

Teze přednášek ke jmenování profesorem

Extrakce relevantních vlastností pomocí hlubokého učení pro průmyslové aplikace

Extraction of Relevant Features Using Deep Learning for Industrial Applications

Autor: **doc. Ing. Petr Doležel, Ph.D.**

Obor: **Řízení strojů a procesů**

Zlín, září 2023

© Petr Doležel

Vydala **Univerzita Tomáše Bati ve Zlíně** v edici **Qualifying Lecture for Professorship**.

Publikace byla vydána v roce 2023.

Klíčová slova: hluboké učení, konvoluční neuronové sítě, zpracování obrazu, extrakce vlastností, inženýrské aplikace

Key words: deep learning, convolutional neural networks, image processing, feature extraction, engineering applications

Práce je dostupná v Knihovně UTB ve Zlíně.

ISBN 978-80-7678-181-8

ABSTRAKT

Předložené teze přednášky ke jmenování profesorem představují zásadní část autorova příspěvku do oblasti extrakce relevantních vlastností z dat získaných v reálných podmínkách, zejména v průmyslové výrobě, pomocí nástrojů hlubokého učení. Pozornost je nejprve věnována extrakci vlastností z vizuálních dat, v druhé části pak analýze signálu a extrakci vlastností ze signálů a časových řad. Oba úseky nejprve obsahují stručný teoretický základ zkoumané problematiky, následně je předložen autorův přínos realizovaný zpravidla formou vědeckých publikací, projektové činnosti či předmětů průmyslově-právní ochrany.

SUMMARY

The theses of the qualifying lecture for professorship represent an essential part of the author's contribution to the field of extraction of relevant features from data obtained in real conditions, especially in industrial production, using deep learning tools. The work is first focused on feature extraction from visual data, and the second part on signal analysis and feature extraction from signals and time series. Both sections first contain a brief theoretical background of the investigated problem, and then the author's contribution is presented, usually realized in the form of scientific publications, project activities, or subjects of intellectual and industrial property.

OBSAH

Abstrakt	3
Summary.....	3
Obsah	4
1. Úvod.....	7
2. Extrakce relevantních vlastností pomocí hlubokého učení	8
2.1 Zpracování obrazu a videa.....	9
2.2 Zpracování zvuku a řeči.....	9
2.3 Zpracování textu a jazyka	9
2.4 Analýza signálů a časových řad.....	10
2.5 Biomedicinské aplikace	10
2.6 Finanční analýza	10
3. Přínos autora v oblasti zpracování obrazu a videa.....	10
3.1 Úvod do problematiky	10
3.2 Koncept extrakce relevantních vlastností pomocí transformace vizuálních dat do pravděpodobnostních map	12
3.2.1 Pravděpodobnostní mapa	12
3.2.2 Transformace vizuálních dat do skupiny deformovaných pravděpodobnostních map.....	13
3.2.3 Postup návrhu systému pro extrakci relevantních vlastností pomocí transformace vizuálních dat do pravděpodobnostních map	15
3.3 Efektivní detekce úchopových bodů pro automatickou manipulaci s netriviálními objekty	16
3.3.1 Reprezentace relevantních vlastností pomocí deformovaných pravděpodobnostních map.....	18
3.3.2 Dataset.....	21
3.3.3 Výběr architektury modelu a její implementace	22
3.3.4 Implementace modelu	24
3.3.5 Rozšíření pro RGB-D vizuální data	25
3.3.6 Výstupy tvůrčí činnosti spojené s představeným řešením	26
3.4 Efektivní detekce hlav cestujících v prostředcích hromadné dopravy	27

3.4.1	Reprezentace relevantních vlastností pomocí deformovaných pravděpodobnostních map	27
3.4.2	Implementace modelu.....	28
3.4.3	Výstupy tvůrčí činnosti spojené s představeným řešením.....	29
3.5	Efektivní detekce zájmových objektů ve sledovaném prostoru.....	30
3.5.1	Výstupy tvůrčí činnosti spojené s představeným řešením.....	31
3.6	Další aplikace autora v oblasti využití modelů hlubokého učení pro zpracování obrazu a videa.....	31
3.6.1	Digitální zpracování obrazu pro stanovení degradace polymerů a nátěrových hmot.....	32
3.6.2	Automatizovaná kontrola svarů	32
3.6.3	Inteligentní firewall pro průmyslové sítě.....	33
4.	Přínos autora v oblasti analýzy signálu a časových řad	33
4.1	Úvod do problematiky.....	33
4.2	Model hlubokého učení pro extrakci vlastností z teplotních průběhů relaxační dynamiky v amorfních materiálech v oblasti skelného přechodu....	36
4.2.1	Dataset.....	37
4.2.2	Výběr architektury modelu a její implementace.....	39
4.2.3	Implementace modelu.....	41
4.2.4	Výstupy tvůrčí činnosti spojené s představeným řešením.....	43
4.3	Spektrální klasifikace mikroplastů.....	43
4.3.1	Výstupy tvůrčí činnosti spojené s představeným řešením.....	44
4.4	Další aplikace autora v oblasti analýzy signálu a časových řad	44
5.	Přínos pro vědu, praxi a pedagogickou činnost	45
6.	Závěr.....	46
7.	Literatura	46
8.	Seznam obrázků.....	56
9.	Profesní životopis autora.....	59

1. ÚVOD

Předkládané teze ke jmenování profesorem jsou sumarizací autorova přínosu do oblasti extrakce relevantních vlastností z dat získaných měřením v reálných podmínkách, zejména pro použití v automatizaci průmyslových výroby a v dopravních systémech.

Celoživotní zájem o výpočetní techniku a automatizaci autora se významně projevil již během magisterského studia na Fakultě chemicko-technologické Univerzity Pardubice, kde autor v roce 2008 obhájil diplomovou práci na téma řízení kontinuálního bioreaktoru pomocí vícevrstvého perceptronu. S tímto tématem autor také získal v sekci Teorie a aplikace systémů řízení první místo v mezinárodní soutěži STOČ 2008 konané na Fakultě aplikované informatiky Univerzity Tomáše Bati ve Zlíně (FAI UTB). Problematice využití umělých neuronových sítí pro modelování a řízení dynamických systémů se Petr Doležel věnoval také v doktorském studiu (úspěšně zakončeno v roce 2011) a následně v zaměstnání na Fakultě elektrotechniky a informatiky Univerzity Pardubice. Od začátku své akademické kariéry se autor zabýval zejména výzkumem s vysokým aplikačním potenciálem, a to formou přímé spolupráce s průmyslovými podniky zabývajícími se inovacemi v automatizaci, či působením v grantových projektech Technologické agentury ČR a resortních projektech Ministerstva průmyslu a obchodu. V roce 2017 Petr Doležel úspěšně absolvoval habilitační řízení v oboru Řízení strojů a procesů na FAI UTB a také se stal proděkanem pro vědu a tvůrčí činnost na své domovské fakultě. Od roku 2022 působí autor jako prorektor pro vědu a tvůrčí činnost na Univerzitě Pardubice.

Velkou oporou po celou dobu působení Petra Doležela v akademické sféře byl prof. Ing. Ivan Taufer, DrSc., který autora nejprve vedl během magisterského a doktorského studia, ale také později svou přirozenou autoritou a neustálou ochotou pomoci pozitivně ovlivňoval autorův odborný i osobnostní růst. Dalším klíčovým momentem byla výzkumná stáž na Ústavu informatizácie, automatizácie a matematiky Fakulty chemickej a potravinárskej technológie Slovenské technické univerzity v Bratislavě vedeném prof. Ing. Miroslavem Fikarem, DrSc., kde autor nabyl neocenitelné poznatky týkající se moderních metod vědecké práce, týmové spolupráce a vědecké komunikace. Na mezinárodní úrovni Petr Doležel intenzivně spolupracuje s několika pracovišti, přičemž se pozitivně vymyká zejména spolupráce s výzkumnou skupinou GICAP působící pod vedením prof. Álvara Herrera na Univerzitě v Burgosu. Spolupráce dosud vedla k řadě společných vědeckých publikací, spoluřešení výzkumného projektu

i k participaci na pořádání konference International Conference on Soft Computing Models in Industrial and Environmental Applications. Velkým milníkem v kariéře autora byl projekt Spolupráce Univerzity Pardubice a aplikační sféry v aplikačně orientovaném výzkumu lokačních, detekčních a simulačních systémů pro dopravní a přepravní procesy (PosiTrans). Petr Doležel zde působil jako vedoucí výzkumného týmu a odborný administrátor projektu. Pod jeho vedením v projektovém týmu pracovalo více než třicet výzkumných pracovníků Univerzity Pardubice, partnerů z průmyslu i ze zahraničních výzkumných organizací. Během projektu bylo vygenerováno přes 20 špičkových časopiseckých publikací, 60 příspěvků na odborných konferencích, v konsorciu partnerů byl získán projekt typu Horizon Europe a celá řada navazujících projektů Ministerstva průmyslu a obchodu. V návaznosti na činnosti v tomto projektu se kolem autora zformoval výzkumný tým¹ čítající v současné době pět akademických pracovníků a více než deset doktorandů.

Mezi hlavní směry výzkumné činnosti Petra Doležela patří:

- extrakce vlastností z vizuálních a dalších dat,
- segmentace a shlukování dat,
- detekce, lokalizace a klasifikace objektů,
- automatizace a robotizace výrobních procesů.

V pedagogické činnosti se autor jako garant a přednášející zapojuje do výuky bakalářských studijních programů Automatizace a Komunikační technika, do navazujících magisterských studijních programů Automatické řízení, Informační technologie a Komunikační a radarové systémy a do doktorského studijního programu Elektrotechnika a informatika. Pod jeho vedením úspěšně obhájilo bakalářskou práci 26 studentů, diplomovou práci 19 studentů a dva studenti úspěšně obhájili doktorskou disertační práci.

2. EXTRAKCE RELEVANTNÍCH VLASTNOSTÍ POMOCÍ HLUBOKÉHO UČENÍ

Hluboké učení představuje jeden z nejvýznamnějších průlomů v oblasti umělé inteligence a strojového učení. Od svého vzniku zaznamenalo intenzivní rozvoj a přispělo k revoluci ve zpracování dat a analýze informací. Mezi jeho aplikacemi

¹ <https://fei.upce.cz/fei/vyzkumny-tym-petra-dolezela>

zaujímá zvláštní místo extrakce relevantních (podstatných) vlastností z různých typů dat naměřených v reálných podmínkách.

Extrakce relevantních vlastností je proces identifikace klíčových charakteristik, vzorců nebo struktur v datech, které mají zásadní význam pro konkrétní úkol. Hluboké učení přináší nový pohled na tento proces, umožňuje automaticky odhalit komplexní vzorce a reprezentace skryté v datech, které byly dříve těžko dosažitelné pomocí tradičních metod.

Extrakce relevantních vlastností s využitím hlubokého učení nachází široké uplatnění v mnoha různých typech úloh a aplikací. Níže zmíněná široká, avšak nikoliv vyčerpávající, paleta aplikací [1], [2], [3] ukazuje, že extrakce relevantních vlastností pomocí hlubokého učení je robustním nástrojem pro analýzu různých typů reálných dat a má potenciál změnit a zkvalitnit mnoho aspektů každodenního života.

2.1 Zpracování obrazu a videa

Extrakce vlastností z vizuálních dat, jako jsou obrázky a videa, je jedním z nejnámějších a nejpoužívanějších způsobů využití hlubokého učení. Konvoluční neuronové sítě umožňují detekci objektů v obraze, jejich klasifikaci, segmentaci a také generaci obrázků. Tato technologie může být aplikována ve sledování objektů, autonomních vozidlech, diagnostice zdravotních stavů na základě medicínských obrazů a mnoha dalších oblastech. Velmi často lze nalézt aplikace v robotice a průmyslových výrobních systémech, kde je hluboké učení využíváno pro navigaci, detekci a rozpoznávání prostředí, manipulaci s objekty, kontrolu kvality, optimalizaci výrobních procesů, predikci selhání zařízení, monitorování stavu strojů a další účely.

2.2 Zpracování zvuku a řeči

Extrakce relevantních vlastností z audiozáznamů, zvukových signálů a řeči je další důležitou oblastí, kde hluboké učení poskytuje vynikající výsledky. Rekurentní neuronové sítě (RNN) a sítě typu transformer jsou často využívány pro rozpoznávání řeči, generaci hlasu, překlad jazyků, analýzu emocí ve zvukových datech a mnoha dalších aplikacích.

2.3 Zpracování textu a jazyka

Extrakce relevantních vlastností z textových dat má široké využití v klasifikaci textů, strojovém překladu, generování textu, chatbotech a mnoha dalších

oblastech zpracování přirozeného jazyka. Rekurentní a transformační modely jsou často používány pro zachycení vztahů a vazeb mezi slovy a větami.

2.4 Analýza signálů a časových řad

V oblasti analýzy časových řad a dalších typů dynamických signálů hraje extrakce relevantních vlastností klíčovou roli. Modely hlubokého učení jsou využívány pro predikci budoucích hodnot, detekci anomálií, analýzu trendů a sezónních vzorců v časových datech.

2.5 Biomedicinské aplikace

V bioinformatice a biomedicíně hluboké učení přináší zásadní pokrok v diagnostice, prognóze, léčbě i rehabilitaci. Hluboké učení je používáno pro diagnostiku, predikci zdravotních stavů, analýzu genomu, lékařské obrazy a další biomedicínské úkoly.

2.6 Finanční analýza

Ve finančním sektoru se extrakce vlastností pomocí hlubokého učení používá pro predikci cen akcií, detekci podvodů, analýzu tržních trendů a další finanční prognózy.

3. PŘÍNOS AUTORA V OBLASTI ZPRACOVÁNÍ OBRAZU A VIDEA

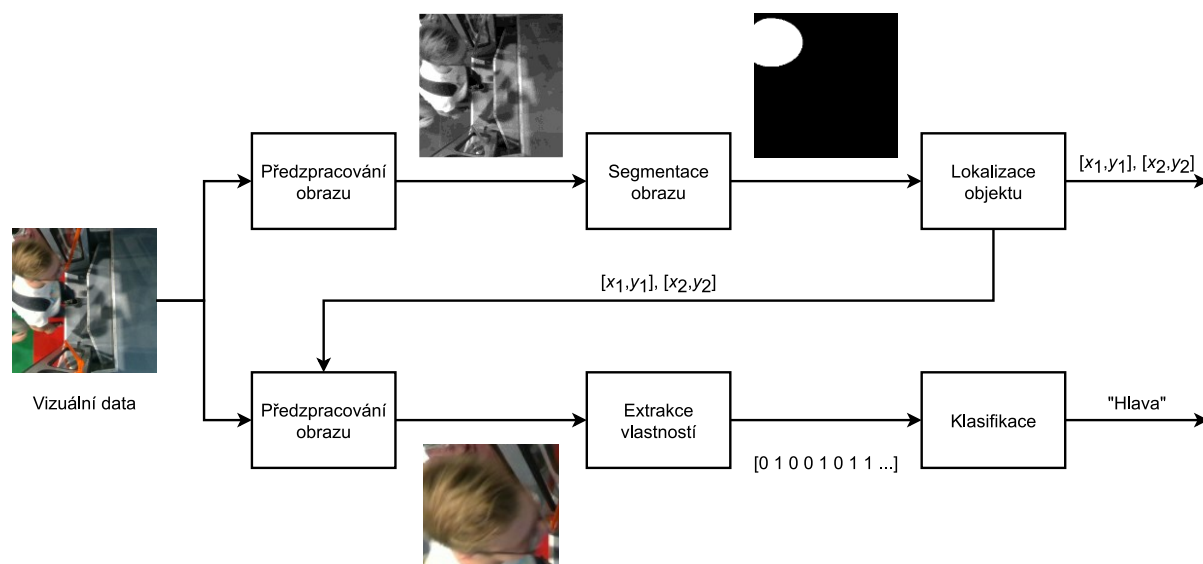
3.1 Úvod do problematiky

V posledních desetiletích se oblast hlubokého učení stala klíčovým prvkem výzkumu i praxe v oblasti umělé inteligence. S jeho silou a schopnostmi se otevřely nové obzory v řešení komplexních úkolů, a to v zásadní míře zejména v oblasti zpracování vizuálních dat, tedy obrazu a videa.

Extrakce relevantních vlastností pomocí hlubokého učení představuje v analýze vizuálních dat zásadní proces, který má za úkol identifikovat klíčové charakteristiky a informace obsažené v obrazech a videích. V důsledku toho jsou modely schopny efektivněji rozumět a interpretovat vizuální scény, rozpoznávat objekty, klasifikovat vzory a provádět řadu dalších úkolů v různých oborech a aplikacích [4], [5].

Klasické schéma příkladu hierarchického systému pro extrakci relevantních vlastností je znázorněno na Obr. 1. Prvním krokem extrakce je předzpracování obrazu. V této fázi jsou obrazy upraveny tak, aby byla minimalizována nežádoucí

informace a zvýrazněny klíčové rysy. Zpravidla je uplatňována filtrace a redukce šumu, normalizace hodnot pixelů, změna velikosti obrazu, případně další techniky, které zlepšují kvalitu a srozumitelnost vizuálních dat. Následujícím krokem je segmentace obrazu, což je proces rozdělení obrazu do souborů regionů, které mají významné vlastnosti nebo reprezentují jednotlivé objekty v obraze. Tento krok je klíčový pro rozpoznávání objektů, detekci hran a dalších úkolů, které vyžadují identifikaci specifických rysů ve vizuálních datech. Po segmentaci následuje lokalizace objektů v obraze, tedy nalezení polohy a velikosti objektů v obraze, což je klíčové pro rozpoznávání objektů, či další analýzu. Jiným typickým krokem je klasifikace objektů, kdy systém na základě extrakce vlastností z klíčové oblasti ve vizuálních datech přiřazuje jednotlivým objektům příslušné kategorie nebo třídy. Systém v závislosti na řešené úloze může zahrnovat další úkoly, jako je detekce (tzn. kombinace lokalizace a klasifikace) a sledování pohybujících se objektů, extrakce textu, či rozpoznávání tváří.



Obr. 1 Příklad schématu pro extrakci vlastností z vizuálních dat.

Metody extrakce relevantních vlastností z vizuálních dat pomocí hlubokého učení často nabízí modely integrující více kroků uvedených na Obr. 1.

V oblasti klasifikace modely hlubokého učení dosahují výrazně lepších výsledků ve srovnání s tradičními přístupy. Klíčovým mezníkem byla práce „ImageNet Classification with Deep Convolutional Neural Networks“ [6], ve které byla poprvé představena hluboká konvoluční síť AlexNet s pěti konvolučními vrstvami a třemi plně propojenými vrstvami. Od té doby byly vyvinuty další architektury, jako je VGGNet [7], ResNet [8], DenseNet [9] a

EfficientNet [10], které dosahují vynikajících výkonů v klasifikaci objektů ve vizuálních datech.

Pro úlohu lokalizace objektů v obraze se používají tzv. detektory objektů založené na konvolučních sítích. Tyto detektory dokážou nejen klasifikovat objekty, ale také odhadnout jejich polohu a ohraničující rámeček (bounding box). Práce „Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks“ [11] představila kombinaci efektivní sítě pro návrh potenciálních regionů přítomnosti objektu a konvoluční sítě pro detekci objektů s vysokou přesností. Dalšími populárními metodami jsou např. YOLO (You Only Look Once) [12] a SSD (Single Shot Multibox Detector) [13].

Hluboké učení dosáhlo významných pokroků také při segmentaci vizuálních dat. V roce 2015 byla publikována práce „Fully Convolutional Networks for Semantic Segmentation“ [14], která představila architekturu FCN (Fully Convolutional Network), což byla první metoda pro sémantickou segmentaci založená na hlubokém učení. Od té doby byly vyvinuty konkurenční architektury, jako je U-Net [15], SegNet [16] a další, které také v segmentačních úlohách dosahují vynikajícího výkonu.

3.2 Koncept extrakce relevantních vlastností pomocí transformace vizuálních dat do pravděpodobnostních map

Ve svých pracích týkajících se extrakce relevantních vlastností z vizuálních dat pomocí hlubokého učení autor navrhl a opakovaně v různých úlohách aplikoval koncept transformace vizuálních dat do skupiny pravděpodobnostních map. Tento koncept lze s výhodou použít pro extrakci relevantních vlastností v úlohách typu detekce, lokalizace a stanovení prostorové orientace objektů ve vizuálních datech.

3.2.1 Pravděpodobnostní mapa

Pravděpodobnostní mapou se myslí prostorová distribuce pravděpodobností, která přiřazuje každému bodu v mřížce nebo pixelu v obraze pravděpodobnost, že tento bod patří do určité třídy nebo kategorie. Pravděpodobnostní mapa nabývá hodnot mezi 0 a 1, kde hodnota blízká se 1 indikuje vysokou pravděpodobnost, že daný bod náleží k dané třídě, a hodnota blízká se 0 indikuje nízkou pravděpodobnost.


V pracích Petra Doležela se pravděpodobnostní mapa deformuje tím, že se skládá výhradně z různých geometrických tvarů vyplněných gradientní plochou, přičemž gradient roste směrem od okraje (hodnota blízká se 0) k centroidu tvaru

(hodnota rovna 1). Velikost, tvar, orientace, poloha maximální hodnoty, strmost gradientu a další vlastnosti těchto geometrických tvarů se využívají k efektivnímu ukládání hodnot relevantních vlastností do pravděpodobnostní mapy.

3.2.2 Transformace vizuálních dat do skupiny deformovaných pravděpodobnostních map

Transformace do skupiny pravděpodobnostních map je uplatňována pro efektivní extrakci relevantních vlastností do schématické struktury, kterou je možno dále zpracovat za účelem vyřešení požadovaného úkolu (detekce, lokalizace atd.)

Existuje-li ve vstupních vizuálních datech n typů relevantních vlastností, kde každá vlastnost je tvořena datovou strukturou obsahující m hodnot, je možno pomocí hlubokého učení transformovat vstupní data na n deformovaných pravděpodobnostních map, kde každá mapa ponese relevantní informace o každém typu vlastnosti. Situace je schematicky znázorněna na Obr. 2. Uspořádání na obrázku naznačuje, že volba tvaru reprezentujícího příslušné relevantní vlastnosti určuje množství a charakter doplňujících informací o vlastnosti. Například tvar odpovídající vlastnosti typu 1 nese informaci o poloze (souřadnice centroidu tvaru na pravděpodobnostní mapě) a informaci o velikosti oblasti zahrnující vlastnost typu 1 v obraze (velikost tvaru na pravděpodobnostní mapě). Tvar odpovídající vlastnosti typu 2 může nést informaci o poloze, velikosti, ale také orientaci v rovině týkající se relevantní vlastnosti typu 2, atd. Je třeba zmínit, že se jedná o příklad, přičemž třeba velikost tvaru v pravděpodobnostní mapě může reprezentovat celou řadou jiných veličin spojených s relevantními vlastnostmi.



Obr. 2 Příklad transformace vizuálních dat do skupiny deformovaných pravděpodobnostních map.

3.2.3 Postup návrhu systému pro extrakci relevantních vlastností pomocí transformace vizuálních dat do pravděpodobnostních map

V souladu s obecnými principy návrhu systému založeného na hlubokém učení je třeba implementovat následující kroky.


1. Definování datasetu – získání nebo vytvoření vhodného datasetu, který obsahuje páry vstupních vizuálních dat a odpovídajících pravděpodobnostních map pro každý požadovaný typ vlastnosti. Pro dataset je třeba ručně nebo automaticky provést anotaci pravděpodobnostních map pro každý relevantní typ vlastnosti ve vstupních vizuálních datech. Dále je třeba provést rozdělení datasetu na trénovací, validační a testovací sady. Trénovací sada bude použita k trénování modelu, validační sada k ladění hyperparametrů a testovací sada k vyhodnocení finálního modelu.
2. Předzpracování dat – přizpůsobení vizuálních dat a pravděpodobnostních map do formátu, který lze snadno zpracovávat v hlubokém učení. To může zahrnovat normalizaci hodnot pixelů, změnu velikosti obrázků a další úpravy.
3. Výběr architektury modelu a její implementace – zvolení vhodné architektury modelu založeného na hlubokém učení, která umožní zpracování vizuálních dat a generování pravděpodobnostních map. Je možno volit ze široké skupiny dosud publikovaných plně konvolučních neuronových sítí, jejich variant, či je možno navrhnout nový typ architektury.
4. Trénování modelu – trénování modelu na trénovací sadě pomocí vybraného algoritmu trénování. Cílem je minimalizovat ztrátovou funkci a naučit model správně generovat pravděpodobnostní mapy.
5. Ladění hyperparametrů – nalezení vhodných hodnot hyperparametrů modelu, jako je velikost trénovací dávky, počet epoch trénování, rychlost učení, počet a typ vrstev v modelu a podobně. Ladění se vyhodnocuje pomocí stanovení hodnoty ztrátové funkce na validační sadě.
6. Evaluace a testování – ověření modelu na testovací sadě a vyhodnocení jeho výkonu. Srovnání predikovaných pravděpodobnostních map s pravděpodobnostními mapami v testovací sadě pomocí vybraných kritérií.
7. Optimalizace – vylepšování modelu na základě zjištění během evaluace. Optimalizace výpočetní náročnosti, případně návrat k některému z předchozích bodů, pokud je výkon modelu nedostatečný.

8. Implementace modelu do nadřazeného systému – zařazení vyvinutého modelu do systému řešícího požadovaný problém.

Představený postup návrhu byl úspěšně implementován v rámci několika vědeckých publikací i aplikačně orientovaných projektů. Výčet nejzajímavějších aplikací je představen v následujících kapitolách, přičemž první z nich je popsána podrobněji, ostatní jsou pouze stručně zmíněny.


3.3 Efektivní detekce úchopových bodů pro automatickou manipulaci s netriviálními objekty

Výzkum v této oblasti byl zaměřen na problematiku manipulace robotických ramen s netriviálními objekty poskytujícími různé typy úchopových bodů. Standardní průmyslové úlohy zahrnují více náhodně umístěných, orientovaných a různě vzájemně sdružených objektů na dopravníkové pásu. Tvary objektů jsou zpravidla známy předem, avšak jejich pozice a orientace nikoliv. Detekční systém používaného robotického zařízení musí být rychlý a přesný, umožňující rychlé rozhodnutí o poloze úchopových bodů a současně musí být zajištěna automatická výměna odpovídajícího koncového efektoru robotického ramene. Příklad takové situace je uveden na Obr. 3.




Obr. 3 Příklad uvažovaného robotického systému. Pásový dopravník přiváží předměty k manipulaci, průmyslová kamera snímá RGB obraz scény a detekční systém určuje polohu a orientaci úchopových bodů. Cílem systému je, aby robotické rameno, které je vybaveno dvěma druhy koncových efektorů, efektivně umisťovalo objekty do požadovaných poloh.

V rámci studie byl vyvinut a otestován systém pro současnou detekci všech přítomných a dostupných úchopových bodů se zaměřením na různé koncové efekторы se třemi stupni volnosti, tj. koncové efekторы s volnou polohou a pevnou prostorovou orientací (gripper, vakuové savky, šroubováky atd.). Pro přehlednost byl dále zvažován jeden typ objektu pro manipulaci a dva typy koncových efektorů, jak je znázorněno na Obr. 4.



Obr. 4 Koncové efekторы – gripper a vakuová savka (vlevo) a objekt k manipulaci (vpravo).


Takto zvolené uspořádání poskytuje pět různých poloh a až dva úchopové body pro paralelní gripper a žádný nebo jeden úchopový bod pro vakuovou savku. Všechny možné polohy jsou uvedeny na Obr. 5.



Obr. 5 Reálné reprezentace objektu (nahore) a úchopové body objektu v různých polohách (dole). Všechny možné úchopové body jsou zvýrazněny symbolem gripperu a symbolem vakuové savky. Poslední poloha neposkytuje žádný úchopový bod.

Zároveň bylo třeba vzít v úvahu vzájemné ovlivňování dostupnosti úchopových bodů v závislosti na uspořádání scény. Polohy jiných objektů totiž často znemožňují reálné uchopení objektu. Některé takové případy jsou znázorněny na Obr. 6. Přirozeně se očekává, že vyvinutý systém detekce nebude detekovat nedostupné úchopové body.

Řešení návrhu systému extrakce relevantních vlastností pomocí transformace vizuálních dat do pravděpodobnostních map pro detekci dostupných úchopových bodů je popsáno v následujících odstavcích.



Obr. 6 Úchopové body náhodně umístěných objektů s nepravidelnými kontakty nebo vzájemnými překryvy (vybrané příklady). Všechny dostupné úchopové body jsou zvýrazněny.

3.3.1 Reprezentace relevantních vlastností pomocí deformovaných pravděpodobnostních map

Úkolem bylo detekovat a lokalizovat dva typy úchopových bodů ve scéně (tj. úchopový bod pro gripper a pro vakuovou savku). Pro vakuovou savku je třeba

znát pouze polohu optimálního bodu pro uchopení, zatímco pro gripper je také potřeba detekovat vhodný úhel natočení koncového efektoru. Z tohoto důvodu byl pro reprezentaci úchopového bodu vakuové savky zvolen kruh, zatímco pro gripper elipsa. Následující rovnice slouží pro výpočet hodnot pixelů deformovaných pravděpodobnostních map pro jednotlivé reprezentace – (1a, 1b) pro vakuovou savku a (2) pro gripper.

$$\text{label}_x = \frac{R-d_{0x}}{R} \text{ pro } d_{0x} < R, \quad (1a)$$


$$\text{label}_x = 0 \text{ pro } d_{0x} \geq R, \quad (1b)$$

kde d_{0x} je vzdálenost mezi aktuálním pixelem a optimální polohou uchopovacího bodu a R je parametr představující poloměr tvaru.


$$\text{label}_x = \left(\frac{d_{12}}{d_{1x}+d_{2x}} \right)^a \frac{1}{1+bd_{0x}^c}, \quad (2)$$

kde d_{12} je délka úsečky, tj. vzdálenost mezi body, které definují úchopový bod; d_{1x} je vzdálenost mezi aktuálním pixelem a prvním koncovým bodem úsečky; d_{2x} je vzdálenost mezi aktuálním pixelem a druhým koncovým bodem úsečky; d_{0x} je vzdálenost mezi aktuálním pixelem a středem úsečky. Parametry a , b , c ovlivňují velikost obrazce a je třeba je nastavit podle vlastností scény.

Situace je znázorněna na Obr. 7 a na Obr. 8.




Obr. 7 Zobrazení úchopového bodu pro vakuovou savku. Ve zdrojovém obraze je úchopový bod znázorněn žlutým kruhem. Hodnoty jednotlivých pixelů vypočtené podle rovnice (1a, 1b) jsou reprezentovány intenzitami (vpravo); čím vyšší je intenzita, tím blíže je hodnota k 1, černá barva se rovná 0. Vzhledem k předložené reprezentaci je optimální poloha uchopovacího bodu definována středem gradientního kruhu (tj. maximální intenzitou).



Obr. 8 Repräsentace úchopového bodu pro gripper. Úchopový bod je ve zdrojovém obraze (vlevo) znázorněn žlutou úsečkou; koncové body jsou zvýrazněny kolečky. Hodnoty jednotlivých pixelů vypočtené podle rovnice (2) jsou reprezentovány intenzitami (vpravo); čím vyšší je intenzita, tím blíže je hodnota k 1. Černá barva je rovna 0. Vzhledem k prezentované reprezentaci je optimální poloha uchopovacího bodu definována středem tvaru (tj. maximální intenzitou) a požadovaný úhel (orientace) gripperu je definován nejpozvolnějším poklesem intenzity.

Takto definované reprezentace úchopových bodů přímo poskytují všechny potřebné informace pro robotické rameno k manipulaci s objektem, tedy polohu pro vakuovou savku a polohu a úhel natočení pro gripper.

Úkolem tedy bylo navrhnout vhodný model hlubokého učení, který transformuje scénu reprezentovanou vizuálními daty na dvojici deformovaných pravděpodobnostních map reprezentujících definované relevantní vlastnosti. Schéma je znázorněno na Obr. 9.



Obr. 9 Model hlubokého učení k transformaci vizuálních dat na dvojici deformovaných pravděpodobnostních map, kde jsou polohy úchopových bodů zvýrazněny jako gradientní tvary.


3.3.2 Dataset

Pro získání potřebného datasetu bylo vytvořeno robotické pracoviště podle Obr. 10. Bylo sejmuto 780 unikátních scén. Výsledná kolekce snímků obsahovala 0 až 9 objektů tří barev (modrá, bílá, šedá) v různých polohách a pozicích. Mnoho snímků obsahovalo pouze části objektů. Rozlišení snímků bylo 288×288 pixelů RGB s 8bitovou hloubkou.

Pro každý snímek bylo třeba určit polohy úchopových bodů a připravit dvojici deformovaných pravděpodobnostních map. Proto byla vytvořena vlastní aplikace (Obr. 11). 54 náhodně vybraných snímků bylo umístěno do testovací množiny.



Obr. 10 Robotické stanoviště pro sběr dat. Zájmové objekty jsou rozptýleny na dopravním pásu. Pro sběr vizuálních dat se používá průmyslová kamera umístěná nad scénou. V hliníkovém profilu v blízkosti kamery je umístěno liniové LED světlo.



Obr. 11 Označování datových sad pomocí vlastní aplikace. Každý úchopový bod na každém snímku je ručně označen a transformován do dvojice pravděpodobnostních map.


3.3.3 Výběr architektury modelu a její implementace

Pro řešení úkol byla vyvinuta vlastní architektura modelu hlubokého učení. Jako výchozí architektura byla použita síť U-Net [15]. U-Net je plně konvoluční neuronová síť, která byla původně navržena pro úlohy segmentace biologických a lékařských obrazů. Od té doby však byla přizpůsobena mnoha dalším aplikacím.

Sleduje typickou architekturu enkodér-dekodér s úzkým hrdlem. Nicméně obsahuje také přímé signály z části enkodéru do části dekodéru, které umožňují síti šířit kontextové informace do vrstev s vyšším rozlišením. U-Net architektura se velmi osvědčila při sémantické segmentaci obrazu, zejména v případech, kdy jsou k dispozici pouze malé trénovací soubory dat [17]. U-Net je však definována více než 30 miliony parametrů s velikostí potřebné paměti 364 MB, čímž se příliš nehodí pro embedded systémy. Z tohoto důvodu byly klasické konvoluční a transponované konvoluční vrstvy nahrazeny jejich redukovanými verzemi. Podle [18] mohou tyto náhrady zajistit více než desetinásobné snížení parametrů při zachování původní přesnosti.

Další vylepšení vychází ze skutečnosti, že cílem sítě bylo detekovat relevantní vlastnosti umístěné na objektech několika barev za různých světelných podmínek. Proto byl implementován tzv. attention mechanismus [19].


Poslední vylepšení vychází z informace, že model by měl generovat dvě pravděpodobnostní mapy, z nichž každá by měla poskytovat informace o jednom typu úchopového bodu. Vzhledem k této skutečnosti by bylo výhodné v určitém okamžiku paralelizovat šíření dat modelem, aby bylo možné zajistit oddělenou část architektury pro zpracování každého typu relevantní vlastnosti. Proto byla část původní architektury U-Net replikována a zrcadlena. Obě paralelní části byly spojeny v závěrečném úseku sítě. Díky tomuto vylepšení se očekává, že model přizpůsobí své parametry tak, aby v jedné paralelní větvi zpracovával prvky relevantní pro gripper a v druhé větvi prvky relevantní pro vakuovou savku. Výsledná architektura modelu byla nazvána ASP U-Net a její zjednodušené schéma je uvedeno na Obr. 12.



Obr. 12 ASP U-Net. Vstupní vizuální data jsou zpracována dvěma konvolučními vrstvami. Poté je signál rozdělen do dvou paralelních větví, z nichž každá zpracovává jiný typ relevantních vlastností. Obě větve jsou pak spojeny a zpracovány sekvencí konvolučních vrstev. Poslední konvoluční vrstva se sigmoidální aktivační funkcí a 2 filtry poskytují výstupní pravděpodobnostní mapy. Parametr n slouží ke škálování modelu.


3.3.4 Implementace modelu

Po procesu trénování, ladění hyperparametrů, testování a optimalizace byl výsledný model implementován pro extrakci relevantních vlastností z vizuálních dat v systému detekce dostupných úchopových bodů podle Obr. 10. Příklady výsledného chování jsou uvedeny na Obr. 13, Obr. 14, a Obr. 15.




Obr. 13 Odezva modelu ASP U-Net na scénu se dvěma objekty. Dvojice vlevo představuje situaci, kdy není ovlivněna dosažitelnost úchopových bodů. Na snímcích vpravo

sousední hrany neumožňují použití gripperu. Proto nejsou tyto úchopové body modelem označeny.



Obr. 14 Odezva modelu ASP U-Net na scénu se dvěma nepravidelně umístěnými objekty. Za povšimnutí stojí, že na levých snímcích je prostor úchopového bodu (modrý objekt, pravý okraj) zmenšen oproti původní velikosti kvůli blízké poloze bílého objektu. Uvažované uchopení pomocí gripperu by se však do zmenšeného místa stále vešlo. Na pravé dvojici snímků, kde se bílý objekt nachází více nahoře, je úchopový bod zcela zamítnut, protože v tomto případě by se gripper do tohoto místa vůbec nevešel (tj. úchopový bod nesplňuje požadavky na minimální rozměr).




Obr. 15 Odezva modelu ASP U-Net na scénu se skupinou náhodně rozmístěných objektů.

Model ASP U-Net je obecně použitelný pro simultánní detekci úchopových bodů vhodných pro různé typy koncových efektorů robotických ramen. V této studii byl tento model využit pro detekci a lokalizaci úchopových bodů pro gripper a vakuovou savku. Jak je ukázáno výše, tento přístup nejen detekuje vhodné typy úchopových bodů, ale také je schopen poskytnout informace pouze o úchopových bodech reálně dostupných pro robotické rameno.


3.3.5 Rozšíření pro RGB-D vizuální data

V případě nutnosti zohledňovat více vrstev objektů ve snímané oblasti lze do vstupních vizuálních dat zahrnout hloubkovou mapu snímané oblasti. Model hlubokého učení pak v rámci velikosti poskytovaných tvarů v deformovaných pravděpodobnostních mapách může poskytnout informaci o lákavosti konkrétních úchopových bodů pro robotické rameno. Příklad takové situace je uveden a popsán na Obr. 16.


Vstupní vizuální data včetně hloubkové mapy



Pravděpodobnostní mapa typ 1



Pravděpodobnostní mapa typ 2



Obr. 16 Odezva modelu ASP U-Net na scénu se skupinou náhodně rozmístěných objektů ve více vrstvách. V tomto řešení je do velikosti poskytovaných objektů zakódována lákavost úchopového bodu pro uchopení robotickým ramenem. Největší objekt (v přerušovaném čtverci) tedy zároveň definuje předmět k uchopení.

3.3.6 Výstupy tvůrčí činnosti spojené s představeným řešením

Představené řešení bylo vyvinuto v rámci prací na projektu PosiTrans². Popisovaný postup je podrobně k dispozici v publikaci [20]. Aplikace pro detekci těžišť objektů je uvedena v [21]. Proces optimalizace návrhu ASP U-Net je uveden v [22]. Představené řešení bylo prakticky implementováno při řešení projektu MPO Aplikace³.

² OPVVV: EF17_049/0008394 Spolupráce Univerzity Pardubice a aplikační sféry v aplikačně orientovaném výzkumu lokačních, detekčních a simulačních systémů pro dopravní a přepravní procesy (PosiTrans), 2018-2022 (řešitel)

³ MPO Aplikace: CZ.01.1.02/0.0/0.0/20_321/0024390 Výzkum a vývoj modulární automatizované výrobní linky na bázi inovovaných robotických modulů a její aplikace na výrobu lékařských katetrů, 2021-2023

3.4 Efektivní detekce hlav cestujících v prostředcích hromadné dopravy


Ve veřejné dopravě má sledování pohybu osob nezastupitelný význam. V některých oblastech veřejné dopravy jsou používány systémy sledování pohybu cestujících, které tuto úlohu automatizují. Jednou z klíčových funkcí, které musí tyto systémy poskytovat, je informace o počtu přepravených cestujících. Přesné počítání cestujících při nástupu a výstupu z dopravních prostředků pozitivně ovlivňuje dohled nad veřejnou dopravou, předpověď toku cestujících, plánování dopravy, monitorování zatížení dopravních prostředků, řízení a správu stanic a optimalizaci nákladů [23], [24].

Pro zajištění robustního a přesného počítání cestujících v reálném čase musí být systém sledování pohybu cestujících založen na vhodném nástroji počítačového vidění a robustním algoritmu zpracování dat. S ohledem na masové nasazení takového monitorovacího systému je stejně důležité, aby daný systém byl finančně dostupný. Zároveň musí být dodržena legislativní omezení spočívající zejména v zachování anonymity cestujících.

Klíčovým krokem systému počítačového vidění pro počítání osob je detekce osob. V této studii je popsáno využití extrakce relevantních vlastností pomocí transformace vizuálních dat do pravděpodobnostních map pro detekci osob v ortogonálně snímaných scénách.

3.4.1 Reprezentace relevantních vlastností pomocí deformovaných pravděpodobnostních map

Úkolem je detekovat hlavy cestujících ve vizuálních datech. Jedná se tedy o jeden relevantní typ vlastnosti. Vzhledem k obecně elipsovitému tvarům hlav byla pro jejich reprezentaci v pravděpodobnostní mapě také zvolena elipsa. Pro zjednodušení anotačního procesu byly v datasetu pro návrh modelu hlubokého učení nejprve vytvořeny obdélníky těsně obklopující přítomné hlavy. Pro zajištění správné aproximace tvarů hlav, které nejsou ve scéně celým objemem, byly obdélníky odhadovány i mimo rozměry vstupních vizuálních dat. Takto získané obdélníky pak sloužily k výpočtu deformované pravděpodobnostní mapy. Situace je znázorněna na Obr. 17.




Obr. 17 Deformovaná pravděpodobnostní mapa pro anotované vstupní snímky. Za zmínku stojí odhad tvaru hlav, které nejsou na vstupním snímku celým objemem.

3.4.2 Implementace modelu

Po procesu výběru architektury modelu, trénování, ladění hyperparametrů, testování a optimalizace byl výsledný model implementován pro extrakci relevantních vlastností z vizuálních dat v systému detekce cestujících v městské hromadné dopravě.

Příklady deformovaných pravděpodobnostních map z reálného provozu, které sloužily pro efektivní stanovení polohy hlav osob ve vizuální mapě, jsou uvedeny na Obr. 18. Informace uvedené na obrázku indikují funkčnost systému v různých prostředích za různých světelných podmínek.



Obr. 18 Příklady vstupních vizuálních dat (nahore) a odpovídajících deformovaných pravděpodobnostních map (dole) při testování systému v reálném provozu městské hromadné dopravy. Na prostřední a pravé dvojici snímků je možné identifikovat objekty, které nejsou umístěny celým objemem ve sledované scéně.

3.4.3 Výstupy tvůrčí činnosti spojené s představeným řešením

Představené řešení bylo vyvinuto v rámci prací na projektu PosiTrans⁴. Popisovaný postup je podrobně k dispozici v publikaci [25]. Dílčí části představeného řešení byly publikovány také v článcích [26], [27], [28]. Představené řešení bylo prakticky implementováno při řešení projektu MPO Aplikace⁵ a při řešení smluvního výzkumu pro firmu Satec s.r.o.⁶

⁴ OPVVV: EF17_049/0008394 Spolupráce Univerzity Pardubice a aplikační sféry v aplikačně orientovaném výzkumu lokačních, detekčních a simulačních systémů pro dopravní a přepravní procesy (PosiTrans), 2018-2022 (řešitel)

⁵ MPO Aplikace: CZ.01.1.02/0.0/0.0/20_321/0024668 Výzkum a vývoj nové generace inteligentního systému FareOn NextGen, 2021-2023

⁶ Snímač pro detekci prokladových cihliček, Satec, s.r.o.


3.5 Efektivní detekce zájmových objektů ve sledovaném prostoru

Monitorování vzdušného prostoru je velmi důležitým tématem pro civilní i vojenskou obranu. S rostoucím počtem dronů a bezpilotních letadel je kladen klíčový důraz na střežení vzdušného prostoru kolem soukromých i veřejných budov [29].


Cílem studie bylo navržení a implementace přístupu k detekci objektů ve vzdušném prostoru na základě vizuálních dat poskytovaných monokulární kamerou umístěnou na zemi uprostřed střeženého prostoru. Monokulární kamera byla řízena nadřazeným řídicím systémem, který na základě informace z radaru detekoval podezřelý objekt, a cílem vyvíjeného systému bylo rozhodnout o konkrétním typu objektu detekovaného radarem.

K řešení byl využit koncept extrakce relevantních vlastností pomocí transformace vizuálních dat do pravděpodobnostních map.

Schéma vyvíjeného systému je uvedeno na Obr. 19. Detail implementované monokulární kamery je uveden na Obr. 20. Příklady objektů detekovaných při implementaci systému jsou uvedeny na Obr. 21.



Obr. 19 Schéma vyvíjeného systému.



Obr. 20 Detail monokulární kamery.



Obr. 21 Příklady vizuálních dat pro detekci zájmových objektů ve sledovaném prostoru.

3.5.1 Výstupy tvůrčí činnosti spojené s představeným řešením

Představené řešení bylo vyvinuto v rámci prací na projektu LTAIN19100⁷. Popisovaný postup je podrobně k dispozici v publikaci [30].

3.6 Další aplikace autora v oblasti využití modelů hlubokého učení pro zpracování obrazu a videa

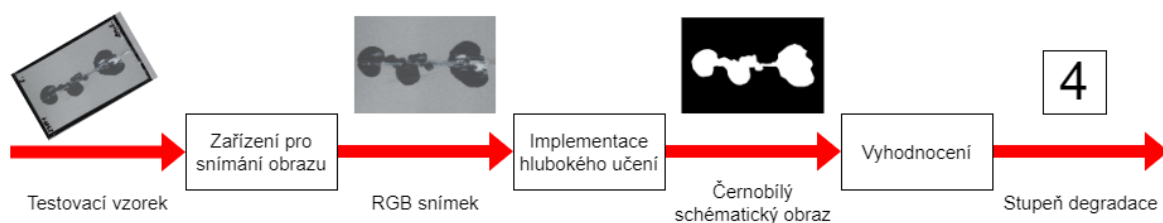
V této kapitole jsou prezentovány aplikace zpracování obrazu, které vznikly v rámci mezioborové spolupráce, případně v reakci na poptávku aplikační sféry. Ačkoliv se jedná zpravidla o jednoúčelová řešení plnící zadaný úkol, ilustrují tyto projekty možnosti využití technologie zpracování obrazu k řešení komplexních problémů, jež by jinak byly jen obtížně dosažitelné.

⁷ INTER-EXCELLENCE: LTAIN19100 Vývoj bezkontaktní technologie pro inteligentní ochranu zájmových prostor, 2020-2022

3.6.1 Digitální zpracování obrazu pro stanovení degradace polymerů a nátěrových hmot

Tato práce byla realizována na přímou poptávku společnosti METAL TRADE COMAX, a.s., která se mimo jiné zabývá aplikací ochranných vrstev na kovové struktury za účelem omezení degradace materiálu. Pro měření odolnosti ochranné vrstvy nátěrové hmoty byla vydána norma ČSN ISO 4628 zabývající se zpracováním a kvantifikací hlavních vad ochranných vrstev. Cílem práce byl návrh, implementace a ověření systému zpracování obrazu pro použití při vyhodnocení kvality testovaných nátěrových hmot podle této normy. Navržený systém implementující model hlubokého učení úspěšně splnil požadavky na robustnost, zejména v podobě necitlivosti na lesk, zrnitost, barvu a jiné vlastnosti vyhodnocované nátěrové hmoty.

Schéma metody je uvedeno na Obr. 22. Spolupráce byla realizována formou smluvního výzkumu⁸. Metoda byla také podrobně představena v rámci publikace [31].



Obr. 22 Schéma metody pro hodnocení stupně degradace nátěru podle ČSN ISO 4628.

3.6.2 Automatizovaná kontrola svarů

Tato práce byla realizována na přímou poptávku společnosti KWD Bohemia, s.r.o., která se zabývá svařováním lehkých kovových konstrukcí, jež následně slouží v automobilovém průmyslu. Předmětem poptávky bylo řešení systému automatické kontroly kvality svarů na různých komponentech v rámci výrobního řetězce implementovaného v rámci výroby.


Řešení bylo vyvíjeno v rámci projektu TAČR⁹ a výstupem byl užitečný vzor systému k provádění automatizované kontroly svarů¹⁰. Výhodou představeného systému je dynamicky se učící model hlubokého učení, který je přes definovaná

⁸ Systém pro hodnocení míry degradace nátěrů, METAL TRADE COMAX, a.s.

⁹ Smart systém pro automatické vyhodnocování kvality svarů, GAMA02/012 (nadřazený projekt TG02010058 - Podpora aktivit proof-of-concept na Univerzitě Pardubice), TAČR, program GAMA

¹⁰ Systém k provádění automatizované kontroly svarů. Úřad průmyslového vlastnictví, 34543. 2020

rozhraní implementován do výrobní linky a synergicky spolupracuje s lidskými operátory na neustálém zlepšování svého výkonu. Zjednodušené schéma systému je uvedeno na Obr. 23. Za zmínku také stojí, že užitečný vzor byl licencován společností K2 Machine s.r.o.



Obr. 23 Schéma systému k provádění automatizované kontroly svarů.

3.6.3 Inteligentní firewall pro průmyslové sítě

Úkol v rámci těchto činností byl definován ve spolupráci s podnikem RONAL CR s.r.o. a byl řešen v rámci projektu TAČR¹¹. Cílem projektu bylo vytvoření inteligentního firewallu pro průmyslové sítě využívajícího principů hlubokého učení. Vyvinutý firewall umožňoval kromě tradičního povolení a blokování provozu také podrobnou inspekci na aplikační vrstvě, duplikaci zprávy, nebo klasifikaci toku pro službu QoS. Zvláštním principem realizovaným v rámci řešení byla procedura kódování vlastností síťového provozu do 2D struktur, které byly speciálně navrženy pro efektivní zpracování pomocí konvolučních neuronových sítí. Postup je podrobně popsán v rámci publikace [32].

4. PŘÍNOS AUTORA V OBLASTI ANALÝZY SIGNÁLU A ČASOVÝCH ŘAD

4.1 Úvod do problematiky

Analýza signálu a časových řad představuje klíčový aspekt například ve fyzice, medicíně, finančnictví a ve strojírenství. V posledních letech je pro řešení

¹¹ Inteligentní firewall pro průmyslové sítě, TJ01000358; TAČR, program ZÉTA

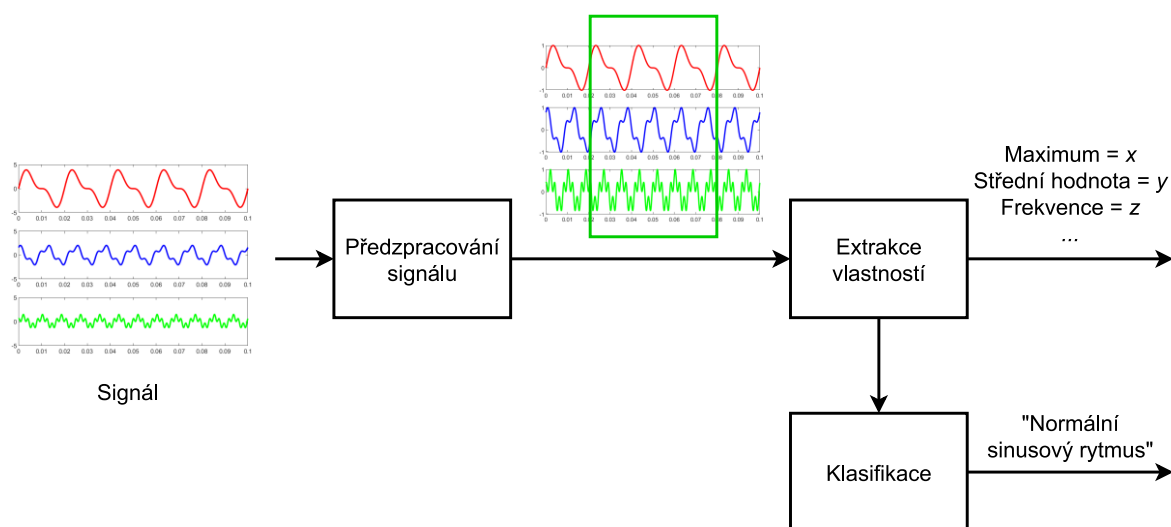
problémů v těchto oblastech možno pozorovat rapidní vzestup využití nástrojů hlubokého učení [33], [34]. Hluboké učení získalo pozornost zejména díky své schopnosti automaticky extrahovat a reprezentovat složité vzory v datech, což umožňuje efektivní a výkonnou analýzu signálu i časových řad.

Dosavadní metody analýzy signálu a časových řad zahrnovaly tradiční statistické a matematické techniky, jako je Fourierova transformace, autoregresní modely, nebo vlnková transformace [35], [36]. Tyto metody se osvědčily, avšak často narážely na komplexní nebo neúplné vzory v datech, které nebyly pomocí těchto metod snadno detekovatelné. Naproti tomu konvoluční neuronové sítě, rekurentní neuronové sítě či generativní adversariální sítě jsou úspěšně aplikovanými typy modelů, které jsou schopny efektivně odhalovat invariantní znaky a abstraktní vzory [37], čímž umožňují dosáhnout nové úrovně analýzy signálu. Do zpracování signálu a časových řad přinesly modely založené na hlubokém učení následující prvky [38].

- Hierarchické zpracování – hierarchická struktura hlubokých sítí umožňuje efektivní zpracování komplexních vzorů a reprezentací na více úrovních abstrakce.
- End-to-End modelování – schopnost end-to-end modelování umožňuje hlubokým sítím zpracovávat signál a časové řady jako komplexní entity bez nutnosti manuálně definovaných příznaků.
- Adaptabilita – modely jsou schopny se adaptovat na nové vzory v datech a reagovat na jejich evoluční charakter.

Analýza signálu nebo časových řad pomocí hlubokého učení zahrnuje několik klíčových kroků. Možné schéma celého procesu je zobrazeno na Obr. 24. Předzpracování signálu je zahájeno již sběrem surových dat, která následně podléhají filtraci, normalizaci a segmentaci na úseky o stejných délkách. Během tohoto procesu jsou odstraněny nebo potlačeny nežádoucí artefakty, šумы a výkyvy. Výsledkem je harmonizovaný a normalizovaný signál, který je připraven k další analýze. Následuje extrakce relevantních vlastností ze signálu, která je provedena pomocí modelu hlubokého učení trénovaného na robustním množství dat. Model je navržen tak, aby automaticky identifikoval klíčové vzory a charakteristiky. Modely hlubokého učení jsou obecně schopny detekovat v signálu vlastnosti, které nejsou klasickými metodami rozpoznatelné [39]. Cílem klasifikace pomocí modelu hlubokého učení je generalizovat a klasifikovat nové neznámé signály na základě naučených vzorů. Klasifikace se provádí v rámci různých tříd nebo kategorií, které jsou definovány specifikacemi úkolu. Modely

hlubokého učení mohou v rámci hierarchické architektury zahrnovat některé nebo i všechny kroky uvedené na Obr. 24.



Obr. 24 Příklad schématu pro extrakci vlastností ze signálů nebo časových řad. Extrakce vlastností ze signálu poskytuje konkrétní vlastnosti zkoumaného signálu, klasifikace přímo přiřazuje signálu třídu, do které signál náleží.

Pro návrh modelu hlubokého učení za účelem extrakce dat nebo klasifikace signálu je třeba obecně implementovat následující kroky.

1. Definování datasetu – získání nebo vytvoření vhodného datasetu, který obsahuje signály různých tříd a variant v rámci těchto tříd. Pro signály v datasetu je třeba ručně nebo automaticky provést rozdělení do požadovaných tříd, případně definovat a stanovit očekávané hodnoty extrahovaných vlastností. Je dále třeba provést rozdělení datasetu na trénovací, validační a testovací sady. Trénovací sada bude použita k trénování modelu, validační sada k ladění hyperparametrů a testovací sada k vyhodnocení finálního modelu.
2. Předzpracování dat – přizpůsobení signálů v datasetu do formátu, který lze snadno zpracovávat v hlubokém učení. To může zahrnovat normalizaci délky signálů, jeho hodnot, úpravu vzorkovací frekvence a podobně.
3. Výběr architektury modelu a její implementace – zvolení vhodné architektury modelu založeného na hlubokém učení, která umožní zpracování signálu, extrakci požadovaných vlastností, či klasifikaci do určené třídy. Pro zohlednění časových závislostí se volí rekurentní neuronové sítě, pro zpracování prostorových vlastností signálu konvoluční neuronové sítě. V poslední době se pozornost upíná

ke generativním adversariálním sítím a architekturám typu transformer [40].

4. Trénování modelu – trénování modelu na trénovací sadě pomocí vybraného algoritmu trénování. Cílem je minimalizovat ztrátovou funkci a naučit model správně extrahovat vlastnosti či klasifikovat signál.
5. Ladění hyperparametrů – nalezení vhodných hodnot hyperparametrů modelu, jako je velikost trénovací dávky, počet epoch trénování, rychlost učení, počet a typ vrstev v modelu a podobně. Ladění se vyhodnocuje pomocí stanovení hodnoty ztrátové funkce na validační sadě.
6. Evaluace a testování – ověření modelu na testovací sadě a vyhodnocení jeho výkonu. Srovnání predikovaných výsledků s očekávanými výsledky v testovací sadě pomocí vybraných kritérií.
7. Optimalizace – vylepšování modelu na základě zjištění během evaluace. Optimalizace výpočetní náročnosti, případně návrat k některému z předchozích bodů, pokud je výkon modelu nedostatečný.
8. Implementace modelu do nadřazeného systému – zařazení vyvinutého modelu do systému řešícího požadovaný problém.

Tento generický metodologický přístup k návrhu modelů hlubokého učení byl efektivně využit v rámci řešení řady úkolů zahrnujících jak základní, tak aplikovaný výzkum. Nejvýznamnější aplikace jsou představeny v následujících odstavcích, přičemž první z těchto aplikací je popsána detailněji, zatímco ostatní jsou pouze stručně zmíněny.

4.2 Model hlubokého učení pro extrakci vlastností z teplotních průběhů relaxační dynamiky v amorfních materiálech v oblasti skelného přechodu

Skelné přechody jsou klíčovým jevem amorfních materiálů, přičemž mají významný potenciál pro využití v širokém spektru aplikací, včetně elektroniky, medicíny a průmyslu [41], [42]. Jednou z nejdůležitějších a určujících vlastností amorfních materiálů je jejich teplota skelného přechodu, pod kterou se materiál chová jako sklovitá pevná látka, a nad kterou se chová jako přechlazená kapalina. Teplota skelného přechodu je klíčovým parametrem, který ovlivňuje mechanické, tepelné a transportní vlastnosti amorfních materiálů. Přesná charakterizace teplot skelného přechodu a s nimi spojených parametrů je proto nezbytná pro pochopení a využití těchto materiálů.

Toolův-Narayanaswamyův-Moynihanův (TNM) model [43], [44] je často používaný empirický model, který popisuje entalpickou relaxaci amorfních

materiálů v blízkosti teploty skelného přechodu. TNM Model je založen na konceptu strukturní relaxace, ke které dochází při přechodu materiálu z metastabilního stavu do stabilnějšího. Navzdory svému rozšíření má TNM model řadu omezení. Jedním z hlavních problémů je stanovení vhodných hodnot jeho parametrů. Tento úkol často komplikuje skutečnost, že parametry jsou vzájemně závislé a mohou se lišit v závislosti na materiálu a experimentálních podmínkách. Přesto je přesné stanovení parametrů TNM modelu nezbytné pro přesné předpovědi entalpického relaxačního chování a teplot skelného přechodu.

Jednou z metod stanovení parametrů TNM modelu je entalpická diferenciální skenovací kalorimetrie (DSC) [45], která měří teplo absorbované nebo uvolněné materiálem při řízeném teplotním programu. Opakovaným vystavováním materiálu teplotním cyklům a měřením entalpické odezvy lze získat soubor křivek diferenční skenovací kalorimetrie (DSC křivky), které lze následně analyzovat a získat parametry TNM modelu. Tento proces je však časově náročný a k získání přesných a reprodukovatelných výsledků vyžaduje kvalifikovaný personál. K řešení tohoto problému však lze vyvinout pokročilý model hlubokého učení, který bude extrahovat parametry TNM modelu přímo ze souboru DSC křivek. Tento přístup má potenciál výrazně snížit čas a pracnost potřebnou pro stanovení parametrů TNM modelu a zároveň zlepšit přesnost a reprodukovatelnost výsledků.

V rámci představené studie byl navržen model hlubokého učení, přesněji řečeno multiškálová konvoluční neuronová síť [46], která dokáže extrahovat parametry TNM modelu sklotvorných materiálů ze souboru jejich DSC křivek.

4.2.1 Dataset

TNM model je definován následujícími rovnicemi.


$$\Phi(t) = \exp \left[- \left(\int_0^t \frac{dt}{\tau(T, T_f)} \right)^\beta \right], \quad (3a)$$

$$\tau(T, T_f) = A \cdot \exp \left[\chi \frac{\Delta h^*}{RT} + (1 - \chi) \frac{\Delta h^*}{RT_f} \right], \quad (3b)$$

kde $\Phi(t)$ je relaxační funkce dané vlastnosti, t je čas, $\tau(T, T_f)$ je relaxační čas, β je neexponenciální parametr, A je preexponenciální faktor, χ je parametr nelinearity, Δh^* je zdánlivá aktivační energie strukturní relaxace, R je univerzální plynová konstanta, T je teplota a T_f je fiktivní teplota, která je definována jako teplota přechlazené kapaliny se stejnou strukturou jako relaxační amorfní

materiál. Každý jev popsáný TNM modelem je definován čtyřmi parametry: $A, \Delta h^*, \chi$ a β [47].

Pro získání souboru parametrů TNM modelu je vždy nutné experimentálně získat vhodná data, která dostatečně popisují chování amorfního materiálu. Jednou z nejčastěji používaných metod získávání dat je aplikace tzv. klasických cyklů, kdy je vzorek amorfního materiálu opakovaně ochlazován při různých rychlostech ochlazování, zatímco ohřev je prováděn vždy stejnou rychlostí (viz levou část Obr. 25). Poté se sleduje normalizovaná tepelná kapacita c_p^N v závislosti na teplotě během každého kroku chlazení a ohřevu. Tato odezva tvoří DSC křivky. Obecný příklad empirických výsledků je uveden na Obr. 25. Je třeba poznamenat, že křivka je pro každý teplotní průběh mírně odlišná, tj. materiál vykazuje paměťový efekt.



Obr. 25 Průběh teplot (vlevo) a odpovídající sada DSC křivek (vpravo) pro studium relaxačního chování amorfních materiálů.

Cílem této studie bylo vytvořit multiškálový konvoluční neuronový model, který bude zpracovávat DSC křivky (pravá část Obr. 25), a následně poskytnout hodnoty parametrů $A, \Delta h^*, \chi$ a β .

Pro trénování modelu hlubokého učení bylo třeba připravit sadu dvojic vstup – očekávaný výstup. V tomto případě byla vstupní struktura reprezentována šesti DSC křivkami a výstupní strukturu tvořily čtyři parametry TNM modelu. Soubor dat byl vypočten pomocí algoritmu pro implicitní výpočet DSC křivek [45]. Tento proces je výpočetně náročný – výpočet pro jednu čtveřici parametrů TNM modelu

trvá na špičkovém počítači přibližně 10 minut. Pro účely této studie bylo vypočteno 5000 sad DSC křivek o délce 18501 bodů. Každý parametr TNM modelu pro každou vypočtenou sadu DSC křivek byl vybrán náhodně s rovnoměrným rozdělením pravděpodobnosti. Rozsahy jednotlivých parametrů byly definovány na základě přirozeně se vyskytujících hodnot ve skutečných amorfních materiálech a jsou uvedeny níže.

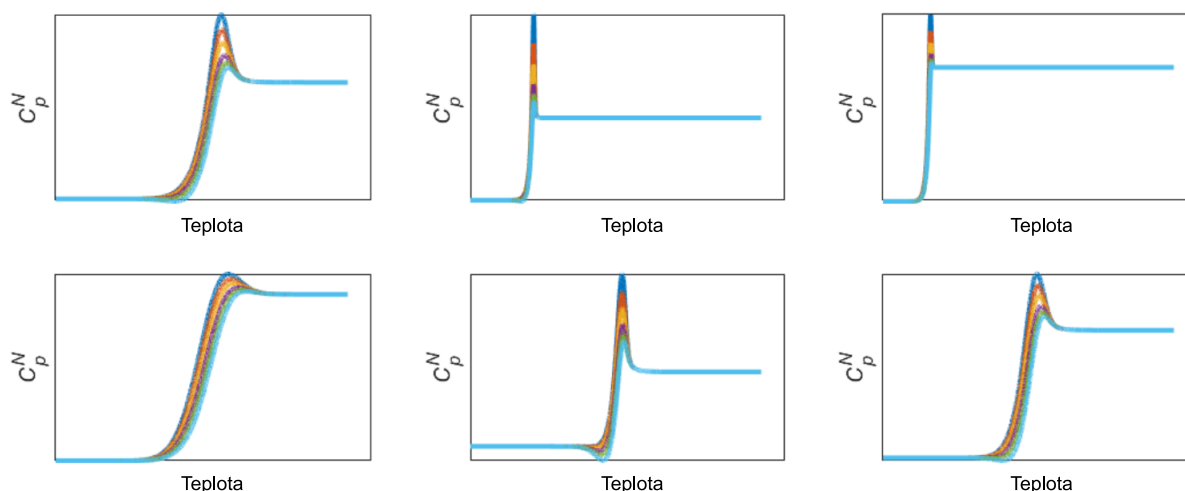
$$\log_e A: [-18; -630],$$

$$\Delta h^*: [2 \times 10^5; 12 \times 10^5] \text{ Jmol}^{-1},$$

$$\chi: [0,2; 1],$$

$$\beta: [0,2; 1].$$

1250 sad bylo zařazeno do testovací množiny. Pro účely trénování neuronového modelu byly hodnoty výstupu normovány na rozsah $[-1, 1]$. Příklady DSC křivek z datasetu jsou uvedeny na Obr. 26.

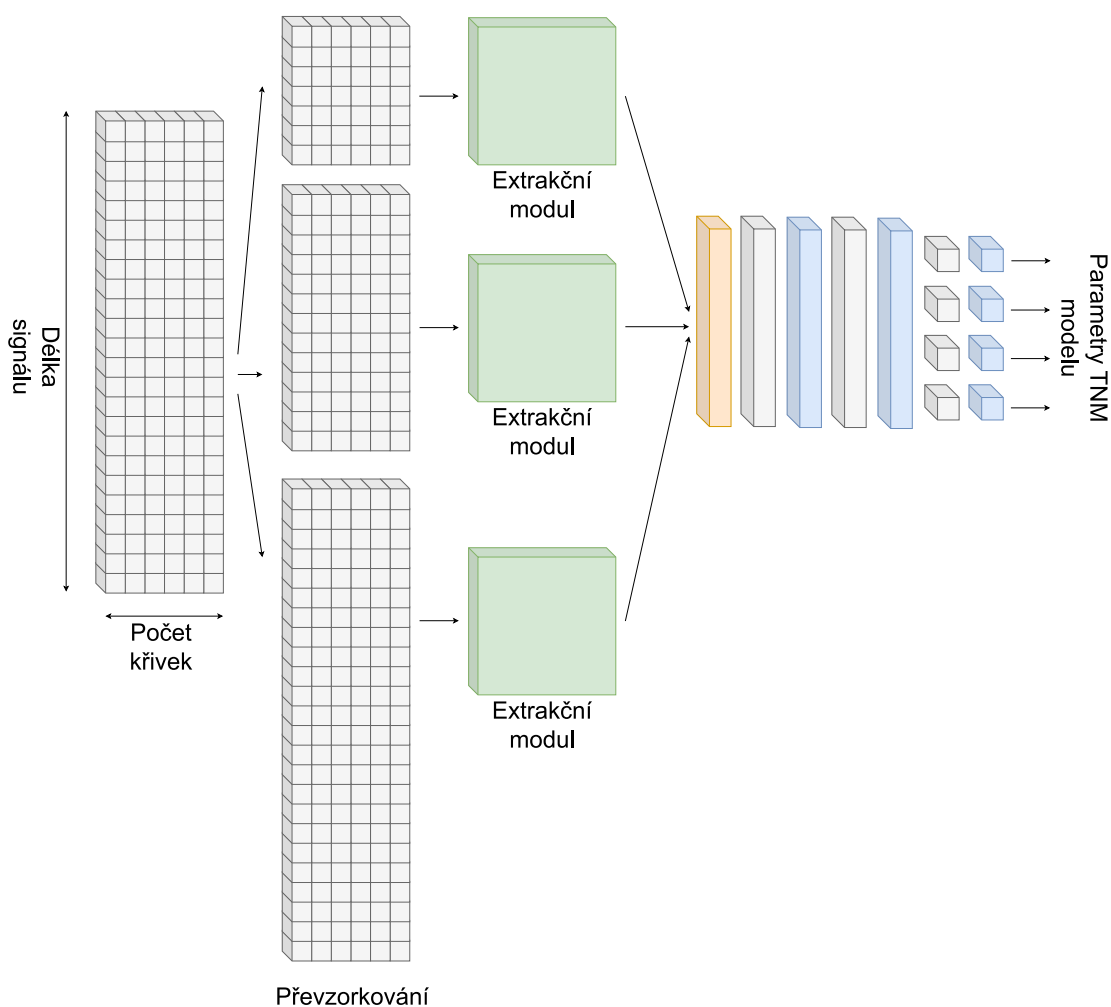


Obr. 26 Příklady DSC křivek použitých v datasetu v závislosti na zvolených parametrech TNM modelu.

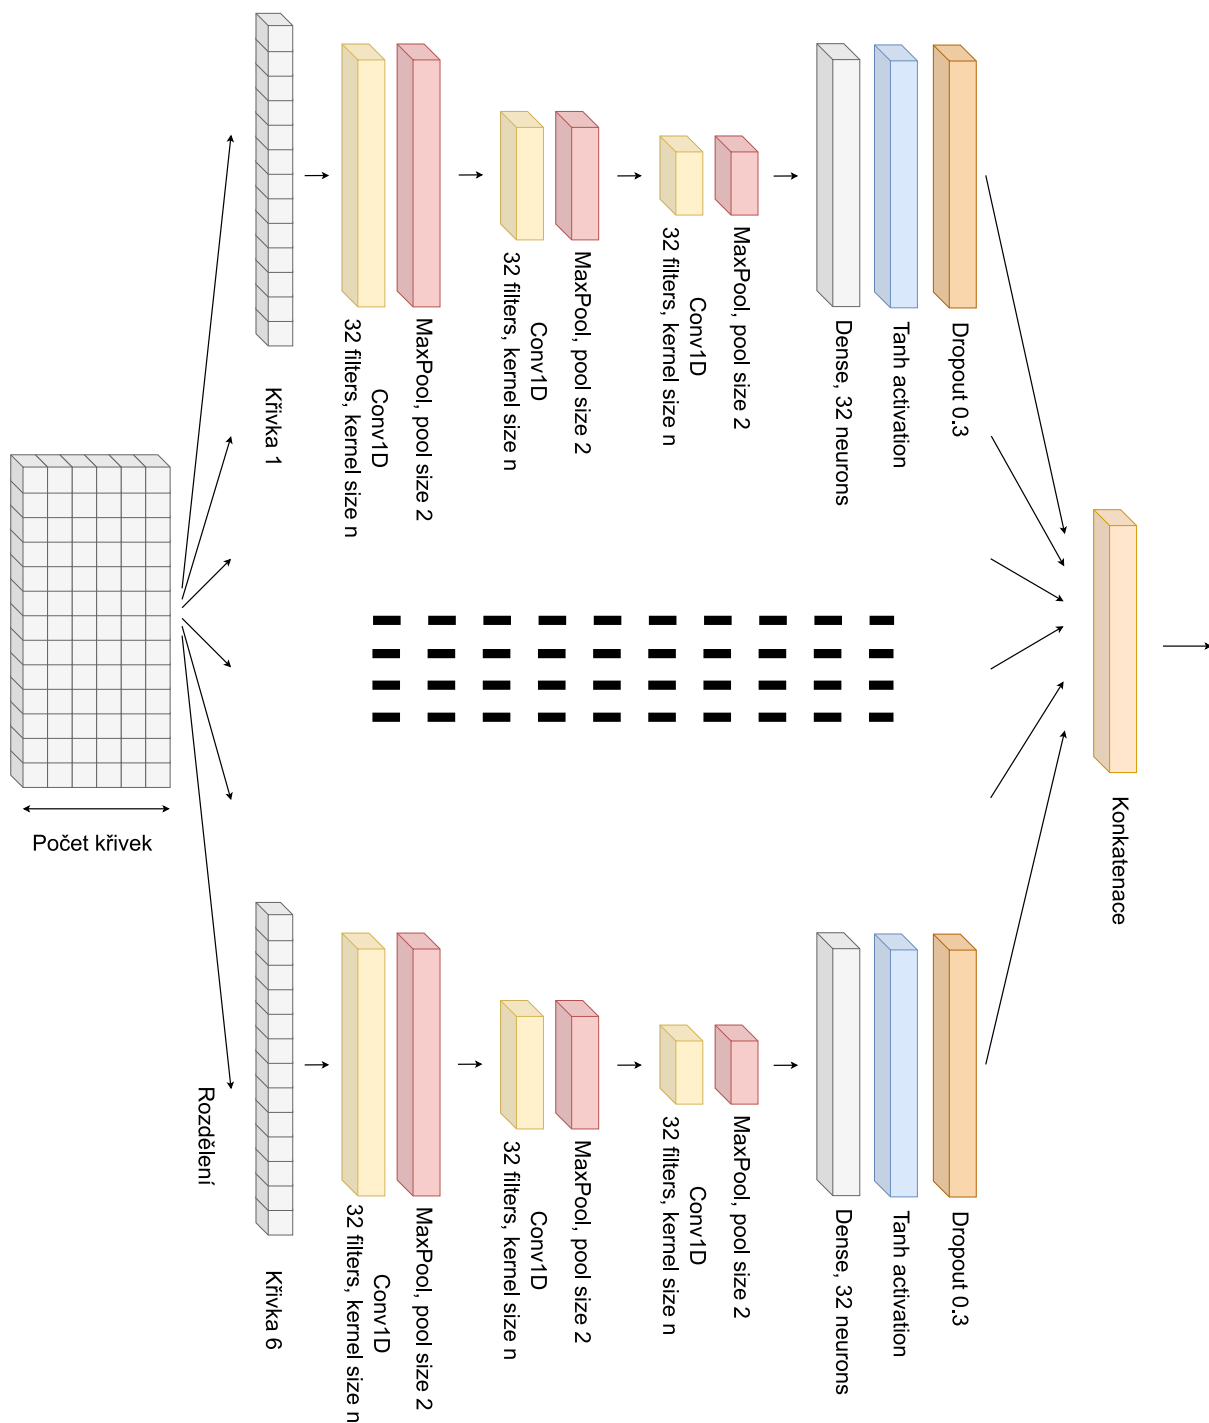
4.2.2 Výběr architektury modelu a její implementace

Pro řešení úkol byla vyvinuta vlastní architektura modelu hlubokého učení vycházející z principu multiškálových neuronových modelů. Jednou z klíčových výhod multiškálových modelů je jejich schopnost zpracovávat signály s různým frekvenčním obsahem. Díky pracovnímu rozsahu v různých měřítcích mohou multiškálové modely účinně zachytit jak nízkofrekvenční, tak vysokofrekvenční složky vstupních signálů [48].

Pro extrakci parametrů TNM modelu byl navržen hierarchický model hlubokého učení. Multiškálovost navrženého modelu je dosažena prostřednictvím úvodní sekce, která pracuje ve třech paralelních nezávislých větvích. Každá větev implementuje modul pro extrakci vlastností různé povahy, přičemž každá pracuje na jiném frekvenčním rozsahu. Každý extrakční modul navíc rozdělí šestici DCS křivek do samostatných větví a zpracovává každou z těchto šesti křivek nezávisle. Výstupy všech větví se poté spojí a výsledný signál se zpracuje dohromady pomocí řady plně propojených vrstev. Výstup navrženého modelu se skládá ze čtyř neuronů s lineární aktivační funkcí, kde každý neuron poskytuje hodnotu jednoho z parametrů TNM modelu. Celková architektura modelu je znázorněna na Obr. 27. Architektura extrakčního modulu je znázorněna na Obr. 28. Velikost jádra konvoluční vrstvy se pohybuje od 4 (horní modul) přes 12 (střední modul) až po 24 (spodní modul). Vstupem dolního modulu je původní sada DSC křivek, vstup prostředního modulu je převzorkován na poloviční velikost a vstup horního modulu na třetinovou velikost původní sady DSC křivek.



Obr. 27 Celková architektura multiškálového modelu.




Obr. 28 Extrakční modul. Vstupní šestice křivek je rozdělena na šest nezávislých větví, z nichž každá je zpracovávána samostatně.

4.2.3 Implementace modelu

Po procesu trénování, ladění hyperparametrů, testování a optimalizace byl výsledný model implementován pro extrakci parametrů TNM modelu z DSC křivek.

Pro demonstraci funkčnosti modelu je na Obr. 29 zobrazen graf náhodně vybrané vstupní sady DSC křivek a související sady křivek vypočtených pomocí výstupních parametrů navrženého modelu uvedeného v této studii. Číselné hodnoty parametrů jsou shrnuty níže.

Očekávaná hodnota	Poskytnutá hodnota
$\log_e A$: -120,10	-122,92,
Δh^* : $1,0300 \times 10^6 \text{ Jmol}^{-1}$,	$1,0294 \times 10^6 \text{ Jmol}^{-1}$,
χ : 0,3600,	0,3484,
β : 0,3400,	0,3378.



Obr. 29 Příklad původního souboru DSC křivek a DSC křivek vypočtených pomocí parametrů poskytovaných modelem hlubokého učení uvedeným v této studii.

Výsledná střední absolutní chyba modelu na testovacích datech je 0,0252, což ukazuje na vysokou přesnost předpovídaných hodnot. Vzhledem k tomu, že transformované výstupní hodnoty se pohybují v rozmezí -1 až 1, je výsledná chyba výstupu modelu nižší než dvě procenta.

Představený model tedy efektivně a dostatečně přesně poskytuje parametry TNM modelu na základě poskytnutých DSC křivek. Vzhledem k tomu, že doba odezvy modelu je na běžných počítačích v řádu setin až desetin sekundy, je úspora výpočetního času ve srovnání s algoritmem pro implicitní výpočet DSC křivek, jehož výpočet trvá v řádu jednotek až desítek minut, nezanedbatelná.


4.2.4 Výstupy tvůrčí činnosti spojené s představeným řešením

Popisovaný postup je podrobně k dispozici v publikaci [49]. Téma je také předmětem disertační práce Ing. Marka Pakosty s názvem Extrakce vlastností z teplotních průběhů skelného přechodu amorfních materiálů.

4.3 Spektrální klasifikace mikroplastů

Mikroplasty, tj. syntetické polymery s velikostí částic menší než 5 mm, jsou nově vznikající znečišťující látky, které jsou v životním prostředí velmi rozšířené. Pro monitorování znečištění životního prostředí mikroplasty je nezbytné mít k dispozici rychlé screeningové techniky, které poskytují přesné informace o kvalitě (typ polymeru) a množství. Spektroskopie je klíčovou technikou pro klasifikaci mikroplastů.

V rámci aplikace spektroskopie je důležitým krokem porovnávání jednotlivých naměřených spekter, resp. zařazení zkoumané látky do správné třídy vzhledem k tomu, že každé měření je velmi individuální a průběhy spekter i pro shodnou látku se výrazně liší (na Obr. 30 je ukázka různých měření FTIR spektra [50]).



Obr. 30 Čtyři příklady FTIR spekter polyethylenu naměřených stejným přístrojem. Signály se liší v počtu špiček, jejich poloze i výšce. Navzdory zjevným rozdílům by tato spektra měla být hodnocena jako jedna třída.

V rámci studie byla zkoumána kvalita a efektivita různých typů modelů hlubokého učení pro klasifikaci FTIR spekter různých typů mikroplastů. Výsledky indikují obecnou vhodnost modelů hlubokého učení pro porovnávání spekter při klasifikaci mikroplastů, přičemž speciálně dobrých výsledků dosáhly architektury typu transformer a multiškálový neuronový model.

4.3.1 Výstupy tvůrčí činnosti spojené s představeným řešením

Představené řešení bylo vyvinuto v rámci prací na projektu PosiTrans¹². Popisovaný postup je podrobně k dispozici v publikaci [51]. Řešení problematiky s doplňujícím využitím SWIR kamery je uvedeno v článku [52]. Téma je také předmětem disertační práce Ing. Jiřího Rolečka s názvem Segmentace a klasifikace multispektrálních dat pomocí nástrojů hlubokého učení.

4.4 Další aplikace autora v oblasti analýzy signálu a časových řad

Analýza signálu a extrakce vlastností ze signálu je multidisciplinárním fenoménem, který spojuje různé vědecké obory ve snaze lépe porozumět, analyzovat a využít komplexních informací, které signály poskytují. Tímto přístupem se otevírají nové perspektivy pro další vývoj technologií a aplikací, které umožní efektivněji a inteligentněji pracovat s velkým množstvím dat, která jsou v současné době v rámci téměř všech oblastí lidské činnosti k dispozici. V rámci spolupráce s vědci a vývojovými pracovníky z jiných oborů se autor oblasti analýzy signálu a extrakce dat ze signálu věnoval i v dalších pracích.

Za zmínku stojí soubor prací zaměřených na klasifikaci zvukových záznamů za účelem detekce škůdců v rostlinné výrobě [53], [54], [55].

S partnery z oblasti medicíny vznikly práce na téma analýzy a klasifikace uroflowmetrických křivek [56] a podpory diagnostiky muskuloskeletálních onemocnění [57]. Vysoký potenciál spolupráce v oblasti medicíny jeví také výzkum na téma oboustranného screeningového vyšetření chuti prostřednictvím telemedicíny. Modely hlubokého učení jsou zde aplikovány zejména při analýze chování pacienta při samovyšetření za účelem vyhodnocení správnosti průběhu

¹² OPVVV: EF17_049/0008394 Spolupráce Univerzity Pardubice a aplikační sféry v aplikačně orientovaném výzkumu lokačních, detekčních a simulačních systémů pro dopravní a přepravní procesy (PosiTrans), 2018-2022 (řešitel)

celé operace. V této oblasti dosud vznikl užitečný vzor¹³ a příspěvek [58]. Ve fázi posuzování je také žádost o evropský patent.

5. PŘÍNOS PRO VĚDU, PRAXI A PEDAGOGICKOU ČINNOST

Spolu s vývojem hardwarových nástrojů jde v současné době překotně kupředu i vývoj teoretických poznatků týkajících se hlubokého učení. V návaznosti na teoretické poznatky se také významně zvyšuje počet prakticky uplatnitelných a komercializovaných výstupů tvůrčích činností implementujících v nějaké podobě modely hlubokého učení. Vedle těchto skutečností projevují průmyslové i jiné podniky výrazný zájem o absolventy technických vysokých škol vykazující znalosti umělé inteligence a hlubokého učení, ale také intenzivně vyhledávají přímou spolupráci s výzkumnými institucemi za účelem dosažení inovací ve svém produktovém portfoliu.

Uvedené skutečnosti jsou jednou z motivací autora, který během více než 15 let působení v akademické sféře zajišťuje předměty vzdělávající studenty v oblastech umělé inteligence, strojového učení a programování se zaměřením na automatizaci technologických procesů. V posledních letech autor také zavedl nové moderní předměty týkající se zpracování signálu a obrazu, jejichž náplní jsou aktuální trendy pro extrakci vlastností z dat pomocí nástrojů hlubokého a strojového učení. Tyto směry autor také zavádí do náplní závěrečných prací studentů, které vznikají pod jeho vedením.

Do všech typů výuky, které autor zajišťuje, jsou implementovány nové poznatky získané v rámci tvůrčí činnosti základního výzkumu či výzkumně-vývojových činností spojených s uplatněním v praxi. Petr Doležel je nositelem dvou výsledků podléhajících průmyslově-právní ochraně a podílel se na řešení 12 projektů s přímou vazbou na uplatnění v praxi. Právě důraz na propojení obsahu terciálního vzdělávání s aplikační sférou identifikuje Petr Doležel jako klíčový pro zefektivnění přípravy studentů na uplatnění v oboru. V tomto směru autor práce také inicioval zapojení Univerzity Pardubice do mezinárodního projektu Deep InventHEI¹⁴, jehož cílem je zajištění vzdělávání studentů i akademiků

¹³ Tester pro vyšetření chuti, testovací sada zahrnující tento tester a systém pro sběr dat z aplikace testovací sady. Úřad průmyslového vlastnictví, 36406. 2022

¹⁴ EU: Deep InventHEI INnoVation and ENTrepreneurship in HEIs, 2023-2024 (<https://eit-hei.eu/projects/deep-inventhei/>)

v podnikatelském prostředí s vysokým potenciálem inovací a na bázi prostředí zapojených univerzit iniciace vzniku nových podniků implementujících inovace do produkce. Autor v současné době vykonává funkci odborného koordinátora činností projektu.

6. ZÁVĚR

Předložené teze přednášky ke jmenování profesorem s názvem „Extrakce relevantních vlastností pomocí hlubokého učení pro průmyslové aplikace“ souhrnně uvádějí nejzajímavější část autorova přínosu do problematiky využití hlubokého učení pro řešení praktických problémů, které zpravidla vyplynuly ze spolupráce Petra Doležela a jeho výzkumného týmu s partnerskými podniky působícími v průmyslové výrobě, případně z mezioborové spolupráce s výzkumnými institucemi z České republiky i ze zahraničí.

Tato práce přináší ucelený pohled na autorem vyvíjené metody zahrnující proces extrakce klíčových vlastností z různorodých datových zdrojů, a to zejména z vizuálních dat, signálů a časových řad. S nutným zohledněním teoretických základů problematiky jsou předloženy nejen konceptuální rámce, ale také praktické aplikace těchto vyvinutých či adaptovaných metod.

Autorova spolupráce s průmyslovými partnery je zároveň příkladem toho, jak akademické činnosti mohou být přímo uplatněny v reálném prostředí a přinést měřitelné výsledky. Úspěšně obhájené inovační projekty a technologie integrované do výrobního procesu skrze smluvní výzkum a licencování ukazují na způsobilost autorova výzkumného týmu spojit akademické prostředí s praktickým uplatněním, další řešené a plánované kolaborativní projekty zároveň zajišťují udržení závazků autora k propojení teoretických poznatků s praktickými aplikacemi.

7. LITERATURA

- [1] DONG, Shi, Ping WANG a Khushnood ABBAS. A survey on deep learning and its applications. *Computer Science Review* [online]. 2021, **40** [cit. 2023-08-22]. ISSN 15740137. Dostupné z: doi:10.1016/j.cosrev.2021.100379
- [2] YAZICI, İbrahim, İbraheem SHAYEA a Jafri DIN. A survey of applications of artificial intelligence and machine learning in future mobile networks-enabled systems. *Engineering Science and Technology, an*

International Journal [online]. 2023, **44** [cit. 2023-08-22]. ISSN 22150986. Dostupné z: doi:10.1016/j.jestch.2023.101455

- [3] REMESEIRO, Beatriz a Veronica BOLON-CANEDO. A review of feature selection methods in medical applications. *Computers in Biology and Medicine* [online]. 2019, **112** [cit. 2023-08-22]. ISSN 00104825. Dostupné z: doi:10.1016/j.compbio.2019.103375
- [4] WEN, Li-Hua a Kang-Hyun JO. Deep learning-based perception systems for autonomous driving: A comprehensive survey. *Neurocomputing* [online]. 2022, **489**, 255-270 [cit. 2023-08-22]. ISSN 09252312. Dostupné z: doi:10.1016/j.neucom.2021.08.155
- [5] CONSTANT, Caroline, Carl-Eric AUBIN, Hilal KREMERS, Diana GARCIA, Cody WYLES, Pouria ROUZROKH a Annalise LARSON. The use of deep learning in medical imaging to improve spine care: A scoping review of current literature and clinical applications. *North American Spine Society Journal (NASSJ)* [online]. 2023, **15** [cit. 2023-08-22]. ISSN 26665484. Dostupné z: doi:10.1016/j.xnsj.2023.100236
- [6] KRIZHEVSKY, Alex, Sutskever ILYA a Hinton GEOFFREY E. ImageNet classification with deep convolutional neural networks. In: *Advances in Neural Information Processing Systems*. Cambridge, Massachusetts: MIT Press, 2012, s. 1097-1105. ISBN 978-1-62748003-1. ISSN 10495258.
- [7] SIMONYAN, Karen a Andrew ZISSERMAN. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. 2015. Dostupné také z: <http://arxiv.org/abs/1409.1556>
- [8] HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN. Deep Residual Learning for Image Recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2016, s. 770-778 [cit. 2023-08-02]. ISBN 978-1-4673-8851-1. Dostupné z: doi:10.1109/CVPR.2016.90
- [9] HUANG, Gao, Zhuang LIU, Laurens VAN DER MAATEN a Kilian WEINBERGER. Densely Connected Convolutional Networks. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*

[online]. IEEE, 2017, s. 2261-2269 [cit. 2023-08-02]. ISBN 978-1-5386-0457-1. Dostupné z: doi:10.1109/CVPR.2017.243

- [10] TAN, M. a Q.V. LE. EfficientNet: Rethinking model scaling for convolutional neural networks: Rethinking model scaling for convolutional neural networks. In: *36th International Conference on Machine Learning, ICML 2019*. Google Research, Brain Team, Mountain View, CA, United States: International Machine Learning Society (IMLS), 2019, , s. 10691-10700. ISBN 978-151088698-8. Dostupné také z: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85077515832&partnerID=40&md5=b8640eb4e9a606d0067b4a420ca73df1>
- [11] REN, Shaoqing, Kaiming HE, Girshick ROSS a Jian SUN. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. In: *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2015, s. 1-9. ISBN 978-1510825024.
- [12] REDMON, Joseph, Santosh DIVVALA, Ross GIRSHICK a Ali FARHADI. You Only Look Once: Unified, Real-Time Object Detection. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2016, s. 779-788 [cit. 2023-08-02]. ISBN 978-1-4673-8851-1. Dostupné z: doi:10.1109/CVPR.2016.91
- [13] LIU, Wei, Dragomir ANGUELOV, Dumitru ERHAN, Christian SZEGEDY, Scott REED, Cheng-Yang FU a Alexander BERG. SSD: Single Shot MultiBox Detector. In: LEIBE, Bastian, Jiri MATAS, Nicu SEBE a Max WELLING, ed., Bastian LEIBE, Jiri MATAS, Nicu SEBE, Max WELLING. *Computer Vision – ECCV 2016* [online]. Cham: Springer International Publishing, 2016, s. 21-37 [cit. 2023-08-02]. Lecture Notes in Computer Science. ISBN 978-3-319-46447-3. Dostupné z: doi:10.1007/978-3-319-46448-0_2
- [14] LONG, Jonathan, Evan SHELHAMER a Trevor DARRELL. Fully convolutional networks for semantic segmentation. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2015, s. 3431-3440 [cit. 2023-08-02]. ISBN 978-1-4673-6964-0. Dostupné z: doi:10.1109/CVPR.2015.7298965

- [15] RONNEBERGER, Olaf, Philipp FISCHER a Thomas BROX. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: NAVAB, Nassir, Joachim HORNEGGER, William M. WELLS a Alejandro F. FRANGI, ed., Nassir NAVAB, Joachim HORNEGGER, William WELLS, Alejandro FRANGI. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* [online]. Cham: Springer International Publishing, 2015, s. 234-241 [cit. 2023-08-02]. Lecture Notes in Computer Science. ISBN 978-3-319-24573-7. Dostupné z: doi:10.1007/978-3-319-24574-4_28
- [16] BADRINARAYANAN, Vijay, Alex KENDALL a Roberto CIPOLLA. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. 2017, **39**(12), 2481-2495 [cit. 2023-08-02]. ISSN 0162-8828. Dostupné z: doi:10.1109/TPAMI.2016.2644615
- [17] BARDIS, Michelle, Roozbeh HOUSHYAR, Chanon CHANTADULY et al. Deep Learning with Limited Data: Organ Segmentation Performance by U-Net. *Electronics* [online]. 2020, **9**(8) [cit. 2023-08-22]. ISSN 2079-9292. Dostupné z: doi:10.3390/electronics9081199
- [18] BEHESHTI, Nazanin a Lennart JOHNSON. Squeeze U-Net: A Memory and Energy Efficient Image Segmentation Network. In: *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* [online]. IEEE, 2020, s. 1495-1504 [cit. 2023-08-22]. ISBN 978-1-7281-9360-1. Dostupné z: doi:10.1109/CVPRW50498.2020.00190
- [19] SHYAMALEE, Thisara a Dulani MEEDENIYA. Attention U-Net for Glaucoma Identification Using Fundus Image Segmentation. In: *2022 International Conference on Decision Aid Sciences and Applications (DASA)* [online]. IEEE, 2022, s. 6-10 [cit. 2023-08-22]. ISBN 978-1-6654-9501-1. Dostupné z: doi:10.1109/DASA54658.2022.9765303
- [20] DOLEZEL, Petr, Dominik STURSA, Dusan KOPECKY a Jiri JECHA. Memory Efficient Grasping Point Detection of Nontrivial Objects. *IEEE Access* [online]. 2021, **9**, 82130-82145 [cit. 2023-08-22]. ISSN 2169-3536. Dostupné z: doi:10.1109/ACCESS.2021.3086417

- [21] STURSA, Dominik, Petr DOLEZEL a Daniel HONC. Grasping Point Detection Using Monocular Camera Image Processing and Knowledge of Center of Gravity. In: SILHAVY, Radek, ed., Radek SILHAVY. *Artificial Intelligence Trends in Systems* [online]. Cham: Springer International Publishing, 2022, s. 531-541 [cit. 2023-08-22]. Lecture Notes in Networks and Systems. ISBN 978-3-031-09075-2. Dostupné z: doi:10.1007/978-3-031-09076-9_48
- [22] DOLEZEL, Petr, Dominik STURSA a Dusan KOPECKY. Suitable ASP U-Net training algorithms for grasping point detection of nontrivial objects. In: *2022 8th International Conference on Control, Decision and Information Technologies (CoDIT)* [online]. IEEE, 2022, s. 1586-1591 [cit. 2023-08-22]. ISBN 978-1-6654-9607-0. Dostupné z: doi:10.1109/CoDIT55151.2022.9803900
- [23] OLIVO, Alessandro, Giulio MATERNINI a Benedetto BARABINO. Empirical Study on the Accuracy and Precision of Automatic Passenger Counting in European Bus Services. *The Open Transportation Journal* [online]. 2019, **13**(1), 250-260 [cit. 2023-08-22]. ISSN 1874-4478. Dostupné z: doi:10.2174/1874447801913010250
- [24] SIEBERT, Michael a David ELLENBERGER. Validation of automatic passenger counting: introducing the t-test-induced equivalence test. *Transportation* [online]. 2020, **47**(6), 3031-3045 [cit. 2023-08-22]. ISSN 0049-4488. Dostupné z: doi:10.1007/s11116-019-09991-9
- [25] DOLEZEL, Petr, Pavel SKRABANEK, Dominik STURSA, Bruno BARUQUE ZANON, Hector COGOLLOS ADRIAN a Pavel KRYDA. Centroid based person detection using pixelwise prediction of the position. *Journal of Computational Science* [online]. 2022, **63** [cit. 2023-08-23]. ISSN 18777503. Dostupné z: doi:10.1016/j.jocs.2022.101760
- [26] CHOUAI, Mohamed, Petr DOLEZEL, Dominik STURSA a Zdenek NEMEC. New End-to-End Strategy Based on DeepLabv3+ Semantic Segmentation for Human Head Detection. *Sensors* [online]. 2021, **21**(17) [cit. 2023-08-23]. ISSN 1424-8220. Dostupné z: doi:10.3390/s21175848
- [27] SKRABANEK, Pavel, Petr DOLEZEL, Zdenek NEMEC a Dominik STURSA. Person Detection for an Orthogonally Placed Monocular

- Camera. *Journal of Advanced Transportation* [online]. 2020, **2020**, 1-13 [cit. 2020-12-01]. ISSN 2042-3195. Dostupné z: doi:10.1155/2020/8843113
- [28] CHOUAI, Mohamed a Petr DOLEZEL. CSU-Net: Contour Semantic Segmentation Self-Enhancement for Human Head Detection. *IEEE Access* [online]. 2023, **11**, 987-999 [cit. 2023-08-23]. ISSN 2169-3536. Dostupné z: doi:10.1109/ACCESS.2022.3233419
- [29] SHANLIANG, Liu, Li YUNLONG, Qu JINGYI a Wu RENBIAO. Airport UAV and birds detection based on deformable DETR. *Journal of Physics: Conference Series* [online]. 2022, **2253**(1) [cit. 2023-08-23]. ISSN 1742-6588. Dostupné z: doi:10.1088/1742-6596/2253/1/012024
- [30] STURSA, Dominik, Petr DOLEZEL a Jan MERTA. Airspace Object Detection Above the Guarded Area Using Segmentation Neural Network. In: ARAI, Kohei, ed., Kohei ARAI. *Proceedings of the Future Technologies Conference (FTC) 2021, Volume 2* [online]. Cham: Springer International Publishing, 2022, s. 283-292 [cit. 2023-08-23]. Lecture Notes in Networks and Systems. ISBN 978-3-030-89879-3. Dostupné z: doi:10.1007/978-3-030-89880-9_22
- [31] ROZSIVALOVA, Veronika, Petr DOLEZEL, Dominik STURSA a Pavel ROZSIVAL. Sequence of U-Shaped Convolutional Networks for Assessment of Degree of Delamination Around Scribe. *International Journal of Computational Intelligence Systems* [online]. 2022, **15**(1) [cit. 2023-08-23]. ISSN 1875-6883. Dostupné z: doi:10.1007/s44196-022-00141-1
- [32] DOLEZEL, Petr, Filip HOLIK, Jan MERTA a Dominik STURSA. Optimization of a Depiction Procedure for an Artificial Intelligence-Based Network Protection System Using a Genetic Algorithm. *Applied Sciences* [online]. 2021, **11**(5) [cit. 2023-08-23]. ISSN 2076-3417. Dostupné z: doi:10.3390/app11052012
- [33] WEI, Sow, Yun-Huoy CHOO, Azah MUDA a Lee SING. A Survey of Explainable Artificial Intelligence in Bio-signals Analysis. *Recent Advances in Computer Science and Communications* [online]. 2022, **16**(3)

[cit. 2023-08-23]. ISSN 26662558. Dostupné z: doi:10.2174/2666255815666220516141153

- [34] SUN, Congzhong a Chaozhou MOU. Survey on the research direction of EEG-based signal processing. *Frontiers in Neuroscience* [online]. 2023, **17** [cit. 2023-08-23]. ISSN 1662-453X. Dostupné z: doi:10.3389/fnins.2023.1203059
- [35] SHARMILA, A. Epilepsy detection from EEG signals: a review. *Journal of Medical Engineering & Technology* [online]. 2018, **42**(5), 368-380 [cit. 2023-08-23]. ISSN 0309-1902. Dostupné z: doi:10.1080/03091902.2018.1513576
- [36] MARTIS, Roshan, U. ACHARYA a Hojjat ADELI. Current methods in electrocardiogram characterization. *Computers in Biology and Medicine* [online]. 2014, **48**, 133-149 [cit. 2023-08-23]. ISSN 00104825. Dostupné z: doi:10.1016/j.combiomed.2014.02.012
- [37] JAGANNATH, Anu, Jithin JAGANNATH a Prem KUMAR. A comprehensive survey on radio frequency (RF) fingerprinting: Traditional approaches, deep learning, and open challenges. *Computer Networks* [online]. 2022, **219** [cit. 2023-08-23]. ISSN 13891286. Dostupné z: doi:10.1016/j.comnet.2022.109455
- [38] YANG, Shuigen. A novel study on deep learning framework to predict and analyze the financial time series information. *Future Generation Computer Systems* [online]. 2021, **125**, 812-819 [cit. 2023-08-23]. ISSN 0167739X. Dostupné z: doi:10.1016/j.future.2021.07.017
- [39] HOU, Shunhu, Yaoyao DONG, Yuhai LI, Qingqing YAN, Mengtao WANG a Shengliang FANG. Multi-domain-fusion deep learning for automatic modulation recognition in spatial cognitive radio. *Scientific Reports* [online]. 2023, **13**(1) [cit. 2023-08-23]. ISSN 2045-2322. Dostupné z: doi:10.1038/s41598-023-37165-2
- [40] SHIN, Ah-Hyung, Seong KIM a Gyeong-Moon PARK. Time Series Anomaly Detection Using Transformer-Based GAN With Two-Step Masking. *IEEE Access* [online]. 2023, **11**, 74035-74047 [cit. 2023-08-23]. ISSN 2169-3536. Dostupné z: doi:10.1109/ACCESS.2023.3289921

- [41] KUZNETSOVA, Yulia a Ivan POPOV. Design and technological aspects of novel CdS quantum dots doped glass–ceramics. *Ceramics International* [online]. 2022, **48**(13), 18972-18982 [cit. 2023-08-23]. ISSN 02728842. Dostupné z: doi:10.1016/j.ceramint.2022.03.180
- [42] WUTTIG, Matthias a Noboru YAMADA. Phase-change materials for rewriteable data storage. *Nature Materials* [online]. 2007, **6**(11), 824-832 [cit. 2023-08-23]. ISSN 1476-1122. Dostupné z: doi:10.1038/nmat2009
- [43] MOYNIHAN, CORNELIUS, ALLAN EASTEAL, MARY BOLT a JOSEPH TUCKER. Dependence of the Fictive Temperature of Glass on Cooling Rate. *Journal of the American Ceramic Society* [online]. 1976, **59**(1-2), 12-16 [cit. 2023-08-23]. ISSN 0002-7820. Dostupné z: doi:10.1111/j.1151-2916.1976.tb09376.x
- [44] NARAYANASWAMY, O. S. A Model of Structural Relaxation in Glass. *Journal of the American Ceramic Society* [online]. 1971, **54**(10), 491-498 [cit. 2023-08-23]. ISSN 0002-7820. Dostupné z: doi:10.1111/j.1151-2916.1971.tb12186.x
- [45] HODGE, I. a Alan BERENS. Effects of annealing and prior history on enthalpy relaxation in glassy polymers. 2. Mathematical modeling. *Macromolecules* [online]. 1982, **15**(3), 762-770 [cit. 2023-08-23]. ISSN 0024-9297. Dostupné z: doi:10.1021/ma00231a016
- [46] CHEN, Wei a Ke SHI. Multi-scale Attention Convolutional Neural Network for time series classification. *Neural Networks* [online]. 2021, **136**, 126-140 [cit. 2023-08-23]. ISSN 08936080. Dostupné z: doi:10.1016/j.neunet.2021.01.001
- [47] SVOBODA, Roman a Jiří MÁLEK. Description of enthalpy relaxation dynamics in terms of TNM model. *Journal of Non-Crystalline Solids* [online]. 2013, **378**, 186-195 [cit. 2023-08-23]. ISSN 00223093. Dostupné z: doi:10.1016/j.jnoncrysol.2013.07.008
- [48] SHAO, Xiaorui, Chang SOO KIM a Dae GEUN KIM. Accurate Multi-Scale Feature Fusion CNN for Time Series Classification in Smart Factory. *Computers, Materials & Continua* [online]. 2020, **65**(1), 543-561 [cit.

2023-08-23]. ISSN 1546-2226. Dostupné z:
doi:10.32604/cmc.2020.011108

- [49] PAKOSTA, Marek, Petr DOLEZEL, Roman SVOBODA a Bruno BARUQUE ZANON. Multi-Scale Neural Model for Tool-Narayanaswamy-Moynihan Model Parameter Extraction. In: *18th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2023)*. Cham: Springer Nature Switzerland, 2023, s. 24-33. ISBN 978-3-031-42528-8. Dostupné z: doi:10.1007/978-3-031-42529-5_3
- [50] COWGER, Win, Andrew GRAY, Silke CHRISTIANSEN et al. Critical Review of Processing and Classification Techniques for Images and Spectra in Microplastic Research. *Applied Spectroscopy* [online]. 2020, 74(9), 989-1010 [cit. 2023-08-23]. ISSN 0003-7028. Dostupné z: doi:10.1177/0003702820929064
- [51] DOLEZEL, Petr, Jiri ROLECEK, Daniel HONC, Dominik STURSA a Bruno ZANON. Spectral Classification of Microplastics using Neural Networks: Pilot Feasibility Study. In: *Proceedings of the 15th International Joint Conference on Biomedical Engineering Systems and Technologies* [online]. SCITEPRESS - Science and Technology Publications, 2022, s. 283-289 [cit. 2023-08-23]. ISBN 978-989-758-552-4. Dostupné z: doi:10.5220/0010986900003123
- [52] STURSA, Dominik, Dusan KOPECKY, Jiri ROLECEK, Petr DOLEZEL a Bruno BARUQUE ZANON. Classification of Polymers Based on the Degree of Their Transparency in SWIR Spectrum. In: GARCÍA BRINGAS, Pablo, Hilde PÉREZ GARCÍA, Francisco Javier MARTINEZ-DE-PISON et al. *17th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2022)* [online]. Cham: Springer Nature Switzerland, 2023, s. 371-382 [cit. 2023-08-23]. Lecture Notes in Networks and Systems. ISBN 978-3-031-18049-1. Dostupné z: doi:10.1007/978-3-031-18050-7_36
- [53] DOLEZEL, Petr, Pavel SKRABANEK a Lumir GAGO. Pattern recognition neural network as a tool for pest birds detection. In: *2016 IEEE Symposium Series on Computational Intelligence (SSCI)* [online]. IEEE,

- 2016, s. 1-6 [cit. 2023-08-23]. ISBN 978-1-5090-4240-1. Dostupné z: doi:10.1109/SSCI.2016.7849988
- [54] DOLEZEL, Petr a Martin MARISKA. Neural Networks and Linear Predictive Coding Coefficients Used for European Starling Detection in Vineyards. In: *10th International Conference on Soft Computing Models in Industrial and Environmental Applications* [online]. Cham: Springer International Publishing, 2015, s. 91-99 [cit. 2023-08-23]. Advances in Intelligent Systems and Computing. ISBN 978-3-319-19718-0. Dostupné z: doi:10.1007/978-3-319-19719-7_8
- [55] DOLEZEL, Petr, Pavel ROZSIVAL a Martin MARISKA. European starling detection in agricultural areas using multilayer artificial neural network. In: *2015 25th International Conference Radioelektronika (RADIOELEKTRONIKA)* [online]. IEEE, 2015, s. 471-474 [cit. 2023-08-23]. ISBN 978-1-4799-8117-5. Dostupné z: doi:10.1109/RADIOELEK.2015.7129029
- [56] STURSA, Dominik, Petr DOLEZEL a Daniel HONC. Basic Urinal Flow Curves Classification with Proposed Solutions. In: ARAI, Kohei, Supriya KAPOOR a Rahul BHATIA, ed., Kohei ARAI, Supriya KAPOOR, Rahul BHATIA. *Intelligent Systems and Applications* [online]. Cham: Springer International Publishing, 2021, s. 737-746 [cit. 2023-08-23]. Advances in Intelligent Systems and Computing. ISBN 978-3-030-55179-7. Dostupné z: doi:10.1007/978-3-030-55180-3_56
- [57] NOVOTNY, Zdenek, Jan MARES a Petr DOLEZEL. Diagnostics support of musculoskeletal diseases using artificial neural network. In: *2021 International Conference on Applied Electronics (AE)* [online]. IEEE, 2021, s. 1-6 [cit. 2023-08-23]. ISBN 978-80-261-0973-0. Dostupné z: doi:10.23919/AE51540.2021.9542877
- [58] BEHL, Oshin, Tomas SYROVY, Petr DOLEZEL, Pavlina BROTHANKOVA a Jan VODICKA. Tasens bands: a novel method for self-administered taste testing. *CHEMICAL SENSES*. 2022, **47**, 340-341. ISSN 0379-864X.

8. SEZNAM OBRÁZKŮ

Obr. 1 Příklad schématu pro extrakci vlastností z vizuálních dat.	11
Obr. 2 Příklad transformace vizuálních dat do skupiny deformovaných pravděpodobnostních map.	14
Obr. 3 Příklad uvažovaného robotického systému. Pásový dopravník přiváží předměty k manipulaci, průmyslová kamera snímá RGB obraz scény a detekční systém určuje polohu a orientaci úchopových bodů. Cílem systému je, aby robotické rameno, které je vybaveno dvěma druhy koncových efektorů, efektivně umísťovalo objekty do požadovaných poloh.	16
Obr. 4 Koncové efektor – gripper a vakuová savka (vlevo) a objekt k manipulaci (vpravo).	17
Obr. 5 Reálné reprezentace objektu (nahore) a úchopové body objektu v různých polohách (dole). Všechny možné úchopové body jsou zvýrazněny symbolem gripperu a symbolem vakuové savky. Poslední poloha neposkytuje žádný úchopový bod.	17
Obr. 6 Úchopové body náhodně umístěných objektů s nepravidelnými kontakty nebo vzájemnými překryvy (vybrané příklady). Všechny dostupné úchopové body jsou zvýrazněny.	18
Obr. 7 Zobrazení úchopového bodu pro vakuovou savku. Ve zdrojovém obraze je úchopový bod znázorněn žlutým kruhem. Hodnoty jednotlivých pixelů vypočtené podle rovnice (1a, 1b) jsou reprezentovány intenzitami (vpravo); čím vyšší je intenzita, tím blíže je hodnota k 1, černá barva se rovná 0. Vzhledem k předložené reprezentaci je optimální poloha uchopovacího bodu definována středem gradientního kruhu (tj. maximální intenzitou).	19
Obr. 8 Reprezentace úchopového bodu pro gripper. Úchopový bod je ve zdrojovém obraze (vlevo) znázorněn žlutou úsečkou; koncové body jsou zvýrazněny kolečky. Hodnoty jednotlivých pixelů vypočtené podle rovnice (2) jsou reprezentovány intenzitami (vpravo); čím vyšší je intenzita, tím blíže je hodnota k 1. Černá barva je rovna 0. Vzhledem k prezentované reprezentaci je optimální poloha uchopovacího bodu definována středem tvaru (tj. maximální intenzitou) a požadovaný úhel (orientace) gripperu je definován nejpozvolnějším poklesem intenzity.	20

Obr. 9 Model hlubokého učení k transformaci vizuálních dat na dvojici deformovaných pravděpodobnostních map, kde jsou polohy úchopových bodů zvýrazněny jako gradientní tvary.	21
Obr. 10 Robotické stanoviště pro sběr dat. Zájmové objekty jsou rozptýleny na dopravním pásu. Pro sběr vizuálních dat se používá průmyslová kamera umístěná nad scénou. V hliníkovém profilu v blízkosti kamery je umístěno liniové LED světlo.	22
Obr. 11 Označování datových sad pomocí vlastní aplikace. Každý úchopový bod na každém snímku je ručně označen a transformován do dvojice pravděpodobnostních map.	22
Obr. 12 ASP U-Net. Vstupní vizuální data jsou zpracována dvěma konvolučními vrstvami. Poté je signál rozdělen do dvou paralelních větví, z nichž každá zpracovává jiný typ relevantních vlastností. Obě větve jsou pak spojeny a zpracovány sekvencí konvolučních vrstev. Poslední konvoluční vrstva se sigmoidální aktivační funkcí a 2 filtry poskytují výstupní pravděpodobnostní mapy. Parametr n slouží ke škálování modelu.	24
Obr. 13 Odezva modelu ASP U-Net na scénu se dvěma objekty. Dvojice vlevo představuje situaci, kdy není ovlivněna dosažitelnost úchopových bodů. Na snímcích vpravo sousední hrany neumožňují použití gripperu. Proto nejsou tyto úchopové body modelem označeny.	24
Obr. 14 Odezva modelu ASP U-Net na scénu se dvěma nepravidelně umístěnými objekty. Za povšimnutí stojí, že na levých snímcích je prostor úchopového bodu (modrý objekt, pravý okraj) zmenšen oproti původní velikosti kvůli blízké poloze bílého objektu. Uvažované uchopení pomocí gripperu by se však do zmenšeného místa stále vešlo. Na pravé dvojici snímků, kde se bílý objekt nachází více nahoře, je úchopový bod zcela zamítnut, protože v tomto případě by se gripper do tohoto místa vůbec nevešel (tj. úchopový bod nesplňuje požadavky na minimální rozměr).	25
Obr. 15 Odezva modelu ASP U-Net na scénu se skupinou náhodně rozmístěných objektů.	25
Obr. 16 Odezva modelu ASP U-Net na scénu se skupinou náhodně rozmístěných objektů ve více vrstvách. V tomto řešení je do velikosti poskytovaných objektů zakódována lákavost úchopového bodu pro uchopení robotickým ramenem. Největší objekt (v přerušovaném čtverci) tedy zároveň definuje předmět k uchopení.	26

Obr. 17 Deformovaná pravděpodobnostní mapa pro anotované vstupní snímky. Za zmínku stojí odhad tvaru hlav, které nejsou na vstupním snímku celým objemem.	28
Obr. 18 Příklady vstupních vizuálních dat (nahore) a odpovídajících deformovaných pravděpodobnostních map (dole) při testování systému v reálném provozu městské hromadné dopravy. Na prostřední a pravé dvojici snímků je možné identifikovat objekty, které nejsou umístěny celým objemem ve sledované scéně.....	29
Obr. 19 Schéma vyvíjeného systému.	30
Obr. 20 Detail monokulární kamery.....	31
Obr. 21 Příklady vizuálních dat pro detekci zájmových objektů ve sledovaném prostoru.	31
Obr. 22 Schéma metody pro hodnocení stupně degradace nátěru podle ČSN ISO 4628.	32
Obr. 23 Schéma systému k provádění automatizované kontroly svarů.	33
Obr. 24 Příklad schématu pro extrakci vlastností ze signálů nebo časových řad. Extrakce vlastností ze signálu poskytuje konkrétní vlastností zkoumaného signálu, klasifikace přímo přiřazuje signálu třídu, do které signál náleží.	35
Obr. 25 Průběh teplot (vlevo) a odpovídající sada DSC křivek (vpravo) pro studium relaxačního chování amorfních materiálů.	38
Obr. 26 Příklady DSC křivek použitých v datasetu v závislosti na zvolených parametrech TNM modelu.....	39
Obr. 27 Celková architektura multiškálového modelu.....	40
Obr. 28 Extrakční modul. Vstupní šestice křivek je rozdělena na šest nezávislých větví, z nichž každá je zpracovávána samostatně.....	41
Obr. 29 Příklad původního souboru DSC křivek a DSC křivek vypočtených pomocí parametrů poskytovaných modelem hlubokého učení uvedeným v této studii.	42
Obr. 30 Čtyři příklady FTIR spekter polyethylenu naměřených stejným přístrojem. Signály se liší v počtu špiček, jejich poloze i výšce. Navzdory zjevným rozdílům by tato spektra měla být hodnocena jako jedna třída.....	43

9. PROFESNÍ ŽIVOTOPIS AUTORA

Jméno a příjmení: Petr Doležel

Titul/ hodnost: doc., Ing., Ph.D.

Datum narození: 4. února 1983

Místo narození: Hranice

Trvalé bydliště: Benešovo náměstí 2526, 530 02 Pardubice

E-mail: petr.dolezel@upce.cz

Mobil: +420 725 503 187

Tel: +420 466 037 450

IEEE Senior Member

Počet článků indexovaných v databázi Web of Science: 69

Web of Science H-index: 6

Počet článků indexovaných v databázi Scopus: 71

Scopus H-index: 6

Průběh zaměstnání:

2022 – dosud Univerzita Pardubice, prorektor pro vědu a tvůrčí činnost

2017 - 2022 Univerzita Pardubice, Fakulta elektrotechniky a informatiky, Katedra řízení procesů, pozice: docent, proděkan pro vědu a tvůrčí činnost

2011 - 2017 Univerzita Pardubice, Fakulta elektrotechniky a informatiky, Katedra řízení procesů, pozice: odborný asistent

2009 - 2011 Univerzita Pardubice, Fakulta elektrotechniky a informatiky, Katedra řízení procesů, pozice: asistent

Vzdělání a vědecká výchova:

1996 - 2002 Gymnázium Hranice, Zborovská 293, Hranice

2003 - 2008 Univerzita Pardubice, Fakulta chemicko-technologická, obor: Řízení technologických procesů, téma diplomové práce: Umělé neuronové sítě v modelování a řízení bioreaktoru

2008 - 2011 Univerzita Pardubice, Fakulta elektrotechniky a informatiky, obor: Informační, komunikační a řídicí technologie, téma disertační práce: Modelování a řízení nelineární soustavy s využitím umělých neuronových sítí

2017 Jmenování docentem na FAI UTB ve Zlíně, obor Řízení strojů a procesů

Studijní a pracovní pobyty v zahraničí:

2009 Slovenská technická univerzita v Bratislave, Fakulta chemickej a potravinárskej technológie, Ústav informatizácie, automatizácie a matematiky, SR

2010	Technická univerzita Košice, SR
2010	Šiauliai University, Faculty of Technology, Litva
2013	Slovenská technická univerzita v Bratislave, Fakulta chemickej a potravinárskej technológie, Ústav informatizácie, automatizácie a matematiky, SR
2016	Norwegian University of Science and Technology, Norsko
2016	Technická univerzita Košice, SR
2018	Zagreb University of Applied Science, Chorvatsko
2019	Zagreb University of Applied Science, Chorvatsko
2019	University of Burgos, Španělsko
2020	Norwegian University of Science and Technology, Norsko
2021	University of Burgos, Španělsko

Profesní odbornost:

- Identifikace a detekce pomocí zpracování obrazu a zvuku
- Implementace algoritmů soft computing a umělé inteligence
- Moderní metody automatické regulace

Řešitel a spoluřešitel výzkumných projektů:

2009 - 2013	Zkvalitnění a zvýšení spolehlivosti dopravní infrastruktury využitím mikrovlnných technologií. MPO ČR, program TIP, náklady za projekt 6.200.000,- Kč
2013 - 2015	Systém pro zvýšení bezpečnosti vrtulníku při přistání a vzletu v neznámém terénu. TAČR, program Alfa, náklady za projekt 3.200.000,- Kč
2014 - 2017	Systém pro monitorování a detekci – SYMOD. TAČR, program Alfa, náklady za projekt 2.295.000,- Kč
2016 - 2019	Systém pro detekci malých létajících objektů v oblasti letiště. MPO ČR, program TRIO, náklady za projekt 17.931.600,- Kč
2017 - 2019	Smart systém pro automatické vyhodnocování kvality svarů. TAČR, program Gama, náklady za projekt 905.000,- Kč
2018 - 2022	Spolupráce Univerzity Pardubice a aplikační sféry v aplikačně orientovaném výzkumu lokačních, detekčních a simulačních systémů pro dopravní a přepravní procesy (PosiTrans). MŠMT, program OP VVV, náklady za projekt 57.000.000,- Kč
2020 - 2022	Vývoj bezkontaktní technologie pro inteligentní ochranu zájmových prostor. MŠMT, program INTER-ACTION, náklady za projekt 5.081.000,- Kč
2021 - 2023	Výzkum a vývoj nové generace inteligentního systému FareOn NextGen. MPO, program Aplikace, náklady za projekt 15.420.989,- Kč

Přehled 5 vybraných výsledků tvůrčí činnosti

- [1] DOLEZEL, Petr, Pavel SKRABANEK, Dominik STURSA, Bruno BARUQUE ZANON, Hector COGOLLOS ADRIAN a Pavel KRYDA. Centroid based person detection using pixelwise

prediction of the position. *Journal of Computational Science*. 2022, **63**. ISSN 18777503. doi:10.1016/j.jocs.2022.101760

- [2] DOLEZEL, Petr, Dominik STURSA, Dusan KOPECKY a Jiri JECHA. Memory Efficient Grasping Point Detection of Nontrivial Objects. *IEEE Access*. 2021, **9**, 82130-82145. ISSN 2169-3536. doi:10.1109/ACCESS.2021.3086417
- [3] ŠKRABÁNEK, Pavel a Petr DOLEŽEL. Robust Grape Detector Based on SVMs and HOG Features. *Computational Intelligence and Neuroscience*. 2017, **1**, 1-17. ISSN 1687-5265. doi:10.1155/2017/3478602
- [4] SKRABANEK, Pavel, Petr DOLEZEL, Zdenek NEMEC a Dominik STURSA. Person Detection for an Orthogonally Placed Monocular Camera. *Journal of Advanced Transportation*. 2020, **1**, 1-13. ISSN 2042-3195. doi:10.1155/2020/8843113
- [5] DOLEŽEL, Petr a Jana HECKENBERGEROVÁ. Computationally simple neural network approach to determine piecewise-linear dynamical model. *Neural Network World*. 2017, **27**(4), 351-371. ISSN 12100552. doi:10.14311/NNW.2017.27.020

Znalost cizích jazyků/ úroveň:

- anglický jazyk: C1 (pokročilý, Advanced English)

doc. Ing. Petr Doležel, Ph.D.

**Extrakce relevantních vlastností pomocí hlubokého učení pro
průmyslové aplikace**

Extraction of Relevant Features using Deep Learning for Industrial
Applications

Teze přednášek ke jmenování profesorem

Vydala Univerzita Tomáše Bati ve Zlíně
nám. T. G. Masaryka 5555, 760 01 Zlín.

Náklad: 90 ks

Sazba: Petr Doležel

Publikace neprošla jazykovou ani redakční úpravou.

Pořadí vydání: První

Rok vydání: 2023

ISBN 978-80-7678-181-8