12.2017 [cit. 2022-05-17]. Dostupné z: <<https://arxiv.org/abs/1705.07215v1>>
- [61] RADFORD, Alec, Luke METZ a Soumith CHINTALA. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks [online]. 2016, 7.1.2016 [cit. 2022-05-17]. Dostupné z: <<https://arxiv.org/abs/1511.06434>>
- [62] LIANG, Yufei, Jiangning ZHANG, Shiwei ZHAO, Runze WU, Yong LIU a Shuwen PAN. Omni-frequency Channel-selection Representations for Unsupervised Anomaly Detection [online]. 2022, 1.3.2022 [cit. 2022-05-17]. Dostupné z: <<https://arxiv.org/abs/2203.00259v1>>
- [63] RISTEA, Nicolae-Catalin, Neelu MADAN, Radu Tudor IONESCU, Kamal NASROLLAHI, Fahad Shahbaz KHAN, Thomas B. MOESLUND a Mubarak SHAH. Self-Supervised Predictive Convolutional Attentive Block for Anomaly Detection [online]. 2022, 13.3.2022 [cit. 2022-05-17]. Dostupné z: <<https://arxiv.org/abs/2111.09099v6>>
- [64] JIANG, Yu, Wei WANG a Chunhui ZHAO. A Machine Vision-based Real-time Anomaly Detection Method for Industrial Products Using Deep Learning [online]. 13.2.2020 [cit. 2022-05-18]. Dostupné z: <<https://ieeexplore.ieee.org/document/8997079>>

- [65] STAAR, Benjamin, Michael LÜTJEN a Michael FREITAG. Anomaly detection with convolutional neural networks for industrial surface inspection [online]. 2018, 18.7.2018 [cit. 2022-05-18]. Dostupné z: <<https://doi.org/10.1016/j.procir.2019.02.123>>
- [66] HUANG, Haixin, Xueduo TANG, Feng WEN a Xin JIN. Small object detection method with shallow feature fusion network for chip surface defect detection [online]. 2022, 10.3.2022 [cit. 2022-05-18]. Dostupné z: <<https://www.nature.com/articles/s41598-022-07654-x>>
- [67] LI, Zhuang, Xincheng TIAN, Xin LIU, Yan LIU a Xiaorui SHI. A Two-Stage Industrial Defect Detection Framework Based on Improved-YOLOv5 and Optimized-Inception-ResnetV2 Models [online]. 2022, 14.1.2022 [cit. 2022-05-18]. Dostupné z: <<https://www.mdpi.com/2076-3417/12/2/834>>

Seznam symbolů a zkratek

GAN	generativní soupeřící síť – Generative Adversarial Networks
AE	autoenkodér
VAE	variační autoenkodér
CAE	konvoluční autoenkodér
SVM	metoda podpůrných vektorů – Support Vector Machine
k-NN	k-nejbližších sousedů – k-Nearest Neighbors
PCA	analýza hlavních komponent – Principal Component Analysis
AUROC	area under receiver operating characteristics
AUC	oblast pod křivkou – area under curve