

VĚDECKÉ SPISY VYSOKÉHO UČENÍ TECHNICKÉHO V BRNĚ

Edice Habilitační a inaugurační spisy, sv. 744

ISSN 1213-418X

Radim Burget

SYSTEMATICKÝ PŘÍSTUP K UČENÍ E-HEALTH SYSTÉMŮ Z OMEZENÝCH ZDROJŮ

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
Ústav telekomunikací

doc. Ing. Radim Burget, Ph.D.

SYSTEMATICKÝ PŘÍSTUP K UČENÍ E-HEALTH SYSTÉMŮ Z OMEZENÝCH ZDROJŮ

SYSTEMATIC APPROACH TO TRAIN E-HEALTH SYSTEMS FROM
LIMITED RESOURCES

TEZE PŘEDNÁŠKY K PROFESORSKÉMU JMENOVACÍMU ŘÍZENÍ



BRNO 2022

KLÍČOVÁ SLOVA

umělá inteligence, e-zdravotnictví, strojové učení

KEYWORDS

artificial intelligence, e-health, machine learning

© Radim Burget, 2022

ISBN 978-80-214-6121-5

ISSN 1213-418X

Obsah

Životopis	4
Úvod	7
1 Postupy trénování e-health systémů z omezených zdrojů	9
1.1 Umělé neuronové sítě	10
1.2 Hodnocení kvality modelů	11
1.3 Metody regularizace	12
2 Umělá inteligence pro e-zdravotnictví	13
2.1 Prevence infekčních onemocnění	13
2.1.1 Onemocnění COVID-19	13
2.1.2 Včasné rozpoznaní infekce malárie	14
2.1.3 Monitoring fyziologických funkcí pomocí nositelného zařízení	15
2.1.4 Další architektury neuronových sítí	18
Závěr	20
Literatura	21
Abstrakt	22

Životopis

Doc. Ing. Radim Burget, Ph.D.



Narozen: 1982

email: burgetrm@vut.cz

Tel: +420 54114 6933, +420 777 821 437

Vzdělání

2014 Habilitace, VUT v Brně, „Využití umělé inteligence pro optimalizaci metod zpracování signálů“

2010 Ph.D., specializace: Teleinformatika, VUT v Brně, „Přenos signalizace pro internetovou televizi“

Pracovní zkušenosti

2006 technický pracovník, [Ústav telekomunikací, FEKT, VUT v Brně](#)

2006-2012 odborný asistent, [Ústav telekomunikací, FEKT, VUT v Brně](#)

2013-nyní docent, [Ústav telekomunikací, FEKT, VUT v Brně](#)

2012-2018 vedoucího skupiny „Zpracování signálů a umělé inteligence“,

[Výzkumné centrum SIX](#)

2010-nyní Vedoucí sekce Data-Mining SPLab (<http://splab.cz/dm>)

Oblasti vědeckého zájmu

Základní a aplikovaný výzkum v oblasti umělé inteligence, signálového zpracování, eHealth. evoluční algoritmy

Pedagogická praxe

Datové struktury a algoritmy, Information representation and machine learning, CISCO akademie CCNP, Top 10 pedagog 2015 (Mgr.)

Další profesní aktivity *(člen různých komisí, organizátor akcí atp.)*

2022-nyní člen poradního orgánu vědecké kolegia ředitele Kriminalistického útvaru, Policie ČR

2021-nyní člen hodnotícího panelu „Kybernetika, umělá inteligence a

zpracování informací“, GAČR

2020-nyní člen oborové rady, Teleinformatika, FEKT, VUT v Brně

2020-nyní člen poradní skupiny „Zdraví“, EU Horizon Europe

2020-nyní člen poradní skupiny „Maria Curie“, EU Horizon Europe

Přehled grantů a výstupů:

Předmět	Množství	Poznámka
Odpovědný řešitel – veřejné zdroje	37,8 mil. Kč	Interreg Central Europe, TAČR, MVČR, MPO v oblasti umělé inteligence
Odpovědný řešitel – neveřejné zdroje	3,7 mil. Kč	Honeywell, Konica Minolta, 3S, UtilCell v oblasti umělé inteligence
Spoluřešitel projektů	348,3 mil. Kč	Vedoucí programu „Signálové zpracování“, výzkumné centrum SIX + další grantové projekty
Významná inženýrská díla	3x	HS Tokoz (rady vlády M17+, klasifikace 2), ČEPS a.s. (ocenění společností), HS Honeywell (ocenění víceprezidentem Phoenix, USA)
Zvané přednášky	15x	Honeywell, Konica-Minolta, Huawei. Silver Economy Meeting (EU Comission), University of Southern California, Massachusetts Institute of Technology
Významné publikace do časopisů s impaktním faktorem	24x	Impaktní faktor AIS: IF: 0.000 až 1,000: 0x Q1: 9x IF: 1.001 až 2,000: 3x Q2: 12x IF: 2.001 až 3,000: 5x Q3: 2x IF: 3.001 až 4,000: 7x Q4: 1x IF: 4.001 a víc: 7x

Publikační činnost (07/2022)

	WoS	SCOPUS	Google
Počet publikací	139	146	174
Počet citací	936	1407	2239
Počet citací bez autocitací	781	1191	N/A
h-index	14	18	23

Úvod

Umělá inteligence zaznamenala v posledních letech významných úspěchů, a to zejména v oblasti zpětnovazebního učení a zpracování nestrukturovaných dat, tj. zpracování obrazu, textu, videa, zvuku či řeči. Motorem tohoto úspěchu je označováno tzv. hluboké učení, čímž se vymezuje oproti dřívějším přístupům, tzv. tradičním metodám umělé inteligence. Za konceptem hlubokého učení a s tím souvisejícím rapidním nárůstem přesnosti nelze jmenovat pouze jednu jedinou inovaci, ale spíš jejich soubor. Mnohé koncepty jsou známy již po desetiletí. Kombinace nových matematických konceptů, obrovského nárůstu výpočetního výkonu, masivní paralelizace a vzniku rozsáhlých trénovacích množin umožnila uspět i v oblastech, které se dříve zdály být neřešitelné.

I přes tento velký úspěch, stále existuje obrovské množství problémů, které lze řešit jen omezeně či nelze vůbec. Umělá inteligence se dělí na úzkou umělou inteligenci, obecnou umělou inteligenci a super-inteligenci. Úzká umělá inteligence zpravidla řeší jen jeden zadaný úkol, naopak obecná umělá inteligence umí řešit libovolný logický úkol a super-inteligence disponuje intelektuálními schopnostmi, které přesahují lidské schopnosti v širokém záběru kognitivních dovedností. Zatímco úzká umělá inteligence nás dnes obklopuje na každém kroku, umělé obecné ani super-inteligence doposud lidstvo nedokázalo dosáhnout a není jasné, kdy se to může podařit.

Nicméně, i když se omezíme právě na oblast úzké umělé inteligence, existuje i zde velmi široká množina problémů, které stále čekají na vyřešení. Existuje také široká množina problémů, kde lidské schopnosti výrazně překonávají schopnosti strojů. Zde lze jmenovat zejména výrazně horší schopnost tzv. generalizace, tj. schopnost z málo příkladů odvodit obecná pravidla, problém za-

ujatosti, tj. předsudky pramenící ze způsobu naprogramování a použitých zdrojů trénovacích dat, vysvětlitelnost rozhodování ale i další.

Tato práce se zaměřuje na úzkou umělou inteligenci pro oblast e-zdravotnictví. Zde je významnou oblastí učení se z poměrně omezených trénovacích dat. Problematika e-zdravotnictví je specifická různorodostí trénovacích dat, která analyzují 2D, 3D i 4D obrazová data (rentgen, magnetická rezonance, počítačová tomografie), chemické rozbory krve, spirometrie a mnoho dalších. Zejména se ale lze jen zřídka kdy spoléhat čistě na statistické metody a čistě automatické učení a zpravidla je nutné validovat výsledky z pohledu klinického významu ale současně využít takové statistické přístupy, které nejen, že dosahují zajímavé přesnosti, ale současně integrují doménovou znalost vybraného problému či využívají metod, které jsou schopny efektivněji nalézt kvalitní vzory, které potom fungují s vysokou přesností i dosud neviděných případech. To je právě doména schopností člověka, kde stále výrazným způsobem překonává schopnosti strojů. Pokud je řeč o rozpoznávání obsahu v obraze, zpracování řeči, videa atp., jsou již v dnešní době dostupné poměrně pokročilé metody. V oblasti e-zdravotnictví nejen že takové množiny neexistují (až na výjimky), nemoci se ale navíc s postupem doby vyvíjejí, mutují a nové choroby vznikají (např. COVID-19).

Zbytek textu je členěn následovně. Kapitola 1.3 stručně představuje techniky strojového učení pro práci nad zdravotnickými daty s omezeným rozsahem. Kapitola 1.3 se potom věnuje konkrétním aplikacím těchto technik. To konkrétně se zaměřením na problematiku detekce infekčních chorob (včetně dnes aktuálního tématu onemocnění COVID-19) a prevenci proti těmto onemocněním či diagnostiku chorob s použitím laciných nositelných zařízení.

1 Postupy trénování e-health systémů z omezených zdrojů

Strojové učení je v současné době opravdu velmi širokou vědní oblastí s aplikacemi přes celou škálu vědních domén. Cílem tohoto textu není poskytnout komplexní přehled, jako spíše zdůraznit techniky, které v oblasti zdravotnictví systematicky dosahují výsledků, kterým se v posledních letech daří překonávat stav vědy a techniky.

Konkrétně se práce věnuje klasifikačním algoritmům strojového učení. Mezi tradiční metody strojového učení patří celá řada algoritmů, jak jsou k -nejbližších sousedů (k -NN) [3], rozhodovací stromy [3], náhodné lesy [3], lineární regrese [3], systémy podpůrných vektorů [3] a další. Současný rozvoj metod se odehrává spíše v oblasti neuronových sítí, konkrétně tzv. hlubokých neuronových sítí. Ale i tzv. tradiční metody jsou často velmi úspěšné a pro oblast, kde je limitovaný objem trénovacích dat, jsou často i lepší volbou.

Oblast e-zdravotnictví je charakteristická tím, že dostupnost dat, zejména pak těch značených, je poměrně omezena. To je v mnohých případech problém organizační (ne všechny zdravotnická zařízení systematicky a strukturovaně ukládají zdravotnické záznamy), finanční (zejména značení spolu nese nemalé náklady), bezpečnostní (např. GDPR), ale v případech méně častých či nových nemocí (např. COVID-19) dostatečné množství záznamů zkrátka neexistuje. Rozvoj metod strojového učení probíhá nejintenzivněji na datových množinách jako jsou ImageNet [2], kde je pro každou kategorii přibližně 1000 vzorků. Nicméně, tato datová sada se výrazným způsobem liší od případů, které je reálné ve většině případů v oblasti e-zdravotnictví nashromáždit.

Tato kapitola nejprve představuje matematický základ neuronových sítí, dále představuje nejčastěji používané metriky používané v oblasti zdravotnictví ke statistickému hodnocení kvality naučených modelů a také jejich vzájemné srovnání. Poslední část se zaměřuje na moderní metody regularizace, tj. technik, které zlepšují schopnosti učení se z omezeného množství trénovacích dat.

1.1 Umělé neuronové sítě

V současné době existuje opravdu široká skupina algoritmů umělých neuronových sítí [6]. Základem všech je neuronová síť složená z dopředného acyklického grafu plně propojených vrstev, kde každá je složena z jednoho či více neuronů. Každý z neuronů je spojen vahou (w_k) s každým výstupem neuronu z předchozí vrstvy (x_{ki}) a dává výstup z dle následující rovnice.

$$z = \sum_{k=1}^n (w_k \cdot x_{ki}) + w_{bias}, \quad (1.1)$$

kde n představuje počet předchozích neuronů, x_{ki} představuje hodnotu vstupu z k -tého neuronu i -tého trénovacího vzorku, w_{bias} je odsazení, které umožní přidat energii neuronu i když jsou veškeré vstupy hodnoty 0.

Za účelem zanesení nelinearity do neuronové sítě se zpravidla aplikuje na výstup neuronové sítě aktivační funkce σ . Typickou funkcí je například hyperbolický tangens, sigmoida, ReLU, softmax a mnoho dalších [6].

$$a = \sigma(z) \quad (1.2)$$

Proces učení potom spočívá v aktualizaci hodnot vah pomocí tzv. algoritmu zpětného šíření chyby (back-propagation) [6]. Algoritmus začíná od konce, kde se porovnává odchylka odpovědi

neuronové sítě proti očekávání v trénovacích datech:

$$w_i(t+1) = w_i(t) + \alpha \cdot (e(t) - a(t)) \cdot x_i(t), \quad (1.3)$$

kde w_i je i -tá váha v časech učení t či $t+1$, α představuje rychlost učení, $e(t)$ a $a(t)$ jsou očekávaná a skutečná odezva neuronové sítě v čase t , a x_i je i -tý vstup. Tato aktualizace každé váhy probíhá v jednotlivých kolech učení (tzv. epochách).

1.2 Hodnocení kvality modelů

Pro posouzení kvality naučených modelů se potom používají různé statistické nástroje. I přes jejich známé nedostatky se v literatuře nejčastěji vyskytují metriky jako je přesnost (accuracy) [3], preciznost (precision) [3], senzitivita [3] a F1 míra [3]:

$$\text{Accuracy} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}} \quad (1.4)$$

$$\text{Precision} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (1.5)$$

$$\text{Recall} = \text{Senzitivita} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (1.6)$$

$$\text{F1} = \frac{2 \cdot N_{\text{TP}}}{2 \cdot N_{\text{TP}} + N_{\text{FP}} + N_{\text{FN}}} \quad (1.7)$$

Zkratka N_{TP} představuje počet vzorků, které se podařilo klasifikovat pravdivě pozitivně, N_{TN} je počet pravdivě negativně klasifikovaných vzorků, N_{FP} představuje počet falešně pozitivně klasifikovaných vzorků a N_{FN} představuje falešně negativně klasifikované vzorky.

1.3 Metody regularizace

V ideálních podmínkách by učení modelu využilo nekonečné množství trénovacích dat a mělo na to nekonečný čas. Takový model by pokrýval veškeré detaily, které lze z dat odvodit. V praxi se bohužel nelze spoléhat ani na nekonečné množství dat, ani na nekonečný čas. Většina moderních algoritmů demonstruje své schopnosti na veřejných množinách, jako je např. ImageNet [2]. Jedná se o poměrně rozsáhlou datovou množinu, což ale neodpovídá potřebám pro velkou podskupinu úloh, kdy je nezbytné se učit jen z malého počtu vzorků.

Právě metody regularizace pomáhají k nalezení zobecněných pravidel modelu. Mezi ty nejznámější patří například Dropout [6], dávková normalizace [6] či L1 a L2 normalizace [6]. Ty modernější přístupy naopak využívají přeskakujících se spojení, kde extrémním řešením jsou např. Ordinální Diferenční rovnice. Dalším přístupem je tzv. přenesené učení, tj. naučení se na obdobných datech a doučení se na konkrétním problému. Z těch předučených sítí jsou potom využívány různé vrstvy latentního prostoru a jejich kombinace pro dosažení optimálního výsledku.

Přestože moderní neuronové sítě jsou schopny se samy učit extrahovat příznaky a ne zřídka jsou v tom dokonce výrazně lepší než manuálně vytvářené přístupy, je-li řeč o omezených datových množinách, tak plně automatické metody často selhávají. Za této situace existuje celá škála řešení, které sice statisticky vycházejí slibně, přesto všechno je stále velká šance, že se jedná jen o náhodu a ve skutečnosti funkční nejsou.

Ruční předzpracování dat je způsob, jak riziko naučení se nesmyslného modelu předejít a jak algoritmy navést. Jedná se bohužel o techniku, která je vázaná na konkrétní případ a jen zřídka kdy je možné danou techniku přenést i na jiný druh problému.

2 Umělá inteligence pro e-zdravotnictví

Následující kapitola popisuje vybrané práce autora, kde se s pomocí uvedených postupů podařilo dosáhnout výraznějších úspěchů ve stavu poznání. Vybraná témata spadají do oblasti elektronického zdravotnictví, konkrétně nakažlivých nemocí a jejich prevence. Výzkum probíhá mimo jiné ve spolupráci se zástupci FN Olomouc.


2.1 Prevence infekčních onemocnění

Tato sekce představuje unikátní metody vyvinuté pro oblast infekčních onemocnění COVID-19 a dále malárie s pomocí mikroskopů a umělé inteligence.

2.1.1 Onemocnění COVID-19

Ihned po vyhlášení pandemické situace COVID-19 v únoru 2020 začaly práce ve snaze zajistit přesnější analýzu rentgenových snímků hrudníku [4]. V rámci spolupráce byl vytvořen mezinárodní tým skládající se z týmu ze Španělska, Indie a České republiky. Cílem této skupiny bylo s použitím dostupných informačních zdrojů vyvinout novou metodu, která zpřesní diagnostiku s pomocí pokročilých metod hlubokého učení. Pro tento účel byla navržena architektura neuronové sítě, využívající latentního prostoru předučené umělé neuronové sítě DarkNet následovanou pyramidovou vrstvou. Díky tomu je kombinována znalost z několika úrovní detailu (viz obr. 2.1).

S pomocí této architektury se podařilo dosáhnout poměrně vysokého zlepšení přesnosti v porovnání s předchozími architekturami. Navržená metoda dosahovala přesnosti $99.61 \pm 0.17 \%$



Obr. 2.1: Multiúrovňová pyramidová architektura neuronové sítě využívající latentního prostoru z předtrénované sítě DarkNet. [4]

[4] pro klasifikaci zdravých pacientů a pacientů s onemocněním COVID-19 (viz obr. 2.2). Další součástí této práce byl experiment, který se pokoušel rozpoznat různé druhy nemocí. V tomto případě se podařilo dosáhnout zajímavých výsledků, které na trénovací množině dosáhly přesnosti $94.79 \pm 3.81 \%$ (viz obr. 2.3) [4]. Dosažená přesnost i velikost nashromážděné datové množiny byla v dané době zcela unikátní.

2.1.2 Včasné rozpoznaní infekce malárie

Další z prací [7] z oblasti infekčních chorob se týkala snahy s pomocí umělé inteligence identifikovat infekci malárie z rozboru krve. Práce je založena na tzv. vizuálních transformerech (viz

		Předpověď		Celkem	Preciznost
		COVID-19	Zdravý		
Skutečnost	COVID-19	188.8	5.2	194	99,368%
	Zdravý	1.2	2916.8	2918	99,822%
Celkem		190	2922	3112	
Specifická		97,320%	99,959%		

Obr. 2.2: Přesnost rozpoznání onemocnění COVID-19 z rentgenu plic oproti zdravým plicím. [4]

obr. 2.4), což je druh neuronové sítě. Právě včasná diagnóza může pomoci zabránit rozvoji nemoci a započítí druhé, závažnější fáze. Problém se potýká s velkým nedostatkem dat, proto jsou data nejen rozšířena (tzv. augmentace), ale je vytvořena tzv. GAN síť, která je schopna vytvářet širokou škálu variant podob trénovacích vzorků.

Na základě provedených experimentů bylo prokázáno, že vizuální transformery v kombinaci s rozšířením trénovací množiny generativní sítě je vhodnou metodou pro medicínská data s omezeným množstvím trénovacích dat 2.4. Obdržené výsledky prokazují lepší schopnost zobecnění se naučených pravidel, než toho jsou schopny ostatní existující přístupy.

2.1.3 Monitoring fyziologických funkcí pomocí nositelného zařízení


Jedna z hlavních příčin, proč je tolik komplikované omezit šíření nemoci COVID-19, je poměrně dlouhá inkubační doba nemoci. Bohužel, i během inkubační doby jsou jedinci infekční a tím i nebezpeční pro své okolí. V rámci práce [8] byly využity zkušenosti s analýzou nositelných zařízení, kde byla snaha pomocí

		Předpověď				Celkem	Preciznost
		COVID-19	Normál	Bakteriální pneumonie	Virální pneumonie		
Skutečnost	COVID-19	187.8	1.6	0.2	4.4	194	99.368%
	Normál	0.2	556.4	1.4	25	583	99.822%
	Bakteriální pneumonie	1.2	52.4	1004.2	714.2	1772	91.175%
	Virální pneumonie	0.8	40	95.6	356.6	493	32.412%
Celkem		190	650.4	1101.4	1100.2		
Specifita		96.804%	95.437%	56.670%	72.333%		


Obr. 2.3: Přesnost rozpoznání různých onemocnění z rentgenu plic (zdravý, bakteriální infekce, virová infekce a COVID-19). [4]

těchto relativně laciných a málo přesných senzorů rozpoznat onemocnění COVID-19 dříve, než propuknou viditelné symptomy. Za tímto účelem byly pořízeny měření od 27 dobrovolníků, kteří prováděli měření jak před, tak po prodělání nemoci. Cílem této práce bylo navrhnout metodu, která bude srovnávat fyziologický stav těla a hledat anomálie zapříčiněné touto nemocí. Abychom mohli odlišit rozdíl mezi zdravými a nemocnými, byla data dále rozšířena o 27 zdravých jedinců. Pořízení této datové množiny je velmi náročné a to z důvodu, že je zapotřebí, aby se dobrovolníci účastnili měření v době, kdy si ještě nejsou vědomi infekce. V tomto případě byl zvolen přístup využití ručního předzpracování dat v kombinaci s tradičními metodami strojového učení. Schéma experimentu je znázorněno na obr. 2.6.


V tomto případě bylo dat extrémně málo. Z toho důvodu byly



Obr. 2.4: Architektura neuronové sítě využívající vizuální transformer pro přesnou identifikaci malárií nakažených buněk. [7]



Obr. 2.5: Srovnání přesnosti vybraných architektur dle vybraných metrik. [7]



Obr. 2.6: Metoda předzpracování senzorických dat za účelem včasné detekce onemocnění COVID-19. [8]

pořízená data předzpracována např. s pomocí diskretní Fourierovy transformace, diskretní waveletovy transformace a dále statistickými deskriptory [8]. S takto extrahovanými příznaky byly natrénovány různé modely strojového učení a jejich kvalita byla vyhodnocena s pomocí křížové validace. Obdržené výsledky ukazují, že nejpresnější model je k -NN a dosažená přesnost 79% (viz tab. 2.1). S pomocí levných fitness nositelných náramků je tedy možné rozpoznat fyziologické změny v těle člověka ještě před projevem pozorovatelných příznaků. Optimální pro tento problém je časové okno 5 dnů od infekce. Práce výrazně posunula přesnost ve srovnání se stavem vědy a techniky.

2.1.4 Další architektury neuronových sítí

Jednou z úspěšných návrhů neuronové sítě byla také architektura Cardi-Net [5], což je hluboká neuronová síť pro diagnózu vybraných nemocí z PCG signálů. Je postavena na tzv. residuální architektuře s použitím silových spektrogramů a pracuje s potlačením šumu s použitím technik augmentace signálu. Výsledný model je plně automatický, prokazuje vysokou spolehlivost a dosažená

Tab. 2.1: Přesnost rozpoznání nemoci v prodromální fázi s použitím nositelných fitness zařízení. [8]

Klasifikátor	Přesnost	Sensitivita	Specificita	MCC
XGBoost	0.71	0.72	0.71	0.46
<i>k</i> -NN	0.78	0.77	0.80	0.60
SVM	0.65	0.66	0.65	0.33
Logistická regrese	0.69	0.69	0.69	0.41
Rozhodovací strom	0.50	0.52	0.49	0.01
Náhodný les	0.62	0.59	0.66	0.27

přesnost je 98.9%.

Další práce navrhuje hlubokou neuronovou síť typu 1D-CNN [1] pro potřeby diagnostiky analýzy prenatálního zdraví, konkrétně diagnostiky fetální acidózy s použitím signálů fetální srdeční frekvence (FHR). Práce se opírá o dostupný a nízkonákladový elektronický hardware bylo prokázáno, že pracuje v reálném čase a s přesností až 99,09 %.

Závěr

Oblast metod strojového učení v posledních letech zaznamenává velmi rychlý rozvoj. I přes úspěchy v mnoha oblastech, zejména pak v oblasti rozvoje analýzy nestrukturovaných dat, existuje stále velmi široká oblast, která čeká na vyřešení. To je případ i převážné většiny problémů řešených v oblasti e-zdravotnictví. Množství pořízení dat je často finančně nákladné, v mnohých případech zcela nemožné získat ve větším množství, variabilita druhů onemocnění je často vysoká a i výskyt komorbidit přináší další výzvu z pohledu proměnlivosti. Nemoci se v čase mohou vyvíjet či objevovat (např. COVID-19) a analýza těchto dat často vyžaduje doménovou znalost. To vše velmi omezuje možnosti strojového učení. I přesto všechno je potenciál nasazení v e-zdravotnictví obrovský.

Tato práce stručně představuje metody strojového učení pro unikátní oblast e-zdravotnictví. Konkrétně se zaměřuje na umělé neuronové sítě a návrh architektur neuronových sítí, které dosahují vyšší přesnosti. Navržené metody přispěly v oblasti infekčních onemocnění, konkrétně pro oblasti onemocnění COVID-19 a malárie. S ohledem na onemocnění COVID-19 byla vyvinuta jedna metoda, která je schopna z rentgenových snímků nejen rozpoznat onemocnění COVID-19, ale současně také identifikovat bakteriální či jiné virové onemocnění plic, dále z běžně dostupného nositelného fitness zařízení identifikovat infekci v tzv. prodromální fázi. S ohledem na práci s malárií se podařilo vyvinout unikátní a přesnou metodu schopnou rozpoznat nemoc s využitím nízkonákladových a běžně dostupných technik rozboru krve.

Literatura

- [1] Baghel, N.; Burget, R.; Dutta, M. K.: 1D-FHRNet: automatic diagnosis of fetal acidosis from fetal heart rate signals. *Biomedical Signal Processing and Control*, 2022: str. 102794.
- [2] Deng, J.; Dong, W.; Socher, R.; aj.: Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition*, Ieee, 2009, s. 248–255.
- [3] Géron, A.: *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. "O'Reilly Media, Inc.", 2019.
- [4] Joshi, R. C.; Yadav, S.; Pathak, V. K.; aj.: A deep learning-based COVID-19 automatic diagnostic framework using chest X-ray images. *Biocybernetics and Biomedical Engineering*, ročník 41, è. 1, 2021: s. 239–254.
- [5] Khan, J. S.; Kaushik, M.; Chaurasia, A.; aj.: Cardi-Net: A deep neural network for classification of cardiac disease using phonocardiogram signal. *Computer Methods and Programs in Biomedicine*, 2022: str. 106727.
- [6] Konasani, V. R.; Kadre, S.: *Machine learning and deep learning using python and tensorflow*. McGraw-Hill Education, 2021.
- [7] Sengar, N.; **Burget, R**; Dutta, M. K.: A Vision Transformer Based Approach for Analysis of Plasmodium Vivax Life Cycle for Malaria Prediction Using Thin Blood Smear Microscopic Images. *Computer Methods and Programs in Biomedicine*, 2022: str. 106996.
- [8] Skibinska, J.; **Burget, R**; Channa, A.; aj.: COVID-19 Diagnosis at Early Stage Based on Smartwatches and Machine Learning Techniques. *IEEE Access*, 2021: s. 119476–119491.

ABSTRAKT

Umělá inteligence zaznamenala zejména od roku 2012 významných úspěchů, a to zejména v oblasti zpracování nestrukturovaných dat, tj. zpracování obrazu, textu, videa, zvuku či řeči. Text práce představuje návrh a ověření unikátní architektury neuronové sítě, která v počátcích pandemie překonala stav vědy a techniky ohledně rozpoznání SARS-CoV-2 patogenu v rentgenových snímcích plic. S tím souvisí další práce postavená na neuronových sítích, která z mikroskopických snímků vzorku krve stanoví infekci malárií (nemoc, která způsobuje 627 tisíc úmrtí ročně). Další část práce představuje unikátní metodu pro rozpoznání nástupu infekce v tzv. prodromální fázi s využitím umělé inteligence a nositelného zařízení (chytrých hodinek). Práce ukazuje, že fyziologické procesy v těle mohou prozradit nástup infekce ještě před samotnými pozorovatelnými příznaky onemocnění. Jsou zmíněny také další dvě architektury neuronových sítí pro diagnostiku srdce a prenatálního vývoje.

ABSTRACT

Artificial intelligence has seen significant success especially since 2012, especially in the field of feedback learning and unstructured data processing, i.e. image, text, video, sound and speech processing. This thesis presents the design and verification of a unique neural network architectures. One of them during the beginning of the pandemic surpassed the state of the art regarding the recognition of the SARS-CoV-2 pathogen in X-ray images of the lungs. Another work based on neural networks recognizes malaria infection from microscopic images of a blood sample. The next part of the work presents a unique neural network for recognition of the onset of infection in the prodromal phase using a wearable device (smart watches). The work shows that physiological processes in the body can reveal the onset of infection even before the observable symptoms of the disease. Two other neural network architectures for cardiac diagnosis and prenatal development are also introduced.