

UNIVERZITA PALACKÉHO V OLOMOUCI

FAKULTA ZDRAVOTNICKÝCH VĚD

Ústav zdravotnického managementu a ochrany veřejného zdraví

Jan Kladivo

**Využití prvků umělé inteligence v diagnostice tonzilofaryngitidy**

Diplomová práce

Vedoucí práce: Ing. Marek Šturek, MBA

Olomouc 2024

Prohlašuji, že jsem diplomovou práci vypracoval samostatně a použil jen uvedené bibliografické a elektronické zdroje.

Olomouc 28. dubna 2022

-----

Podpis autora

Děkuji vedoucímu práce panu Ing. Marku Šturkovi, MBA za vstřícné a přátelské jednání, odborné konzultace, poskytnuté materiály, rady a vlastní čas při realizaci této práce.

# **Anotace**

**Typ závěrečné práce:** Diplomová práce

**Téma práce:** Implementace prvků umělé inteligence v nemocničním prostředí

**Název práce:** Využití prvků umělé inteligence v diagnostice tonzilofaryngitidy

**Název práce v angličtině:** The use of artificial intelligence in the diagnosis of tonsillopharyngitis

**Datum zadání:** 2023-01-30

**Datum odevzdání:** 2024-05-03

**Vysoká škola, fakulta, ústav:** Univerzita Palackého v Olomouci, Fakulta zdravotnických věd, Ústav zdravotnického managementu a ochrany veřejného zdraví

**Autor práce:** Kladivo Jan

**Vedoucí práce:** Ing. Marek Šturek, MBA.

**Oponent práce:** Mgr. Ondřej Machaczka, Ph.D.

**Abstrakt v českém jazyce:** Tato diplomová práce pojednává o možnostech využití prvků umělé inteligence ve zdravotnictví. V teoretické části přibližuje oblast umělé inteligence a v praktické se konkrétně zaměřuje na zpracování fotografií při diagnostice tonsilofaryngitidy.

**Abstrakt v anglickém jazyce:** This thesis deals with the possibilities of using artificial intelligence elements in healthcare. In the theoretical part it presents the field of artificial intelligence and in the practical part it specifically focuses on the processing of photographs in the diagnosis of tonsillopharyngitis.

**Klíčová slova v českém jazyce:** Umělá inteligence, strojové učení, tonzilofaryngitida, Orange data mining, McIsaac skóre

**Klíčová slova v anglickém jazyce:** Artificial Intelligence, machine learning, tonsillopharyngitis, Orange data mining, McIsaac score

**Rozsah:** 64 stran

# Obsah

Úvod .....	7
Seznam vstupní literatury .....	8
Popis řešeršní činnosti .....	9
1 Teoretická část .....	10
1.1 Co je to umělá inteligence? .....	10
1.2 Historie .....	11
1.3 Typy umělé inteligence.....	12
1.3.1 Úzká umělá inteligence (Artificial narrow intelligence) .....	13
1.3.2 Obecná umělá inteligence (Artificial general intelligence) .....	13
1.3.3 Umělá superinteligence .....	14
1.3.4 Vysvětlitelná umělá inteligence .....	14
1.4 Umělá inteligence .....	15
1.4.1 Machine learning .....	15
1.4.2 Hluboké učení (Deep learning).....	20
1.5 Možnosti využití umělé inteligence v nemocničním prostředí.....	22
1.5.1 Příklady využití UI v nemocničním prostředí .....	23
1.6 Etické aspekty použití UI ve zdravotnictví.....	28
1.6.1 Etické výzvy využití UI ve zdravotnictví .....	28
1.7 Legislativa UI .....	32
1.7.1 Evropská unie: KOORDINOVANÝ PLÁN V OBLASTI UMĚLÉ INTELIGENCE .....	35
1.7.2 Národní strategie umělé inteligence v České republice.....	35
1.7.3 Právní základ pro UI v Evropské unii .....	41
1.8 Tonzilofaryngitida .....	42
2 Praktická část.....	44
2.1 Data.....	44

2.2	Orange .....	45
2.3	Model UI .....	45
2.4	Předzpracování dat .....	45
2.5	Výběr klasifikačního modelu.....	46
2.6	Návrh modelu v programu Orange.....	46
2.6.1	Vyhodnocení modelu .....	51
2.7	McIsaac skóre .....	53
3	Diskuse .....	55
4	Limitace .....	56
5	Závěr.....	57
6	Referenční seznam.....	58
6.1	Teoretická část .....	58
6.2	Zdroje praktická část .....	61
7	Seznam obrázků a tabulek .....	62
7.1	Seznam obrázků.....	62
7.2	Seznam tabulek.....	62
8	Seznam zkratk.....	63

## Úvod

Následující stránky této práce budou věnovány tématu využití Umělé inteligence, respektive jejího podoboru strojového učení. Fascinace lidstva technologickým pokrokem přetrvává již od jeho ranného zrodu. Stejně jako v dobách dávnověku byl fantastickým nástrojem z budoucnosti žhnoucí plamen, později páka, kolo, knihtisk, parní stroj, nebo jaderná energie stojí člověk pravděpodobně i dnes před nástrojem nedozírného transformačního potenciálu, díky němuž se svět mění každou vteřinou, a tak musí být připraven a ochoten se s ním náležitě seznámit a začít ho využívat dříve, než zanikne okno, které dává příležitost ho pochopit u jeho samotného zrodu. Zdravotnictví je důležitou součástí politiky každého státu a je to právě zdravotnictví, kde má tento vynález jednu z největších možností uplatnění v současnosti. Evropská unie dává ve svém dokumentu Coordinated Plan on Artificial Intelligence 2021 Review jasně najevo, kterým směrem se chce v této problematice vydat, ten směr jí míří vstříc a zcela jistě během následujících let změní významně podobu našeho zdravotnictví i naše životy samotné.

Takto významný zásah do lidské činnosti s sebou nese i mnoho otázek, nejvíce etických a legislativních, i tato problematika je v redukované formě součástí této práce, v její teoretické části, a snaží se čtenáři představit základní dokumenty zpracované Evropskou unií a Vládou české republiky pro řízenou implementaci umělé inteligence do každodenní reality, stejnou měrou se práce snaží přiblížit základní etické aspekty zavádění umělé inteligence do zdravotnictví.

Strojové učení se v oblasti zdravotnictví, jak už bylo zmíněno, těší velkému úspěchu. Největším přínosem je na poli zobrazovacích metod a počítačového vidění. Současné modely využívající technologie hlubokého učení jsou schopné velmi efektivně odhalit skryté souvislosti v komplexních datech, jako například snímkování magnetickou rezonancí, rentgenem, nebo pozitronovou emisní tomografií. Mohou tak být nápomocny při odhalování širokého spektra onemocnění. (Adelaja & Alkattan, 2023, str. 45)

I tato práce se zabývá schopnostmi modelu umělé inteligence uplatněnými v analýze snímků, kdy si klade za cíl nejprve seznámit čtenáře s tématem umělé inteligence a posléze vytvořit model na bázi strojového učení pod dohledem, který by byl schopen efektivně odhalit a vyhodnotit příznak neviróvé tonzilofaryngitidy, tonzilární exudáty, na základě prosté barevné fotografie krku a zařadit toto vyhodnocení do skórovacího systému McIsaac.

## Seznam vstupní literatury

WADDEN, Jordan Joseph. What Kind of Artificial Intelligence Should We Want for Use in Healthcare Decision-Making Applications. *Canadian Journal of Bioethics / Revue Canadienne de Bioethique* [online]. 2021, **4**(1), 94-100 [cit. 2023-01-30]. ISSN 25614665.

JIMMA, Bahiru Legesse. Artificial intelligence in healthcare: A bibliometric analysis. *Telematics and Informatics Reports* [online]. 2023, **9** [cit. 2023-01-30]. ISSN 27725030. Dostupné z: doi:10.1016/j.teler.2023.100041

BAG, Surajit, Pavitra DHAMIJA, Rajesh Kumar SINGH, Muhammad Sabbir RAHMAN a V. Raja SREEDHARAN. Big data analytics and artificial intelligence technologies based collaborative platform empowering absorptive capacity in health care supply chain: An empirical study. *Journal of Business Research* [online]. 2023, **154** [cit. 2023-01-30]. ISSN 01482963. Dostupné z: doi:10.1016/j.jbusres.2022.113315

SHAHID, Nida, Tim RAPPON a Whitney BERTA. Applications of artificial neural networks in health care organizational decision-making: A scoping review. *PLoS ONE* [online]. 2019, **14**(2), 1-22 [cit. 2022-11-18]. ISSN 19326203. Dostupné z: doi:10.1371/journal.pone.0212356

DARWIESH, A., A.H. EL-BAZ, A.Z. ABUALKISHIK a M. ELHOSENY. Artificial Intelligence Model for Risk Management in Healthcare Institutions: Towards Sustainable Development. *Sustainability (Switzerland)* [online]. 2023, **15**(1) [cit. 2023-01-30]. ISSN 20711050. Dostupné z: doi:10.3390/su15010420



## Popis rešeršní činnosti

### Vyhledávací kritéria

**Klíčová slova v českém jazyce:** umělá inteligence v nemocniční péči, strojové učení v nemocniční péči, modely umělé inteligence využívané ve zdravotnictví, právní aspekty používání umělé inteligence ve zdravotnictví, etika používání umělé inteligence ve zdravotnictví, historie umělé inteligence, tonzilo-faryngitida, McIsac skóre

**Klíčová slova v anglickém jazyce:** artificial intelligence in hospital care, machine learning in hospital care, artificial intelligence models used in healthcare, legal aspects of using artificial intelligence in healthcare, ethics of using artificial intelligence in healthcare, history of artificial intelligence, tonsillopharyngitis, McIsaac score

**Jazyk:** čeština, angličtina, polština

**Období:** 2012-2022

**Další kritéria:** plný text, recenzovaná periodika



### Databáze

Ebsco, Google Scholar, ScienceDirect



### Nalezeno

131+210+28



### Vyřazující kritéria

Obsahově nevhodné články, duplicitní články, placené články, text článku v jiném než zvoleném jazyce



### Sumarizace využitých databází a dohledaných dokumentů

Ebsco – 19

Google Scholar – 8

ScienceDirect – 5

Pro práci byly použity také 2 dokumenty Evropské unie a 1 dokument Vlády ČR.

# 1 Teoretická část

## 1.1 Co je to umělá inteligence?

Evropská komise definuje Umělou inteligenci takto:

"Systémy umělé inteligence (dále jen UI) jsou softwarové (a případně i hardwarové) systémy navržené lidmi, které vzhledem ke komplexnímu cíli jednají ve fyzickém nebo digitálním rozměru tak, že vnímají své prostředí prostřednictvím dat. Získáváním, interpretací shromážděných strukturovaných nebo nestruturovaných dat, uvažováním na základě znalostí nebo zpracováním informací získaných z těchto dat a rozhodují se o nejlepší akci (akcích), kterou (které) je třeba podniknout k dosažení daného cíle. Systémy umělé inteligence mohou používat buď symbolická pravidla, nebo se naučit numerický model, a mohou také přizpůsobit své chování analýzou toho, jak jejich předchozí akce ovlivnily jejich prostředí. Jako vědní disciplína zahrnuje umělá inteligence několik přístupů a technik, jako je strojové učení (z nichž hluboké učení a posilovací učení jsou konkrétními příklady), strojové uvažování (které zahrnuje plánování, rozvrhování, reprezentace znalostí a uvažování, vyhledávání a optimalizace) a robotiku (která zahrnuje řízení, vnímání, senzory a aktuátory, jakož i integraci všech ostatních technik do kyberneticko-fyzických systémů)" (High-Level Expert Group on Artificial Intelligence, 2019, str. 6).

Caluori uvádí, že debatu o definici "Co je to umělá inteligence?" lze rozdělit do pěti parametrů: schopnost učení, podobnost člověku, stav "mysli", úspěšnost řešení a složitost problému. Poslední z nich je méně kontroverzní než ty první. V průběhu času se používání těchto parametrů. Od 50. let 20. století, kdy byla umělá inteligence zavedena, měnilo, ale diskuse se obecně věnuje těmto dimenzím. Neexistuje však žádná jednoznačná shoda na tom, která kritéria jsou pro definici UI rozhodující a jak musí být naplněna. Nicméně existuje určitá obecná shoda na dvou parametrech: složitost problému není rozhodující a od 90. let 20. století je obecně přijímána lidská podoba jako klíčový atribut pro UI, i když na různých úrovních. Navzdory nedostatku shody údaje naznačují, že pro sepsání definice UI je třeba chápat ji v kontextu oblasti její distribuce a jejího cíle. To se shoduje s rozlišením mezi pracovní a slovníkovou definicí, ačkoli hranice těchto kategorií jsou proměnlivé. Důsledky těchto zjištění pro výzkum UI a společenskou praxi definování UI zůstávají otevřené. Definování umělé inteligence je vnímáno jako sociální praxe ovlivněná vnějšími, kulturními a historickými faktory, které je třeba vzít v úvahu. V probíhající diskusi o umělé inteligenci by se pozornost neměla soustředit pouze na definice, ale také na jejich sociální kontext (Caluori, 2023, str. 7-9).

## 1.2 Historie

Počátky výpočetní techniky a umělé inteligence (UI) jsou úzce spjaty s průkopnickou prací osobností jako Charles Babbage, Augusta Ada Kingová (hraběnka z Lovelace) a Alan Mathison Turing. Babbageův analytický stroj, který vznikl na počátku 19. století a stal se základem pro moderní výpočetní techniku tím, že zavedl koncepty, jako jsou děrné štítky pro programování, a naznačil, jak by měly vypadat dnešních počítačů. Augusta Ada Kingová významně rozšířila dílo Babbage o posun výpočetní teorie a ukázala rané pochopení potenciálu této technologie. Turingovy převratné myšlenky a dílo, včetně jeho práce o spočítatelných číslech a Turingově stroji, položily základy současné výpočetní techniky a umělé inteligence. Jeho vytvoření "Turingova testu" jako měřítka strojové inteligence zůstává klíčové pro výzkum a diskusi o umělé inteligenci dodnes (Grzybowski et al., 2024, str. 2-4).

Koncept využití počítačů k simulaci inteligentního chování, který popsal Alan Turing v roce 1950, položil základy moderní umělé inteligence. Následně John McCarthy v roce 1956 vytvořil termín umělá inteligence a definoval ji jako vědu a techniku vytváření inteligentních strojů (Kaul et al., 2020, str. 807).

V raných fázích vývoje umělé inteligence se pozornost soustředila na vytváření strojů schopných vykonávat úkoly, které dříve vykonával výhradně člověk. Významným milníkem bylo uvedení prvního průmyslového robotického ramene Unimate v roce 1961, které automatizovalo procesy například lití pod tlakem na montážních linkách. Krátce poté, v roce 1964, se objevil robot Eliza jako průkopník v oblasti zpracování přirozeného jazyka, který simuloval lidskou konverzaci pomocí technik porovnávání vzorů a substituce. Další průlom přinesl vývoj Shakeyho v roce 1966, který představoval prvního mobilního robota schopného interpretovat složité instrukce, nikoliv jednoduché příkazy. Navzdory pomalému zavádění v medicíně položila tato éra základy digitalizace dat, a vytvoření klíčových zdrojů, jako je systém analýzy a vyhledávání lékařské literatury a PubMed, Národní lékařskou knihovnou v 60. letech 20. století. Tento vývoj připravil půdu pro pozdější růst a využívání umělé inteligence v medicíně, podpořený vytvořením databází klinické informatiky a systémů lékařských záznamů v tomto období (Kaul et al., 2020, str. 808).

Období od 70. let 20. století do roku 2000 je často označováno jako "zima umělé inteligence", to se projevilo jako pokles financování a zájmu, což vedlo ke snížení rychlosti pokroku. Tato krize, charakterizovaná dvěma velkými obdobími útlumu vývoje na konci 70. let a na přelomu 80. a 90. let, byla způsobena vnímanými omezeními a příliš vysokými náklady na vývoj odborných digitálních informačních databází. Přesto spolupráce mezi průkopníky umělé inteligence přetrvávala a vedla k takovým milníkům, jako bylo vytvoření The Research

Resource on Computers in Biomedicine Saulem Amarelem v roce 1971 a systému Stanfordské univerzity Medical Experimental-Artificial Intelligence in Medicine v roce 1973, který usnadnil vytváření sítí mezi výzkumníky. Tato spolupráce vyvrcholila v roce 1975 prvním seminářem Artificial Intelligence in Medicine sponzorovaným Národními ústavami zdraví. Významné prototypy, včetně modelu CASNET pro konzultaci glaukomu a systému MYCIN pro lékařskou diagnostiku, ukázaly v tomto období potenciál umělé inteligence v medicíně (Kaul et al., 2020, str. 808-809).

V letech 2000 až 2020 došlo k zásadnímu pokroku v oblasti umělé inteligence (UI), jehož příkladem bylo vytvoření systému Watson společností IBM v roce 2007, který v roce 2011 překonal člověka v soutěži Jeopardy!. Na rozdíl od tradičních systémů využíval Watson technologii DeepQA, která pracovala na principu zpracování přirozeného jazyka a různá vyhledávání k analýze nestrukturovaných dat a generování odpovědí. Tato inovace způsobila revoluci v Evidence Based Medicine tím, že byla schopna zpracovat elektronické lékařské záznamy pacientů a umožnila klinické rozhodování založené na důkazech. Kromě toho se jako klíčový pokrok ukázala technologie Deep Learning, která s dostupností větších souborů dat a lepším výpočetním výkonem překonala předchozí omezení, kterými byla nadměrná adaptace, jež způsobovala, že se modely například v medicíně příliš zaměřovaly na některé části dat, tak že zbylá podstatná data jim unikala a výsledky, které uváděly byly značně zkreslené. Deep Learning, jehož příkladem jsou konvoluční neuronové sítě, způsobilo také revoluci ve zpracování obrazu díky simulaci chování neuronů lidského mozku a rozpoznávání složitých vzorů, což vedlo k významnému pokroku v aplikacích umělé inteligence v různých oblastech včetně zobrazovacích metod v medicíně (Kaul et al., 2020, str. 809).

### **1.3 Typy umělé inteligence**

Podle Sookhaka vývoj systémů, které jsou založeny na umělé inteligenci prochází etapami od umělé úzké inteligence k umělé obecné inteligenci a vrcholí umělou superinteligencí, u níž se předpokládá, že komplexně překoná lidské schopnosti. Vymezení rozdílů mezi těmito klasifikacemi umělé inteligence a novějšími koncepty, jako je inteligence na úrovni člověka, je výzvou, která je umocněna absencí komplexních studií zabývajících se vývojem a vzájemnými vztahy těchto klasifikací napříč třídami UI (Sookhak & Forestiero, 2022, str. 1-2).

Evropská komise pro rozdělení uvádí, že obecný systém umělé inteligence má být systémem, který dokáže vykonávat většinu činností, které mohou vykonávat lidé. Úzké systémy umělé inteligence jsou naopak systémy, které mohou vykonávat jednu nebo několik málo konkrétních úloh. Příkladem úzké umělé inteligence jsou v současnosti nasazené systémy

umělé inteligence. V počátcích vývoje umělé inteligence používali výzkumníci jinou terminologii (slabá a silná UI). Stále existuje mnoho otevřených etických, vědeckých a technologických výzev k vybudování schopností, které by byly potřebné k dosažení obecné UI, jako je například uvažování zdravým rozumem, sebeuvědomění a schopnost stroje definovat svůj vlastní účel (High-Level Expert Group on Artificial Intelligence, 2019, str. 5).

### **1.3.1 Úzká umělá inteligence (Artificial narrow intelligence)**

Současné nástroje úzké umělé inteligence (dále jen ANI) vynikají ve specifických úlohách a často dosahují nadlidských výkonů, jak ukazují různé studie. Tyto úlohy jsou obvykle dobře definované a strukturované. Úzké systémy umělé inteligence jsou však méně vhodné, nebo dokonce nevhodné pro úlohy nebo prostředí, kde chybí struktura, konzistence, pravidla nebo pokyny, kde mohou nastat neočekávané, vzácné nebo neobvyklé události (například mimořádné situace). Dodržování pevně daných postupů obvykle nevede k vhodným řešením za takových rozmanitých okolností (Korteling et al., 2021, str. 8).

V situacích zahrnujících nepředvídané změny cílů nebo okolností se účinnost současné UI výrazně snižuje, protože jí chybí schopnost uvažovat z širší perspektivy a odpovídajícím způsobem se přizpůsobit. Podobně jako v případě ANI je často nutný lidský dohled, aby bylo možné řešit odchylky a zajistit flexibilní a adaptivní výkon systému (Korteling et al., 2021, str. 8).

### **1.3.2 Obecná umělá inteligence (Artificial general intelligence)**

Korteling definuje obecnou umělou inteligenci (dále jen AGI) jako „Nebiologické schopnosti pro samostatné a efektivní dosahování komplexních cílů v různých prostředích.“ Systémy AGI by měly mít schopnost automaticky a efektivně identifikovat a extrahovat základní vlastnosti pro své fungování a učení v širokém spektru úkolů a kontextů. Výzkum AGI se zaměřuje na všestrannost a úplnost inteligence a od tradičního výzkumu umělé inteligence se liší tím, že se snaží konstruovat systémy, které se v některých aspektech podobají lidské mysli (Korteling et al., 2021, str. 2).

AGI však nemá mezi předními vědci zabývajícími se umělou inteligencí všeobecně uznávanou definici. Obvykle se AGI vztahuje na zástupce, jejichž inteligence odpovídá inteligenci člověka. AGI lze považovat za ekvivalent inteligence na lidské úrovni (Sookhak & Forestiero, 2022, str. 2).

V komunitě UI přetrvává debata o dosažitelnosti AGI, přičemž existují optimistické i pesimistické názory. Někteří výzkumníci věří, že AGI je proveditelná, a vyvíjejí systémy nebo algoritmy zaměřené na její realizaci s využitím posilovacího učení, pravděpodobnostních

přístupů nebo hlubokých neuronových modelů. Praktické systémy AGI však zůstávají nedosažitelné. Filozofické názory kritizují AGI kvůli jedinečným vlastnostem lidské inteligence a tvrdí, že je pro stroje nedosažitelná. Před zodpovězením otázky AGI je zásadní proniknout do jejích aspektů. AGI není pouhý algoritmus, ale kontinuální proces odrážející vývoj lidské inteligence. Ztělesnění lidské inteligence a znalosti zdravého rozumu ovlivňují náš mentální model světa, který je pro realizaci AGI zásadní (Chehreghani, 2024, str. 1-2).

Triguero uvádí, že systém umělé inteligence pro všeobecné účely je pokročilý systém umělé inteligence, který je schopen efektivně provádět různé úkoly. Úroveň jeho autonomie a zdatnosti je definována několika zásadními vlastnostmi, jako je schopnost přizpůsobit se a vyniknout v nových úlohách, které se mohou objevit v budoucnu, prokázat kompetence v oblastech, pro které nebyl výslovně vyškolen, učit se z omezených dat a aktivně rozpoznávat vlastní omezení, aby zlepšil svůj výkon (Triguero et al., 2024, str. 5).

### **1.3.3 Umělá superinteligence**

Umělou superinteligenci (dále jen ASI) Bostrom charakterizuje jako systém, který výrazně převyšuje lidskou inteligenci prakticky ve všech oblastech a je schopen překonat současné kognitivní systémy v mnoha úlohách. Bostrom dělí ASI na tři hlavní typy: ASI kvality, ASI rychlosti a kolektivní ASI. Kvalitní ASI představuje systém, který je přinejmenším stejně rychlý jako lidská mysl, ale kvalitativně výrazně inteligentnější. Rychlostní ASI je naproti tomu definována jako systém, který dokáže vykonávat všechny úkoly, které dokáže lidský intelekt, ale výrazně rychleji. Kolektivní ASI zahrnuje systém složený z mnoha menších intelektů, který umožňuje dosahovat lepších výkonů v různých oblastech ve srovnání se současnými kognitivními systémy (Brundage, 2015, str. 33).

### **1.3.4 Vysvětlitelná umělá inteligence**

Vysvětlitelná umělá inteligence (dále jen XAI) je rozvíjející se obor, který nachází uplatnění v různých oblastech, včetně zdravotnictví, dopravy a vojenských službách. Zahrnuje využití řady nástrojů a postupů ke zvýšení transparentnosti modelů učení. Tím, že modely mohou poskytovat vysvětlení svých rozhodnutí, mohou lidé těmto systémům důvěřovat, zejména při řešení otázek, jako je zaujatost a spravedlnost. Vysvětlitelnost pomáhá nejen pochopit rozhodování, ale také přispívá k řešení dalších problémů, jako je spravedlnost a důvěryhodnost. Modelům, jejichž rozhodovací systém není transparentní se říká tzv. „černé skříňky“ (Sookhak & Forestiero, 2022, str. 7-8).

V posledních letech se objevily rozsáhlé průzkumy týkající se XAI, které se zaměřují na technické analýzy se srovnáním různých metodik a přispívají ke konstrukci transparentních

systemů UI/ML. Ve zdravotnictví byly metody XAI zkoumány pro zvýšení odpovědnosti a spolehlivosti, například techniky vizuálního vysvětlení pro rozpoznávání rakoviny prsu a detekci Alzheimerovy choroby. Podobně ve financích se diskutuje o integraci technik XAI s informačními a komunikačními technologiemi s cílem zmírnit rizika a zvýšit jejich efektivitu. Nedávné pokroky v oblasti XAI se zaměřily na objasnění fungování modelů černé skříňky, především prostřednictvím metodik založených na důležitosti znaků a pravidlech (La Gatta et al., 2024, str. 3-4).

Navzdory pozoruhodným schopnostem metod učení, jako jsou neuronové sítě a hluboké učení, se tyto metody při plnění úkolů často spoléhají na nevysvětlitelné vzorce. Ve scénářích, kde je pochopení důvodů rozhodování klíčové, například v kritických úlohách, se však vysvětlitelná umělá inteligence stává nepostradatelnou. Význam vysvětlitelnosti se ještě zvyrazňuje při nasazení agentů založených na inteligenci podobné člověku v úlohách typicky ve zdravotnictví, armádě nebo v jiných kritických kontextech, kde je vysvětlitelnost rozhodnutí prvořadá. Nedávné pokroky a aplikace vysvětlitelných algoritmů učení byly zdokumentovány, což posouvá význam a uplatnění této oblasti. Metody důležitosti znaků se zaměřují na objasnění chování modelu v rámci konkrétních případů, přičemž využívají interpretovatelné modely, jako jsou lineární modely nebo rozhodovací stromy. Metodiky založené na pravidlech poskytují explicitní postup pro lepší pochopení hranic rozhodování uživatelem. Tyto metody se však potýkají s problémy kvůli lokalizované povaze svých vysvětlení. K řešení tohoto problému slouží přístupy jako CASTLE, které integrují globální informace do lokálních vysvětlovacích procesů a nabízejí komplexní pochopení chování modelu. V oblasti škálovatelných a přizpůsobitelných vysvětlovacích technik v rámci velkých dat přetrvává výrazná mezera (La Gatta et al., 2024, str. 3-4).

## **1.4 Umělá inteligence**

### **1.4.1 Machine learning**

Strojové učení (dále jen ML) se využívá k trénování strojů, aby efektivněji zpracovávaly data, zejména pokud je obtížné interpretovat informace přímo z dat. S rostoucí dostupností datových souborů roste poptávka po strojovém učení v různých odvětvích, kde se používá k získání relevantních poznatků. Cílem strojového učení je umožnit strojům učit se z dat a byl proveden rozsáhlý výzkum umožňující strojům učit se samostatně bez explicitního programování. Matematici a programátoři používají různé přístupy k řešení této výzvy, zejména u velkých souborů dat. Strojové učení se při řešení problémů s daty opírá o různé algoritmy a datoví vědci zdůrazňují, že neexistuje univerzální algoritmus pro každý problém. Volba algoritmu závisí na

faktorech, jako je typ problému, počet proměnných a nejvhodnější model (Mahesh, 2020, str. 381).

Algoritmy strojového učení se dělí do kategorií podle přístupu k učení, typu dat, která zpracovávají, a problémů, které řeší, přičemž základními kategoriemi jsou učení pod dohledem, učení bez dohledu a posilování. Kromě toho existují hybridní přístupy a další běžné metody, které přirozeně rozšiřují rozsah problémů strojového učení jako posilovací učení, učení pod vlastním dohledem (Mahesh, 2020, str. 381).

### **Učení pod dohledem**

Učení pod dohledem se zakládá na označování údajů a párování vstupů s výstupy, za účelem trénování algoritmů, které mohou předpovídat cíle nových pozorování. Tyto algoritmy minimalizují ztrátovou funkci, aby vyhodnotily svou shodu s daty, a snaží se vyhnout nadměrnému přizpůsobení, kdy se předpovědi výrazně liší od skutečných pozorování. Při učení pod dohledem se množina pozorování  $\{(x_1, y_1), \dots, (x_n, y_n)\}$  skládá z vektorů prediktorů ( $x_i$ ) a odpovídajících značek nebo cílů ( $y_i$ ). Algoritmy odvozují funkci ( $f$ ) pro předpovídání cílů ( $\hat{y}_i$ ) na základě prediktorů ( $x_i$ ), přičemž typ funkce závisí na úloze: regrese pro číselné cíle a klasifikace pro kategoriální cíle (Sun et al., 2024, str. 3-6).

Mahesh vysvětluje učení pod dohledem jako úlohu ve strojovém učení, kdy se na základě příkladových dvojic vstup-výstup učí funkce, která mapuje vstupní data na výstup. Jedná se o odvození funkce z označených trénovacích dat, která se skládají ze souboru trénovacích příkladů se známými výstupy. Algoritmy strojového učení s kontrolou vyžadují externí pomoc a obvykle zahrnují rozdělení vstupní sady dat na trénovací a testovací sadu dat. Tréninkový soubor dat obsahuje výstupní proměnnou, kterou je třeba předpovědět nebo klasifikovat. Tyto algoritmy se učí vzory z trénovacího souboru dat a poté je aplikují na testovací soubor dat pro účely predikce nebo klasifikace (Mahesh, 2020, str. 381).

Primárním cílem každé techniky strojového učení pod dohledem je vytvořit model, který předpovídá cílovou proměnnou na základě vstupních znaků z dat. Matematická funkce, která mapuje tyto vstupní rysy na výstupní proměnnou, se označuje jako cílová funkce algoritmu strojového učení. Většina modelů strojového učení obsahuje alespoň jeden parametr modelu, který lze optimalizovat a který přímo ovlivňuje cílovou funkci (Lo Vercio et al., 2020, str. 2).

Tento přístup našel široké uplatnění ve zdravotnictví, kde poskytuje podporu klinického rozhodování založenou na datech tím, že mapuje vstupní proměnné do diskrétních kategorií (například pomocí lékařského zobrazování diagnostikuje nádory, podtypy a závažnost



rakoviny) a provádí prediktivní analýzu pro spojitě výstupy (například pomocí dat z elektronických zdravotních záznamů předpovídá recidivy onemocnění, prognózu a úmrtnost (Chen & Decary, 2020, str.10-11).

## **Zástupci strojového učení pod dohledem**

### **Rozhodovací strom**

Rozhodovací strom je grafické znázornění možností a jejich výsledků strukturované jako strom. Uzly grafu symbolizují události nebo rozhodnutí, zatímco hrany představují rozhodovací pravidla nebo podmínky. Každý rozhodovací strom se skládá z uzlů a větví, kde každý uzel označuje atributy, které mají být klasifikovány, a každá větev představuje možnou hodnotu pro daný uzel. Rozhodovací stromy v podstatě rozkládají složitý rozhodovací proces na jednodušší, snadno pochopitelné kroky, což z nich činí cenný nástroj v různých oblastech pro klasifikační a predikční úlohy (Mahesh, 2020, str. 382).

Burkart tuto definici rozvádí a uvádí, že rozhodovací stromy se trénují pomocí označených vstupních funkcí, výsledkem jsou zkonstruované stromy sestávající z uzlů stromu a listových uzlů. Každému uzlu stromu je přiřazena rozdělovací funkce a hodnota, zatímco listovým uzlům je přiřazena značka třídy pro klasifikaci nebo zprůměrovaná hodnota pro regresi. Během procesu testování začíná testovací instance v horním uzlu stromu, známém jako kořenový uzel, a pohybuje se směrem dolů, dokud nedosáhne listového uzlu. V každém mezilehlém uzlu se porovnává konkrétní hodnota znaku s hodnotou dělení a podle výsledku porovnání se pokračuje buď doleva, nebo doprava. Rozhodovací stromy se obvykle vytvářejí způsobem shora dolů a nenasatným způsobem, což znamená, že jakmile je jednou vybrán prvek a jeho hodnota jako kritérium rozdělení, nelze je změnit jinou hodnotou rozdělení nebo prvkem. Navíc, zatímco každý rozhodovací strom lze převést na model založený na pravidlech, opačná transformace není možná (Burkart & Huber, 2021, str. 257).

### **Naive Bayes**

Naive Bayes metoda je klasifikační metoda vycházející z Bayesovy věty, která pracuje s předpokladem nezávislosti prediktorů. V podstatě předpokládá, že přítomnost určitého znaku ve třídě je zcela nezávislá na přítomnosti jakéhokoli jiného znaku. Klasifikátory Naive Bayes se používají především v oblasti klasifikace textu. Zaměřují se na úlohy shlukování a klasifikace založené na podmíněné pravděpodobnosti výskytu událostí (Mahesh, 2020, str. 382).

## **Support Vector Machine (SVM)**

Metoda podpůrných vektorů (Support Vector Machine, dále jen SVM) je jednou z nejrozšířenějších špičkových technik strojového učení. V oblasti strojového učení jsou SVM modely učení pod dohledem doprovázené učebními algoritmy určenými k analýze dat pro účely klasifikace i regrese. Kromě schopnosti lineární klasifikace vynikají SVM i v nelineární klasifikaci díky metodě známé jako trik jádra, která efektivně mapuje vstupy do prostorů znaků vyšších dimenzí. Základní princip SVM spočívá ve vymezení okrajů mezi třídami, přičemž je zajištěno, že okraje jsou maximálně vzdálené od tříd, aby se minimalizovaly chyby klasifikace (Mahesh, 2020, str. 382).

Lo Vercio tuto definici rozvádí a vysvětluje, že SVM jsou binární klasifikátory, které určují optimální rozhodovací hranici neboli hyperplochu v prostoru příznaků pro oddělení dvou tříd. Algoritmus hledá hyperplochu, která minimalizuje chybu zobecnění na nových datech, a to výhradně pomocí bodů nejbližších hyperploše, známých jako podpůrné vektory. Tento přístup zajišťuje, že při kreslení hranice mezi třídami jsou brány v úvahu pouze nejrelevantnější datové body, přičemž ty vzdálenější jsou efektivně ignorovány. Algoritmus SVM maximalizuje rozpětí, což je vzdálenost mezi hyperplochou a podpůrnými vektory, aby určil rozhodovací hranici, která nejlépe odděluje třídy. Pro zpracování nelineárních a zašuměných dat využívají SVM trik jádra a měkké rozpětí. Trik s jádrem transformuje rysy do vyšší dimenze, aby byly lineárně separovatelné, zatímco SVM s měkkým rozpětím současně maximalizují rozpětí a minimalizují chybu, aby zvládly zašuměná data. Regrese s podpůrnými vektory (Support Vector Regression, dále jen SVR) rozšiřuje SVM na regresní problémy tím, že přizpůsobuje hyperrovinu v rámci definované toleranční meze a snaží se minimalizovat chybu za touto mezí. SVR minimalizuje chybu způsobenou podpůrnými vektory nacházejícími se za touto mezí a regrese se provádí na základě optimalizované hyperplochy. Modely SVM a SVR vynikají tím, že pracují s relativně malým počtem příkladů, což je činí vhodnými pro mnoho úloh učení pod dohledem v oblasti medicíny, kde jsou soubory dat často malé. Trénování SVM se však může stát náročným při větších souborech dat, například v úlohách klasifikace podle pixelů a voxelů (Lo Vercio et al., 2020, str. 9).

## **CN2 Rule induction**

CN2 funguje na principu vytvoření seznamu pravidel seřazených podle důležitosti prostřednictvím iteračního procesu. Tento algoritmus postupně vyhledává pravidla, která pokrývají co nejvíce instancí datového souboru, přičemž vyhodnocuje vhodnost každého pravidla pomocí hodnotící funkce, jako je Entropie nebo Laplaceův odhad. Pokryté případy

jsou poté odstraněny a zbývající pozorování jsou pokryta dalšími pravidly, dokud nejsou zahrnuty všechny případy a nelze nalézt další pravidla. Tento proces zajišťuje, že výsledná pravidla jsou srozumitelná a použitelná (Heymann et al., 2022, str. 3).

### **Učení bez dohledu**

Na rozdíl od učení pod dohledem zahrnuje učení vzorů z neoznačených dat a často se používá pro průzkumnou analýzu velkých datových souborů, včetně úloh, jako je snižování dimenzionality dat a shlukování za účelem identifikace nových tříd v neoznačených datech. Shlukování seskupuje pozorování na základě podobných vlastností a chování, běžně se používá v kritické péči k vytvoření homogenity skupin pacientů, například kategorií založených na syndromech (Sun et al., 2024, str. 6-7).

Podle Maheshe se učení bez dohledu od učení s dohledem liší tím, že se nespolehá na správné odpovědi ani na učitele, který by řídil proces učení. Namísto toho algoritmy pracují samostatně, aby odhalily vnitřní strukturu dat. Tyto algoritmy se učí funkce z dat samotných, bez explicitního vedení. Když jsou jim předložena nová data, využívají dříve naučené rysy k identifikaci vzorů nebo tříd v datech. Učení bez dohledu se používá především pro úlohy, jako je shlukování a redukce znaků (Mahesh, 2020, str. 383).

Ve zdravotnictví hraje učení bez dohledu klíčovou roli při předpovídání individuálních rizik onemocnění pomocí genetických biomarkerů a přizpůsobování personalizované léčby na základě genomických změn. Na rozdíl od učení pod dohledem nevyžaduje učení bez dohledu označené výsledky, čímž se blíží skutečné umělé inteligenci. Bez lidského vedení je však náchylnější k chybám, protože se při předpovědích může spoléhat na triviální vlastnosti dat. Proto se v praxi často používá kombinace učení pod dohledem a bez dohledu, tzv. polopřímé učení, kdy se k tréninku využívá velké množství neoznačených dat spolu s malým podílem dat označených, čímž se využívají silné stránky obou algoritmů učení (Chen & Decary, 2020, str. 11).

### **Zástupci strojového učení bez dohledu:**

#### **K-means Clustering**

K-means patří mezi nejjednodušší techniky učení bez dohledu, které se používají k řešení všeobecně známého problému shlukování. Metoda využívá přímočarý přístup ke kategorizaci souboru dat do určitého počtu shluků. Klíčovým konceptem je určení K center, z nichž každé představuje shluk. Umístění těchto center je klíčové, protože jejich umístění významně ovlivňuje výsledek shlukování. Proto je pro dosažení optimálních výsledků vhodnější umístit je co nejdále od sebe (Mahesh, 2020, str. 383).

## **Principal Component Analysis (PCA)**

Analýza hlavních komponent (PCA) je statistická metoda, která využívá ortogonální transformaci k převodu souboru pozorování, která mohou být korelovaná, na soubor lineárně nekorelovaných proměnných známých jako hlavní komponenty. Tento proces snižuje dimenzionalitu dat, což urychluje výpočty a umožňuje jejich snadnější zvládnutí. PCA se používá k objasnění rozptylově-kovarianční struktury skupiny proměnných prostřednictvím lineárních kombinací. Slouží jako běžná technika pro redukci dimenzionality. Po PCA je dalším krokem přiřazení každého datového bodu k nejbližšímu středu. Po přiřazení všech bodů je dokončeno počáteční seskupení. Poté se přepočítají nové centroidy jako barycentra shluků z předchozího kroku (Mahesh, 2020, str. 383).

## **Posilovací učení (Reinforcement learning)**

Učení posilováním se používá, když je cílem provést sérii rozhodnutí, která vedou ke konečné odměně. V tomto procesu učení získává umělý agent na základě svých akcí buď odměny, nebo sankce. Cílem je maximalizovat kumulativní odměnu získanou v průběhu času. Příkladem může být trénování agentů pro hraní počítačových her nebo plnění úkolů v robotice s ohledem na konkrétní konečný cíl (Sah, 2020, str. 2).

Ve zdravotnictví lze posilování učení použít ve scénářích, kde agent musí neustále interagovat s prostředím a upravovat své akce na základě zpětné vazby, jako je optimalizace léčebných plánů a roboticky asistovaná chirurgie (Chen & Decary, 2020, str. 11).

### **1.4.2 Hluboké učení (Deep learning)**

Hluboké učení je metoda implementace různých algoritmů strojového učení pomocí neuronových sítí s více vrstvami. Tyto vrstvy zpracování se učí stále abstraktnější reprezentaci dat, což síti umožňuje porozumět vstupním datům na několika úrovních složitosti (Sah, 2020, str. 6).

Tento přístup vedl k průlomovým objevům v oblastech závislých na detekci příznaků a velkých objemech dat včetně počítačového vidění, rozpoznávání řeči, zpracování přirozeného jazyka, objevování léčiv a genomiky. Strojové učení bylo úspěšně aplikováno na různé typy dat, včetně obrázků, řeči, videa a textu, pro složité úlohy zahrnující rozsáhlé soubory dat, přičemž často dosahuje výsledků srovnatelných s lidskými experty nebo je dokonce předčí v přesnosti a efektivitě. V budoucnu by tyto modely mohly poskytovat klinickou inteligenci založenou na datech a důkazech, která by měla zlepšit lékařskou diagnostiku, rozhodování o léčbě, biomedicínský výzkum a poskytování zdravotnických služeb. Navzdory úspěchům v oblasti lékařského zobrazování a úloh s velkým objemem dat není strojové učení univerzálním

řešením. Může mít potíže s úlohami vyžadujícími uvažování „selským rozumem“ nebo znalosti specifické pro danou oblast, stejně jako se situacemi, které přesahují rozsah jeho tréninkových dat (Chen & Decary, 2020, str. 11).

### **Neuronové sítě (Artificial neural networks)**

Neuronová síť (dále jen ANN) je soubor algoritmů určených k identifikaci základních vzorců v datech, které se podobají fungování lidského mozku. Ať už organické, nebo umělé, neuronové sítě se skládají ze vzájemně propojených neuronů. Mají schopnost přizpůsobit se novým vstupům, což jim umožňuje dosahovat optimálních výsledků, aniž by bylo nutné zcela přepracovat výstupní kritéria. ANN funguje podobně ve třech vrstvách: vstupní, skryté a výstupní. Vstupní vrstva přijímá vstupní data, která jsou následně zpracována ve skryté vrstvě, a nakonec výstupní vrstva vytváří vypočtený výsledek (Mahesh, 2020, str. 385).

Lo Vercio popisuje funkci ANN komplexněji a to tak, že ANN se skládají z neuronů uspořádaných do vrstev, které jsou propojeny váženými spoji. Neurony přijímají příchozí signály, zpracovávají je a prostřednictvím těchto spojení předávají výstupní signály jiným neuronům. Vážená spojení upravují signály mezi neurony na základě jejich důležitosti. ANN mají obvykle vstupní vrstvu, jednu nebo více skrytých vrstev a výstupní vrstvu. Neurony v jedné vrstvě jsou propojeny s neurony v další vrstvě prostřednictvím vážených spojení a vrstvy mohou být částečně nebo plně propojené. Aby se zabránilo nadměrnému přizpůsobení, které je u ANN vzhledem k jejich složitosti běžné, často se používá technika regularizace vysazením, kdy jsou neurony a spojení během trénování dočasně odstraněny, aby se zabránilo nadměrné koadaptaci. ANN mohou rozpoznávat nelineární vztahy mezi vstupními funkcemi a výstupy pomocí nelineárních aktivačních funkcí ve skrytých vrstvách (Lo Vercio et al., 2020, str. 10-11).

### **Neuronové sítě pod dohledem**

V ANN s dohledem se síť trénuje pomocí dvojic vstup-výstup, u nichž je výstup již znám. Předpovězený ANN se porovnává se skutečným výstupem a případné rozdíly nebo chyby mezi nimi se používají k úpravě parametrů sítě. Tyto upravené parametry jsou pak vráceny zpět do ANN k dalšímu zpracování. Tento typ ANN, který se při trénování spoléhá na známé výstupy, se běžně používá v ANN typu feedforward (Mahesh, 2020, str. 385).

### **Neuronové sítě bez dohledu**

V neřízených ANN pracuje síť bez předchozí znalosti výstupu odpovídajícího vstupu. Jejím hlavním úkolem je klasifikovat data na základě podobností bez explicitního vedení. ANN

vyhodnocuje vztahy mezi různými vstupy a uspořádává je do skupin na základě jejich korelace. (Mahesh, 2020, str. 385)

## **1.5 Možnosti využití umělé inteligence v nemocničním prostředí**

Techniky umělé inteligence nabízejí významnou podporu pro komplexní řízení zdravotnických služeb a pomáhají lékařům, zdravotním sestřám a správcům v jejich úlohách. Systémy umělé inteligence mohou například poskytovat v reálném čase aktualizované lékařské informace z různých zdrojů, jako jsou časopisy, učebnice a klinické postupy, což se stává obzvláště důležitým během událostí, jako je pandemie COVID-19, kdy je nepřetržitá výměna informací nezbytná pro efektivní řízení na celém světě. Další aplikace zahrnují koordinaci informačních nástrojů pro pacienty, vydávání upozornění na zdravotní rizika a předpovídání zdravotních výsledků. Tyto aplikace zvyšují efektivitu nemocnic a zdravotní péče tak, že umožňují lékařům okamžitý přístup k datům, zajišťují lepší bezpečnost pacientů při podávání léků zdravotními sestrami a udržují pacienty informované a zapojené do jejich péče. Kromě toho umělá inteligence přispívá k optimalizaci logistických procesů, například k řízení zásob léků a vybavení prostřednictvím systémů just-in-time založených na prediktivních algoritmech. Tyto aplikace mohou také podpořit školení personálu ve zdravotnictví a potenciálně tak překlenout rozdíly mezi městskou a venkovskou zdravotní péčí. Kromě toho může umělá inteligence prospět řízení zdravotnických služeb tím, že využije mnohočetnost dat elektronických zdravotních záznamů, předpoví heterogenitu dat v nemocnicích a klinikách, identifikuje odlehle hodnoty, provádí klinické testy, sjednocuje zastoupení pacientů, zlepšuje budoucí prediktivní modely a poskytuje srovnávací údaje pro analýzu služeb (Secinaro et al., 2021, str. 16).

Ve světě se postupně zmenšuje propast mezi digitálními technologiemi a umělou inteligencí. Ve zdravotnictví se pacienti aktivněji podílejí na správě svého zdraví tím, že vyhledávají informace online a využívají UI a digitální zařízení, která doplňují práci zdravotnického personálu. Tento posun směrem k posílení postavení pacientů změnil zdravotní péči z izolované služby na dynamický ekosystém zahrnující různé faktory, jako je strava, cvičení a preventivní medicína. Technologie umělé inteligence hrají v tomto ekosystému zásadní roli a pomáhají zdravotnickému personálu při diagnostice a operacích (Lee & Yoon, 2021, str. 13).

Pro využívání systémů založených na UI ve zdravotnictví je zásadní spolupráce odborníků z různých oblastí. Úsilí by se navíc mělo zaměřit na přechod nahraditelných zaměstnanců do nových rolí a na podporu spolupráce mezi lékařskou komunitou, odvětvím informačních a komunikačních technologií a státní správou v oblasti výzkumu lékařské

informatiky a analýzy velkých objemů dat ve zdravotnictví. Mimo to by mělo být vzdělávání a školení v oblasti umělé inteligence začleněno do různých vysokoškolských oborů, včetně lékařských fakult, aby se budoucí lékaři připravili na digitální éru. Důraz na vzdělávání pacientů a poskytování snadno dostupných systémů s podporou UI může podpořit účast pacientů a zlepšit výsledky zdravotní péče. Posílení systémů ochrany informací je zásadní pro prevenci narušení bezpečnosti údajů a udržení důvěry pacientů, což vyžaduje vytvoření důkladných opatření kybernetické bezpečnosti a dohod o morální odpovědnosti ve zdravotnických zařízeních (Lee & Yoon, 2021, str. 14).

### **1.5.1 Příklady využití UI v nemocničním prostředí**

#### **Diagnostická asistence**

Technologie umělé inteligence se ve zdravotnictví stále častěji využívají pro diagnostické účely s cílem snížit počet chyb a zlepšit výsledky pacientů. Diagnostické chyby, které tvoří významnou část lékařských omylů a mají za následek desítky tisíc úmrtí ročně v amerických nemocnicích, lze zmírnit pomocí nástrojů využívajících umělou inteligenci. Navzdory rozdílům v míře shody mezi doporučeními UI a rozhodnutími lékařského personálu je UI považována za cenný nástroj při poskytování komplexních možností léčby a zvyšování spokojenosti pacientů (Lee & Yoon, 2021, str. 6-7).

Ve zdravotnictví UI figuruje hlavně ve zobrazovací diagnostice tak, že rychle analyzuje rentgenové snímky, CT a MRI, a pomáhá tak lékařům v přesné diagnostice. Tradičně se diagnostika do značné míry opírala o lidské odborné znalosti, ale umělá inteligence snižuje počet chyb a urychluje tento proces. UI pomáhá identifikovat abnormality a měřit vlastnosti snímků, čímž zvyšuje přesnost a snižuje variabilitu. Mimo to UI pomáhá při třídění tím, že určuje priority případů podle závažnosti, čímž zefektivňuje pracovní postupy. UI však pouze doplňuje, nikoli nahrazuje zdravotnické pracovníky, poskytuje další data a poznatky, které pomáhají při diagnostice, přičemž konečné rozhodnutí je na odborníkovi (Adelaja & Alkattan, 2023, str. 45).

#### **Rakovina prsu**

Umělá inteligence významně ovlivnila lékařské zobrazování při diagnostice rakoviny prsu, zejména při analýze mamogramů za účelem zvýšení přesnosti. Tyto algoritmy účinně rozpoznávají a kategorizují abnormality, čímž napomáhají včasné detekci díky odhalení jemných změn v prsní tkáni. Řešení s umělou inteligencí snižují variabilitu mezi radiology a upřednostňují případy pro další vyšetření, čímž zvyšují diagnostickou přesnost a efektivitu třídění. Algoritmy hlubokého učení přispívají identifikací šíření rakoviny v prsu a vytvářením

modelů predikce rizika pomocí rozsáhlých souborů dat. Zohledněním faktorů, jako je rodinná anamnéza, věk a hustota prsu, mohou systémy UI identifikovat vysoce rizikové jedince, což umožňuje včasnější detekci a lepší výsledky léčby (Adelaja & Alkattan, 2023, str. 45-46).

### **Onemocnění očí**

Umělá inteligence v oblasti léčby očních onemocnění nabízí neinvazivní a objektivní metodu diagnostiky pomocí analýzy různých zobrazovacích metod, jako je fotografie očního pozadí, OCT a testování zorného pole, což vede k přesnější a včasnější diagnostice běžných očních poruch, jako je glaukom a diabetická retinopatie. Algoritmy umělé inteligence využívají pokročilé strojové učení a hluboké ANN k detekci vzorů v lékařských snímcích, což umožňuje rychlejší zpracování a včasnější odhalení abnormalit. V oftalmologii se UI používá k analýze snímků sítnice pro poruchy, jako je glaukom a makulární degenerace, k vyhodnocování údajů o optickém nervu pro včasnou detekci glaukomu, k vyhodnocování skenů rohovky pro stavy, jako je keratokonus, a k analýze příznaků hlášených pacienty prostřednictvím chatbotů nebo virtuálních asistentů pro včasnou diagnostiku a třídění (Adelaja & Alkattan, 2023, str. 46).

### **Neurologická onemocnění**

Diagnostika neurologických poruch je náročná a často vyžaduje odborné znalosti neurologů a řadu diagnostických testů. UI se objevila jako potenciální nástroj, který může v tomto procesu pomoci analýzou široké škály zdrojů dat, jako jsou klinické poznámky, EEG záznamy, MRI, CT a PET skeny. Umělá inteligence dokáže interpretovat lékařská zobrazovací data a odhalit abnormality související se stavy, jako je mrtvice, mozkové nádory, roztroušená skleróza a Alzheimerova choroba, a tím zlepšit diagnostickou přesnost a snížit počet možností interpretace. Interpretuje také data EEG k diagnostice stavů, jako je epilepsie a poruchy spánku. Dále umělá inteligence analyzuje genetická data k identifikaci specifických neurologických onemocnění s dědičnou složkou, což umožňuje přesnější a personalizovanější diagnostiku (Adelaja & Alkattan, 2023, str. 46-47).

### **Kardiovaskulární onemocnění**

V rámci problematiky kardiovaskulárních onemocnění systémy umělé inteligence analyzují rozsáhlé soubory dat, včetně údajů o pacientech z lékařských záznamů a zobrazovacích vyšetření, aby vyhodnotily riziko vzniku KVO u jednotlivce a identifikovaly vysoce rizikové pacienty. Tyto algoritmy rovněž analyzují lékařská zobrazovací vyšetření, jako jsou echokardiogramy, CT a MRI, aby odhalily anomálie, například oslabený srdeční sval nebo problémy s chlopněmi. Umělá inteligence může také analyzovat data EKG a odhalit abnormální



srdeční rytmus nebo ischemické abnormality. Predikční modely odhadují pravděpodobnost, že se u pacienta vyskytne kardiovaskulární onemocnění nebo negativní srdeční příhoda, a řídí se tak preventivními opatřeními a plány léčby. Systémy na podporu rozhodování s umělou inteligencí poskytují návrhy nebo diferenciální diagnózy na základě uznávaných postupů a předchozích případů, čímž pomáhají poskytovatelům zdravotní péče při stanovování přesných diagnóz a vedení individuálních rozhodnutí o léčbě (Adelaja & Alkattan, 2023, str. 47).

### **Onemocnění gastrointestinálního traktu**

Obor gastroenterologie prochází transformací díky integraci umělé inteligence, která zlepšuje diagnostiku poruch trávicího systému. Algoritmy umělé inteligence zjednodušují identifikaci, kategorizaci a léčbu různých gastrointestinálních onemocnění analýzou dat pacientů, lékařských snímků a klinických záznamů. UI umožňuje diagnostiku onemocnění trávicího traktu několika metodami: analýza obrazu umožňuje systémům UI odhalit anomálie, jako jsou polypy, vředy, nádory nebo známky zánětu v trávicím traktu, což napomáhá přesné diagnostice a plánům léčby. Schopnost UI rozpoznávat vzory identifikuje vzory v datech pacientů, včetně příznaků, anamnézy a výsledků testů, a nabízí tak náhled na poruchy, jako jsou zánětlivá onemocnění střev, celiakie, zánět slinivky břišní nebo onemocnění jater. Systémy pro podporu rozhodování na bázi umělé inteligence poskytují gastroenterologům hodnotné rady na základě zavedených norem a předchozích případů a zlepšují rychlost a přesnost diagnostiky tím, že analyzují údaje o pacientovi a výsledky testů a vytvářejí diferenciální diagnózy nebo navrhuje další postupy. Algoritmy UI rovněž provádějí stratifikaci rizika analýzou genetických markerů a anamnézy s cílem identifikovat osoby ohrožené gastrointestinálními poruchami, což usnadňuje včasné zásahy nebo preventivní opatření. Prediktivní analýzy využívající masivní soubory dat navíc umožňují UI předpovídat vývoj onemocnění a účinnost léčby, což umožňuje přizpůsobit léčbu a zlepšit výsledky léčby pacientů v globálním měřítku (Adelaja & Alkattan, 2023, str. 47-48).

### **Ošetřovatelská a manažerská pomoc**

Ve zdravotnictví se stále častěji používají technologie založené na umělé inteligenci, které mají ulehčit od papírování a zlepšit procesy péče o pacienty. Zavádějí se elektronické systémy, které integrují a digitalizují lékařské záznamy, a také se v nemocnicích využívají chatboti pro zapojení pacientů. Například Cleavelandská klinika využívá digitální asistentku Cortanu od společnosti Microsoft s umělou inteligencí k identifikaci rizikových pacientů v péči na jednotce intenzivní péče prostřednictvím prediktivní analýzy. Podobně Univerzitní nemocnice Johnse Hopkinse spolupracuje se společností GE Healthcare na zavádění prediktivní analýzy

pro efektivnější provozní tok. Tyto technologie umělé inteligence vedly k významným zlepšením, jako je rychlejší přidělování lůžek na pohotovosti, snížení prodlev při převozu a lepší přijímání pacientů se složitými zdravotními stavy. Kromě toho jsou využívány roboticky asistované operace a virtuální asistenti pro zdravotní sestry, kteří zvyšují přesnost chirurgických zákroků a pomáhají s úkony péče o pacienty. Příkladem jsou roboti Alexa v nemocnici Cedars-Sinai a robot s umělou inteligencí Paul v nemocnici Eunpyeong St Mary's Hospital, kteří zefektivňují úkoly zdravotnického personálu a poskytují pacientům pomoc v reálném čase (Lee & Yoon, 2021, str. 7-8).

### **Ošetrovatelská péče**

Umělá inteligence se využívá v přímé ošetrovatelské péči k zefektivnění procesů péče a poskytování podpory osobám závislým na péči a rodinným pečovatelům prostřednictvím sledování, monitorování a klasifikace činností a zdravotních údajů. Zpočátku se aplikace zaměřovaly na pomoc při koordinaci péče, komunikaci, sestavování rozpisu sester a plánování. Technologie umělé inteligence byla také použita k detekci, klasifikaci a prevenci pádů, stejně jako k rozpoznání, klasifikaci a snížení počtu alarmů a k předvídaní a klasifikaci dekubitů (Seibert et al., 2021, str. 11).

Ruksakulpiwat rozděluje využití UI v ošetrovatelské péči do šesti hlavních témat: Identifikace rizik, Hodnocení zdravotního stavu, Klasifikace pacientů, Vývoj výzkumu, Zlepšení poskytování péče a zdravotnické dokumentace a Plánování ošetrovatelské péče (Ruksakulpiwat et al., 2024, str. 1606).

### **Nemocniční management**

Složitost řízení klinické medicíny představuje pro manažery v ošetrovatelství výzvu, ale řízení medicíny s pomocí umělé inteligence v kombinaci s preventivní medicínou nebo precizní péčí by mohlo posílit ošetrovatelskou profesi. Manažeři v ošetrovatelství mohou být informováni o aktuálních tématech ošetrovatelského výzkumu, aby mohli pracovat vědečtěji a držet krok s nejnovějším vývojem. Kvůli tomu bude klíčová mezioborová spolupráce, která vyžaduje, aby se ošetrovatelští manažeři seznamovali s mezinárodním vývojem, spolupracovali napříč různými obory a zapojovali se do akademických debat a konzultací. Porozumění oblastem a problémům výzkumu může pomoci sladit politiku a klinickou praxi, což umožní výzkumným pracovníkům v ošetrovatelství využívat jako referenční body modely klinické praxe založené na důkazech a zdravotních potřebách pacientů. Rostoucí informatizace zdravotnických zařízení zdůrazňuje, že je důležité, aby se manažeři v ošetrovatelství zaměřili na vzdělávání sester, vypracovali strategie školení pro personál a začlenili poznatky o umělé inteligenci do klinické

praxe. Kromě toho mohou manažeři v ošetrovatelství efektivně rozdělovat zdroje, spolupracovat s mezinárodními institucemi, podporovat pokrok v ošetrovatelském výzkumu a posilovat vědeckou povahu ošetrovatelství (Chang & Su, 2022, str. 3651).

### **Management rizik**

Management rizik má v nemocnicích zásadní význam pro bezpečnost pacientů, řídí klinická rizika, zajišťuje bezpečnost informací, usiluje o snížení provozních rizik, dodržování předpisů a řízení lidských zdrojů. UI hraje v těchto oblastech významnou roli, protože analyzuje údaje o pacientech v reálném čase, aby odhalila včasné příznaky zhoršení stavu je tak schopna identifikovat faktory spojené s nežádoucími událostmi. Umělá inteligence dále pomáhá standardizovat klinické postupy, zlepšovat přesnost diagnostiky prostřednictvím rozpoznávání obrazu a zvyšovat přesnost záznamů o pacientech prostřednictvím zpracování přirozeného jazyka. Mimo to UI nepřetržitě monitoruje síťový provoz z hlediska kybernetických bezpečnostních hrozeb, pomáhá při dodržování předpisů o ochraně osobních údajů a odhaluje anomální vzorce chování uživatelů, aby se zabránilo vnitřním hrozbám. Prediktivní analýzy poháněné UI zmírňují provozní rizika předvídáním a řešením narušení dodavatelského řetězce nebo nedostatku personálu. Současně může hrát významnou roli při dodržování právních předpisů sledováním a analýzou dat z hlediska chyb ve fakturaci a automatizací auditů. UI také pomáhá při řízení lidských zdrojů tím, že pomáhá při náboru, analyzuje vzorce související s rizikem vyhoření nebo fluktuace zaměstnanců a zlepšuje jejich pohodu a setrvání v zaměstnání (Božić, 2023, str. 66-67).

### **Lidské zdroje**

Technologie umělé inteligence doplňují lidské interakce, zvyšují efektivitu řešení problémů, poskytují školení a podporují zaměstnance, což vyžaduje vytvoření organizačního prostředí, v němž mohou lidé a technologie koexistovat. Vedoucí pracovníci by měli sehrát zásadní roli při podpoře zapojení zaměstnanců do školení a jejich průběžného rozvoje, aby splňovali kritéria a dovednosti potřebné pro práci s agenty umělé inteligence tak, aby se zvýšily jejich technologické znalosti a konkurenceschopnost na globálním trhu. Přestože řízení lidských zdrojů zaměřené na technologie nabízí řadu výhod, existuje riziko, že technologie zastíní a nahradí odborníky v oblasti řízení lidských zdrojů, což poukazuje na důležitost zachovat rovnováhu a zajistit, aby technologie posilovaly, nikoli nahrazovaly lidské odborné znalosti. Kromě toho roste potřeba předpisů na ochranu soukromí zaměstnanců a řešení etických výzev, které přináší technologický pokrok v oblasti lidských zdrojů, jako jsou aplikace umělé inteligence, strojového učení a hlubokého učení (Vrontis et al., 2022, str. 1255-1256).

## 1.6 Etické aspekty použití UI ve zdravotnictví

V posledních letech se ML stalo transformativní silou v oblasti zdravotnictví, kde ukázalo pozoruhodný potenciál v oblastech, jako je diagnostika, prediktivní analýza a automatizace administrativních úkolů. Rychlá integrace ML do systémů zdravotní péče vyvolala poptávku po kontrole jeho etických důsledků. Přestože ML slibuje revoluční pokrok, obavy týkající se soukromí dat, algoritmické spravedlnosti a autonomie rozhodování vzbudily ve vědeckých a lékařských komunitách značnou pozornost. Jedna z hlavních etických otázek se točí kolem ochrany citlivých zdravotnických údajů vzhledem k rozsáhlému využívání velkých souborů dat při trénování modelů ML. Navzdory existujícím opatřením, jako je šifrování a anonymizace, přetrvávají obavy z možného narušení a zneužití dat. Kromě toho dat. Otázky představuje významnou výzvu algoritmická spravedlnost a zaujatost, přičemž první implementace upozorňují na riziko diskriminačních výsledků v oblasti zdravotní péče na základě zaujatých nebo nereprezentativních dat. Rozhodnutí delegovaná na ML algoritmy navíc vyvolávají důležitá etická dilemata, zejména ve scénářích, kdy složité algoritmy pracují s omezeným lidským porozuměním, což může ohrozit zásady informovaného souhlasu a sdíleného rozhodování. Probíhající diskuse o "algoritmickém rozhodování" zdůrazňuje potřebu přísných etických rámců, které by zajistily transparentnost, spravedlnost a odpovědnost v aplikacích ML ve zdravotnictví. Ačkoli byly navrženy různé etické rámce, stále se diskutuje o jejich komplexnosti a přizpůsobivosti, zejména s vývojem ML technologií. Řešení těchto obav vyžaduje společné úsilí zahrnující zdravotníky, datové vědce, tvůrce politik a pacienty, aby se vyvinuly praktické a vymahatelné etické pokyny, které upřednostňují soukromí dat, transparentnost algoritmů a autonomii pacientů. Navzdory dosaženému pokroku přetrvávají problémy, jako je soukromí údajů, informovaný souhlas, algoritmická zaujatost, transparentnost a odpovědnost, které zdůrazňují potřebu neustálého zdokonalování etických rámců na podporu odpovědného zavádění ML ve zdravotnictví (Javed et al., 2024, str. 16233–16235).

### 1.6.1 Etické výzvy využití UI ve zdravotnictví

#### Ochrana osobních údajů a bezpečnost

V oblasti zdravotní péče vyvolává nasazení ML značné obavy týkající se soukromí a bezpečnosti údajů. Údaje ve zdravotnictví, které zahrnují množství citlivých informací od chorobopisů pacientů až po genomické údaje, podléhají přísnému regulačnímu dohledu kvůli požadavkům na jejich důvěrnost. Vzhledem k tomu, že algoritmy ML jsou pro optimální fungování závislé na přístupu k těmto datům, vznikají obavy ohledně důvěrnosti, integrity a dostupnosti těchto dat. Neoprávněný přístup, narušení dat a nedostatečně provedené iniciativy

sdílení dat představují riziko pro soukromí pacientů. Neprůhlednost ML algoritmů, zejména modelů hlubokého učení, navíc komplikuje pochopení využití dat a souvisejících procesů. K řešení těchto obav byly vyvinuty různé technické přístupy. Základními technikami jsou šifrování a anonymizace dat, přičemž šifrování transformuje data do kódu, aby se zabránilo neoprávněnému přístupu, a anonymizace odstraňuje nebo upravuje osobní údaje tak, aby byly anonymní. Obě metody však mají svá omezení, jako je možnost dešifrování zašifrovaných údajů a reverzibilita anonymizace v kombinaci s dalšími zdroji dat. Cílem diferenciální ochrany soukromí je vyvážit přesnost údajů a soukromí přidáním šumu do souborů dat, ačkoli to může ohrozit výkonnost algoritmu. Federativní učení umožňuje trénovat ML modely napříč decentralizovanými zařízeními, která drží lokální vzorky dat, bez nutnosti výměny dat, což zajišťuje soukromí dat, ale za cenu výpočetních nákladů. Homomorfní šifrování umožňuje provádět výpočty na zašifrovaných datech a poskytuje další úroveň zabezpečení tím, že vytváří zašifrované výsledky bez dešifrování. Přísné řízení přístupu k datům, jako je řízení přístupu na základě rolí nebo atributů, snižuje riziko neoprávněného použití dat, zatímco nepřetržité monitorování a audit pomáhají odhalovat a předcházet vnitřním hrozbám. Dodržování stávajících předpisů, jako je HIPAA nebo GDPR, je zásadní, i když orientace v jejich požadavcích může být složitá. Celkově je nezbytné komplexní pochopení technických strategií pro zajištění ochrany osobních údajů v aplikacích ML ve zdravotnictví (Javed et al., 2024, str. 16236-16237).

### **Informovaný souhlas**

Informovaný souhlas, základní zásada lékařské etiky, zajišťuje, že pacienti plně chápou lékařské postupy a souhlasí s nimi. Integrace strojového učení však do této zásady vnáší komplikace. Algoritmy analyzují údaje o pacientech a vytvářejí předpovědi nebo doporučení, která mají přímý dopad na péči, což zvyšuje problém získání informovaného souhlasu pro algoritmická rozhodování. Neprůhledná povaha mnoha algoritmů, zejména hlubokých ANN, představuje obtíže při srozumitelném vysvětlování jejich fungování pacientům. Tradiční procesy udělování souhlasu jsou přizpůsobeny konkrétním lékařským postupům, zatímco modely strojového učení využívají data pro více účelů, což vede ke spornosti rozsahu souhlasu. Pacienti také musí pochopit, že algoritmická rozhodnutí jsou pravděpodobnostními odhady, které nemusí být vždy správné. Na rozdíl od tradičních léčebných postupů se známými riziky jsou rizika algoritmických rozhodnutí mlhavá, což představuje značný problém pro získání úplného informovaného souhlasu. Načasování získání souhlasu navíc vyvolává etické otázky, zejména pokud jde o retrospektivní souhlas s analýzou údajů. Různá úroveň vzdělání

a porozumění pacientů spolu s kulturními rozdíly v normách ochrany soukromí a souhlasu navíc zvyšují možnost vzniku nedorozumění a problémů. Právní rámce jako HIPAA a GDPR řeší souhlas s údaji, ale nemusí dostatečně řešit problémy strojového učení ve zdravotnictví. Přizpůsobení informovaného souhlasu tak, aby zohledňoval zásahy strojového učení, je tedy nezbytné, ale velmi náročné (Javed et al., 2024, str. 16237-16238).

Získání zákonného souhlasu se shromažďováním citlivých informací od pacientů představuje problém, zejména při definování struktury a načasování souhlasu, aby byla respektována autonomie uživatelů a jejich lidská práva. Tato nejistota ohledně používání údajů a jeho důsledků podtrhuje etická dilemata, jako je Collingridgeovo dilema, zpochybňující zavedené normy týkající se ochrany soukromí a údajů. Zásady, jako je transparentnost, jsou sice zakotveny v předpisech, jako je směrnice EU o ochraně údajů, ale samy o sobě nemohou zajistit etickou a odpovědnou umělou inteligenci pro digitální zdraví (Trocin et al., 2023, str. 2150).

### **Collingridgeovo dilema**

Collingridgeovo dilema se zabývá problémy spojenými s kontrolou technologií. Tvrdí, že pokusy o kontrolu technologií jsou obtížné kvůli zásadnímu problému s časem: v raných fázích technologického vývoje, kdy je možné kontrolu vykonávat, není dostatek znalostí o možných škodlivých sociálních důsledcích, které by takovou kontrolu ospravedlnily. Avšak v době, kdy se tyto důsledky stanou zjevnými, je kontrola technologie již nákladná a pomalá. Toto dilema poukazuje na inherentní obtížnost účinného řízení technologických inovací, zejména pokud jde o řešení nepředvídaných nebo nezamýšlených důsledků (Genus & Stirling, 2018, str. 63).

### **Spravedlnost a zaujatost**

Algoritmy strojového učení trénované na reálných datech přebírají předsudky přítomné ve společnosti, což může prohlubovat rozdíly ve zdravotní péči. Předpojatost při sběru dat, často zkreslená směrem k určitým demografickým skupinám, může ohrozit přesnost a spravedlnost algoritmických předpovědí, zejména u nedostatečně zastoupených skupin. To může vést k nesprávným diagnózám nebo nevhodné léčbě, což představuje vážné riziko pro zdraví pacientů. Algoritmy navíc mohou udržovat a zesilovat sociální předsudky přítomné v datech, což může vést k nespravedlivému poskytování zdravotní péče. Složitější algoritmy, jako jsou hluboké ANN, mohou zdroje zkreslení zahalit, což komplikuje snahy o jejich řešení. Nemedicínské informace, jako jsou socioekonomické ukazatele v údajích o zdravotní péči, mohou dále prohlubovat předsudky a potenciálně znevýhodňovat osoby z nižších socioekonomických vrstev. Navzdory společenskému uvědomění těchto problémů chybí

standardizované etické pokyny a předpisy zaměřené na spravedlnost a zaujatost algoritmů ve zdravotnictví. Bezprostřední reálné důsledky neobjektivních algoritmů poukazují na naléhavost řešení algoritmické zaujatosti jako etického dilematu s hmatatelnými důsledky. Zatímco výzkum zkoumá techniky snížení zaujatosti, etické úvahy a kompromisy přetrvávají. Kromě toho zůstává klíčovým aspektem etického řízení v oblasti strojového učení ve zdravotnictví definování odpovědnosti za neobjektivní výsledky (Javed et al., 2024, str. 16238-16239).

Při zpracování lékařských dat naráží umělá inteligence na různá omezení zpracování, která ovlivňují spolehlivost jejích výsledků. Důkazy vytvořené umělou inteligencí mohou být ovlivněny kvalitou dat, která využívá, což vede k možným nepřesnostem a závislosti na perspektivě pozorovatele. Tato omezení pramení z více zdrojů, včetně fází návrhu a implementace UI v organizacích, které jsou často formovány hodnotami návrhářů a implementátorů. Kromě toho ke zkreslení přispívají technická omezení a problémy při používání UI. Navíc vzhledem k tomu, že UI je školená lidskými odborníky, může předsudky zdědit od samého počátku, což je dále upevňuje v procesu učení a potenciálně zhoršuje poškození osob zapojených do zdravotní péče (Trocin et al., 2023, str. 2150–2151).

Řešení předpojatosti v modelech umělé inteligence je zásadní, zejména pokud jsou rozhodnutí ovlivněna citlivými atributy, jako je rasa, pohlaví nebo náboženství. V literatuře o spravedlnosti v umělé inteligenci jsou uvedeny tři hlavní přístupy k řešení tohoto problému. Zaprvé, zaujatost může pocházet ze samotných dat, což vyžaduje kroky předzpracování, aby se odstranily problémy s datovým souborem. Za druhé, kritéria spravedlnosti mohou být začleněna po učení, aby se upravil model a zajistila se spravedlnost. Za třetí, omezení spravedlnosti lze začlenit do samotného procesu učení a sladit je s hlavním cílem učení. Navzdory snahám o prosazování spravedlnosti neexistují žádná definitivní řešení, což odráží problémy, kterým čelí lidské společnosti. Školení systémů umělé inteligence při absenci vhodných souborů dat a teorií představuje značné překážky, zejména pokud tyto systémy musí zohlednit citlivé atributy. Zajištění spravedlnosti v modelech UI tak zůstává složitým a trvalým úsilím (Sookhak & Forestiero, 2022, str. 7).

Evropská komise komentuje problematiku zaujatosti takto:

„Vzhledem k tomu, že mnoho systémů umělé inteligence, například ty, které obsahují komponenty strojového učení pod dohledem, se spoléhají na obrovském množství dat, je důležité pochopit, jak data ovlivňují chování systému. Například pokud jsou trénovací data zkreslená, tj. nejsou dostatečně vyvážená nebo inkluzivní, systém UI vycvičený na takových datech nebude schopen dobře zobecňovat a bude případně činit nespravedlivá rozhodnutí, která mohou zvýhodňovat některé skupiny na úkor jiných. V poslední době se komunita UI zabývá

metodami, které umožňují odhalit a zmírnit zkreslení při trénování systému na datových sadách a také v dalších částech systému UI“ (High-Level Expert Group on Artificial Intelligence, 2019, str. 5).

### **Autonomie a rozhodování**

Integrace strojového učení do zdravotnictví vnáší do tradičních rozhodovacích procesů komplikovanost a zpochybňuje roli zdravotníků a pacientů v oblasti autonomie a rozhodování. Přestože algoritmy strojového učení nabízejí cenné poznatky z rozsáhlých souborů dat, jejich neprůhledná povaha, zejména u modelů hlubokého učení, vyvolává obavy ohledně transparentnosti a důvěry v rozhodování v oblasti zdravotnictví. Tento nedostatek porozumění může narušit autonomii pacienta a narušit důvěru mezi pacienty a poskytovateli zdravotní péče. Navíc hrozí riziko přílišného spoléhání se na technologie, což může snížit schopnost se samostatně rozhodovat u zdravotníků, kteří se mohou příliš podřizovat doporučením algoritmů. Informovaný souhlas, který je základním kamenem autonomie a svobodné vůle pacienta, se kvůli složitosti algoritmů strojového učení stává obtížným a brání pacientům plně pochopit důsledky jejich rozhodnutí. Strojové učení navíc postrádá etické uvažování a nedokáže pochopit emocionální a etické uvažování, které je vlastní lidskému rozhodování, což dále komplikuje integraci algoritmů do rozhodovacích procesů ve zdravotnictví (Javed et al., 2024, str. 16239-16241).

Nepřehlednost UI, často označovaná jako "black-boxed medicine", umocňuje obavy pacientů a legitimitě postupu s použitím UI, protože zdravotníci často neznají složité postupy, které UI dodržuje, a mohou čelit dilematům při vyvažování spoléhání se na lidské odborné znalosti a návrhy UI (Trocin et al., 2023, str. 2151).

Vnímání umělé inteligence jako přirozeně objektivnější, než lidské poznání může být zavádějící, protože vzorce identifikované umělou inteligencí mohou trpět nadměrným přizpůsobením a postrádat smysluplnost v návaznosti na omezené velikosti vzorku. V důsledku toho je zpochybněna reprodukovatelnost a vnější platnost rozhodnutí řízených UI ve zdravotnických zařízeních, což zpochybňuje vědeckou přísnost těchto metod a vyžaduje kritickou diskusi mezi tvůrci politik a odborníky z praxe o míře důvěry v rozhodnutí řízená UI (Trocin et al., 2023, str. 2149).

## **1.7 Legislativa UI**

Umělá inteligence stále častěji nahrazuje pokročilé technologie algoritmizace, což umožňuje provádět opakující se a relativně jednoduché úkoly mnohem rychleji než dříve, což dříve



vyžadovalo mnoho času kvalifikovaných pracovníků. Standardizace vstupních dat však představuje výzvu, protože je musí zpracovávat programy s předem danou syntaxí, přestože algoritmy mají mnoho možností vlastní modifikace na základě měnících se pravidel zpracování a výsledků. Teprve vývoj univerzální AGI bude skutečně odrážet schopnosti lidského mozku vnímat a zpracovávat data. AGI umožní digitálním systémům řídit se postupnými iteracemi zpracování dat a někdy provádět akce, které se na základě předchozích zkušeností mohou zdát nelogické. Přesto pokročilé algoritmy schopné automatizace stále více pronikají do různých oblastí našeho života, zejména do podnikání, včetně řízení lidských zdrojů. Jedním z hlavních nedostatků umělé inteligence je její neschopnost porozumět měkkým dovednostem souvisejícím s lidskou osobností, postoji, rozhodnutím a chováním. Ve výzkumných ústavech a laboratořích technologických společností se objevily snahy o digitální analýzu "řeči těla" a výrazů tváře z nahraných videí, ale při extrakci pravidel z nesouvisejících materiálů může docházet k chybám (Oleksiewicz, 2022, str. 56).

Plán budování začleňování informatiky do společnosti, včetně umělé inteligence, v Evropské unii byl zahájen zveřejněním bílé knihy "Růst, konkurenceschopnost a zaměstnanost – výzvy a cesty vpřed do 21. století, COM (93)700 v konečném znění" v roce 1993. Tento dokument se zaměřil především na ekonomické otázky, přičemž prioritou byla konkurenceschopnost ekonomiky Evropského společenství a přijetí standardů IT vyvinutých Spojenými státy. Rozvoj politiky začleňování informačních a komunikačních technologií do společnosti však začal zveřejněním Bangemannovy zprávy v roce 1994 s názvem "Evropa a globální informační společnost: Doporučení Evropské radě", která nastínila politiku Evropské unie v této oblasti. Mezi následné iniciativy patřila Zelená kniha "Život a práce v informační společnosti" z roku 1996, která se zaměřila na důsledky transformace směrem k informační společnosti pro občany a dopad informačních a komunikačních technologií na jejich život. Cílem iniciativy eEurope, která byla zahájena v roce 1999 zveřejněním dokumentu "eEurope Informační společnost pro všechny, COM (1999) 687 v konečném znění", bylo vybudovat v členských státech moderní a silnou ekonomiku. Dalším významným mezníkem byl evropský summit ve Feiře v roce 2000, na kterém byl přijat plán eEurope 2002, zdůrazňující potřebu rozvoje rychlého, levného a univerzálního internetu, investic do lidského potenciálu a popularizace využívání virtuální sítě. V roce 2001 byl na summitu v Göteborgu představen plán "eEurope 2003: Společné úsilí o zavedení informační společnosti v Evropě – akční plán", který se zaměřil na urychlení reform, stimulaci modernizace ekonomik kandidátských zemí, zlepšení konkurenceschopnosti a sociální soudržnosti. Plán rozvoje informační společnosti do roku 2005 byl přijat na summitu Evropské unie v Seville v roce 2002 dokumentem "eEurope

2005: Informační společnost pro všechny – akční plán, COM (2002) 263 v konečném znění." Cílem tohoto plánu byl rozvoj elektronických služeb, zajištění všeobecného přístupu k širokopásmovému internetu, vytvoření dynamického prostředí pro elektronickou ekonomiku a vytvoření systému bezpečnosti informační infrastruktury. Pokud jde o dopad technologií, zejména umělé inteligence a robotiky, na budoucnost práce a sociálních vztahů, existují obavy z dehumanizace a omezení kreativity. Technologie sice mohou významně urychlit rozhodovací procesy a zpracovávat složitá data, ale existují rizika chyb a nepředvídatelných výsledků v důsledku technických faktorů a omezení, která jsou vlastní algoritmům a systémům zpracování dat (Oleksiewicz, 2022, str. 57-59).

Významným problémem zůstává právní status umělé inteligence v Evropské unii, neboť umělá inteligence v současné době nemá právní způsobilost a podle stávajících zákonů nemůže být činěna odpovědnou za škody způsobené jejím provozem. Vývoj umělé inteligence v různých oblastech života představuje výzvu, zejména pokud jde o sociální a morální důsledky. Například interakce mezi zákazníky a sociálně interaktivními roboty vyvolává obavy z možných psychických závislostí, které by mohly korporace vyvíjející takové roboty zneužívat. Nick Bostrom naznačuje, že schopnosti umělé inteligence se systematicky vyvíjejí nad úroveň lidských schopností. K řešení těchto otázek vydal Evropský parlament v roce 2017 usnesení o občanském právu nazvané "Pravidla robotiky", v němž navrhuje stanovit právní status UI. Tato rezoluce doporučila přiznat robotům zvláštní status známý jako elektronická osobnost nebo jim přiznat subjektivitu právnických osob, a to zejména v případě nejrozvinutějších systémů UI. Cílem tohoto návrhu bylo zavést nezávislou odpovědnost za škody způsobené roboty. Evropská komise následně v dubnu 2018 představila iniciativu Umělá inteligence pro Evropu, jejímž cílem je posílit technologickou kapacitu, připravit se na socioekonomické změny a zajistit etický a právní rámec v souladu s evropskými hodnotami. Iniciativu v červnu 2018 schválila Evropská rada. Komise dále v prosinci 2018 přijala Koordinovaný plán pro umělou inteligenci, po němž v únoru 2020 následovalo zveřejnění bílé knihy o umělé inteligenci, která klade důraz na dokonalost a důvěru v umělou inteligenci. Kromě toho bylo vyvinuto úsilí o posílení kybernetické bezpečnosti v EU, včetně přijetí Aktu o kybernetické bezpečnosti v dubnu 2019 a zřízení společné kybernetické jednotky v srpnu 2021. Mimo jiné Evropský parlament a Rada v dubnu 2021 zveřejnily návrh nařízení týkající se vytvoření harmonizovaných právních norem pro systémy UI v EU s důrazem na lidská práva a základní zásady. Stávající právní rámec uznává, že vynálezy musí mít lidského vynálezce, a koncept vynálezu bez vynálezce je neslučitelný se stávajícími předpisy. Někteří odborníci však tvrdí, že americké právo vyžaduje pro poskytnutí ochrany práv duševního vlastnictví

menší zapojení člověka, což může mít vliv na konkurenceschopnost evropských společností. V důsledku toho je třeba, aby zákony umožňující ochranu vynálezů nebo děl vytvořených samostatně stroji byly v souladu s technologickým pokrokem a zajistily odpovídající ochranu duševního vlastnictví (Oleksiewicz, 2022, str. 61-64).

### **1.7.1 Evropská unie: KOORDINOVANÝ PLÁN V OBLASTI UMĚLÉ INTELIGENCE**

Evropská unie si vývoj umělé inteligence v jejím rámci představuje takto: Prvním krokem je nutné vybudovat základní podmínky pro rozvoj a implementaci umělé inteligence (UI) v Evropské unii (EU). To zahrnuje získávání, shromažďování a sdílení informací o politikách týkajících se UI, využívání potenciálu dat a posilování kritické výpočetní kapacity. Druhým krokem je udělat z EU centrum excelence od výzkumu až po trh. To lze dosáhnout spoluprací se zainteresovanými stranami, budováním a mobilizací výzkumných kapacit a poskytováním nástrojů prostřednictvím platformy UI pro testování a experimentování. Financování a podpora inovativních nápadů a řešení pro UI jsou nezbytné. Třetím krokem je zabezpečení toho, aby UI sloužila lidem a přispívala k dobré společnosti. Tím je míněno rozvoj talentů a nabídky dovedností, vypracování politického rámce k zajištění důvěry v UI a prosazování vize EU o udržitelné a spolehlivé UI. Je také důležité budovat strategické vedoucí postavení v odvětvích s velkým dopadem. To zahrnuje zapojení UI do problematiky klimatu a životního prostředí, využití nové generace UI ke zlepšování zdraví a udržení vedoucí pozice Evropy v oblasti robotiky. Čtvrtým posledním krokem je nutné zajistit, aby se veřejný sektor stal průkopníkem využívání UI, a prosadit použití UI v oblasti práva, migrace, azylu, inteligentní mobility a udržitelného zemědělství. Tyto kroky jsou podporovány harmonogramem klíčových opatření a analýzou vnitrostátních strategií a investic v oblasti UI (*Coordinated Plan on Artificial Intelligence 2021 Review*, 2021 str. 6-50).

### **1.7.2 Národní strategie umělé inteligence v České republice**

Plánováním rozvoje a implementací umělé inteligence na území ČR se zabývá vládní dokument Národní strategie umělé inteligence v České republice. Tento dokument obsahuje sedm oblastí rozvoje UI na území ČR.

#### **1. Podpora a koncentrace vědy výzkumu a vývoje**

Česká republika disponuje komparativní výhodou v oblasti umělé inteligence (UI) díky excelentnímu výzkumu a vývoji jak v primárním, tak i aplikovaném výzkumu. S tisíci vědeckými pracovníky v oborech UI a úzce souvisejících a produkcí více než sta odborníků ročně, české vysoké školy představují významný zdroj odborníků v oblasti UI, dokonce více

než některé světově uznávané metropole UI. Aby byl tento potenciál plně využit, je nezbytné nadále rozvíjet vědecko-výzkumnou kapacitu v akademické i podnikové sféře a posilovat spolupráci se soukromým sektorem.

Klíčovým faktorem pro dosažení tohoto cíle je lákání špičkových talentů a přenášení výsledků do praxe, což vyžaduje podporu nespécifického pokročilého výzkumu a inovací. Prioritou je vybudování Evropského centra excelence ve výzkumu UI, Evropského testovacího centra a Digitálních inovačních hubů, které by měly být součástí ekosystému pro transfer znalostí. K dosažení tohoto cíle je nutné vytvoření konsorcia akademických výzkumných pracovišť, zapojení do evropských sítí excelence a podpora spolupráce s vybranými nečlenskými státy EU.

Krátkodobé cíle do roku 2021 zahrnují vznik Evropského centra excelence v Praze, vznik Evropského testovacího centra pro pokročilou průmyslovou výrobu, plně fungující Digitální Inovační Huby a zapojení do evropských sítí excelence. Střednědobé cíle do roku 2027 zahrnují plnou integraci a spolupráci Evropského centra excelence s partnerskými výzkumnými pracovišti, propagaci ČR v zahraničí pro experty ve výzkumu, a vytvoření plně funkčního ekosystému kolem Evropského centra excelence. Dlouhodobé cíle do roku 2035 zahrnují integrovaný systém Evropského centra excelence, Evropského testovacího centra a DIH, a Českou republiku jako atraktivní zemi pro excelentní vědce a výzkumníky v oblasti UI.

Pro dosažení těchto cílů jsou klíčové nástroje, jako je úzká spolupráce vědecko-výzkumných pracovišť, revize právních a administrativních podmínek pro podporu migrace vědeckých pracovníků, finanční a nefinanční podpora získávání a udržení výzkumníků, a zapojení veřejné správy a municipalit do podpory v oblasti UI aktivit (*Národní strategie umělé inteligence v České republice*, 2019, str. 15-17).

## **2. Financování vědy a výzkumu, podpora investic a rozvoj UI ekosystému v ČR**

Ministerstvo průmyslu a obchodu společně se soukromým subjektem CzechInvest si klade za cíl nastavit příznivé podmínky pro investice a spolupráci se zahraničními subjekty s cílem rozvoje ekosystému umělé inteligence v České republice. Tento cíl zahrnuje podporu vědy, výzkumu a vývoje, které jsou klíčovými faktory pro plné využití potenciálu UI v zemi. S rychlým rozvojem této oblasti se stává stále důležitější poskytnout jak finanční, tak nefinanční podporu excelentnímu výzkumu jak v akademickém prostředí, tak v podnikovém sektoru. Zejména pro začínající podnikatele a start-upy je získání financování pro expanzi na globální úrovni klíčové, a proto je nutné zajistit efektivní alokaci kapitálu a podporu rozvoje

podniků s vysokou přidanou hodnotou, což má být základem budoucí prosperity, zaměstnanosti a hospodářského růstu v ČR.

K dosažení těchto cílů jsou definovány krátkodobé, střednědobé a dlouhodobé strategické kroky. Mezi krátkodobé cíle do roku 2021 patří například zmapování stávajících nástrojů a infrastruktury pro podporu UI, vytvoření Inovačního hubu umělé inteligence agentury CzechInvest, nebo posílení institucionálního financování institucí zabývajících se výzkumem. Střednědobé cíle do roku 2027 zahrnují přilákání významných investic do oblasti UI, vytvoření dlouhodobých programů podpory a zřízení fondu pro financování inkubátorů akademických institucí. Dlouhodobější cíle do roku 2035 pak směřují k vzniku nových českých podniků v oblasti UI s mezinárodním působením, podpoře inkubace start-upů a vybudování stabilních výzkumných center. Pro dosažení těchto cílů jsou definovány různé nástroje, jako například finanční podpora prostřednictvím programů EU, grantové programy, koordinace podpůrných programů a propagace českého UI prostředí doma i v zahraničí.

Spolupracujícími subjekty v této oblasti jsou Českomoravská záruční a rozvojová banka, Technologická agentura ČR, Grantová agentura ČR, Ministerstvo financí ČR, Ministerstvo dopravy ČR, Česká národní banka a Platforma pro AI SP ČR. Tyto subjekty společně působí na dosažení cílů stanovených pro rozvoj ekosystému umělé inteligence v České republice (*Národní strategie umělé inteligence v České republice*, 2019, str. 18-21).

### **3. UI v průmyslu, službách a veřejné správě, růst ekonomiky, mezd a celková konkurenceschopnost ČR**

V České republice, jakožto jedné z nejprůmyslovějších zemí s významným podílem automobilového průmyslu, je nástup umělé inteligence, automatizace a masivní robotizace vnímán jako faktor nejistoty pro firmy, obchodní modely a celou ekonomiku. Předpokládá se, že transformace v oblasti UI a digitalizace zásadně ovlivní strukturu podniků, organizaci výroby a vztahy v dodavatelsko-odběratelských řetězcích. Existuje riziko, že v případě neúspěchu v globálním závodě o technologickou dominanci by Česko, propojené s německým průmyslovým klastrem, mohlo ztratit až polovinu přidané hodnoty, zejména v autoprůmyslu. Proto je klíčové, aby ČR v nadcházejícím období posílila svou průmyslovou, ekonomickou a technologickou pozici, což bude mít zásadní vliv na další růst hospodářství a životní úroveň obyvatelstva. Umělá inteligence se jeví jako klíčový faktor, který může posunout zemi v hodnotovém řetězci výše a podpořit vznik nových silných národních hráčů, stejně jako úspěšný rozvoj stávajících firem. Je zásadní, aby se Česká republika zaměřila na využití

a přenos know-how ze špičkového výzkumu do firemní praxe, podporu automatizace v malých a středních podnicích a kvalifikované a rekvalifikované pracovní síly.

K dosažení těchto cílů jsou nezbytné státní zásahy, zejména v oblasti podmínek podnikání, budování infrastruktury a získávání co největší části hodnotového řetězce. Kromě toho je nutné zpracování analýz a strategií v oblasti technologického rozvoje UI, propagace a podpora využívání stávajících projektů ekonomické migrace, a zjednodušení podmínek pro investování a podnikání v oblasti UI. V dlouhodobém horizontu je cílem využít potenciál UI k posunu české ekonomiky směrem k vyšší přidané hodnotě, produktivitě a prosperitě, a zvýšit tak globální pozici ČR v oblasti konkurenceschopnosti a technologických kompetencí.

Pro dosažení těchto cílů je nezbytná spolupráce různých subjektů včetně ministerstev, průmyslových asociací, technologických agentur a dalších relevantních organizací. Je také důležité zajistit podporu pro výzkum a vývoj UI, poskytnout infrastrukturu pro sdílení dat a propagovat využívání UI ve veřejné správě a průmyslu s cílem zefektivnit činnost a zvýšit přidanou hodnotu ekonomiky (*Národní strategie umělé inteligence v České republice*, 2019, str. 22-25).

#### **4. Lidský kapitál a vzdělávací systém spolu s celoživotním vzděláváním**

Transformace vzdělávacího systému v České republice je nezbytná v reakci na rostoucí vliv umělé inteligence na ekonomiku a společnost. S cílem minimalizovat negativní dopady a plně využít příležitostí, které UI nabízí, je nutné upravit celý vzdělávací systém a zaměřit se na celoživotní vzdělávání a rekvalifikaci přímo u zaměstnavatelů. V následujících 5, 15 a 30 letech mohou technologie nahradit rutinní dovednosti až u 1,3 milionu, 2,2 milionu a téměř 3,4 milionu zaměstnanců v ČR, což vyžaduje zaměření na rozvoj dovedností, které nejsou nahraditelné automatizací, a na unikátní dovednosti s vysokou přidanou hodnotou. Klíčovým prvkem je rozvoj komplexních dovedností, multidisciplinarity a infromatického myšlení. Současný vzdělávací systém nedostatečně integruje digitální technologie do výuky, žáci nedosahují očekávaných výsledků v oblasti infromatického myšlení a matematická gramotnost není dostatečně podporována.

K dosažení těchto cílů je nutná úzká spolupráce veřejného a soukromého sektoru, včetně vzdělávacích institucí, zaměstnavatelů a nestátních organizací, a také mezinárodní spolupráce a přejímání osvědčených postupů.

Krátkodobé cíle do roku 2021 zahrnují zpracování metodické podpory pro ředitele škol, akreditaci nových PhD programů v oblasti UI a rozvoj digitálních kompetencí žáků. Střednědobé cíle do roku 2027 zahrnují zahájení transformace školství, začlenění výuky UI

na vysokých školách a podporu doktorských programů v oblasti UI. Dlouhodobé cíle do roku 2035 zahrnují dokončení transformace školství s plně funkční výukou UI a zajištění flexibilního systému aktualizace kurikula.

Pro dosažení těchto cílů jsou nezbytné nástroje jako studie návrhu transformace vzdělávání vzhledem k dopadům UI, průběžné vyhodnocování dopadů automatizace a UI na společnost a revize obsahu všeobecného vzdělávání.

Spolupracujícími subjekty jsou Ministerstvo průmyslu a obchodu, Ministerstvo práce a sociálních věcí, vzdělávací instituce a další relevantní organizace (*Národní strategie umělé inteligence v České republice*, 2019, str. 26-29).

### **5. Opatření k řešení dopadů UI na trh práce a sociální systém**

Vliv umělé inteligence na ekonomiku a trh práce je obecně spojován s automatizací a nahrazováním rutinních a opakujících se prací stroji, což by mělo uvolnit lidskou kapacitu pro kreativnější práci s vyšší přidanou hodnotou. Automatizace také představuje cestu k řešení nedostatku pracovní síly v důsledku nepříznivého demografického vývoje ve vyspělých zemích. Nicméně přechod na nový model práce vyžaduje transformaci na úrovni ekonomiky, sektorů i jednotlivců, což může být náročné a přinést negativní důsledky, jako je zvýšená nezaměstnanost, sociální vyloučení nebo nerovnost.

K dosažení střednědobých cílů do roku 2027 je klíčové mapování trendů na trhu práce, aktualizace povolání a kompetencí, podpora sebezaměstnání, a adaptace dávkových systémů pro nové obory a profese. Dlouhodobě je nutné připravit společnost na změny a dopady UI a automatizace, minimalizovat negativní dopady transformace ekonomiky a trhu práce, a podporovat nové pracovní příležitosti a mobilitu pracovníků.

K dosažení těchto cílů jsou nezbytné různé opatření, včetně pravidelného zpracovávání predikcí, zapojení zaměstnavatelů a zaměstnanců do procesu posuzování dopadů technologických trendů, podpora rozvoje pracovních příležitostí a mobility pracovníků, a změny v systému sociálního a důchodového zabezpečení.

Spolupracujícími subjekty v tomto procesu jsou Úřad práce ČR, Ministerstvo vnitra, Ministerstvo školství, Ministerstvo průmyslu a obchodu, Ministerstvo financí a další subjekty dle rozhodnutí gestora, hlavního koordinátora, nebo Výboru pro UI (*Národní strategie umělé inteligence v České republice*, 2019, str. 30-32).

## **6. Právní a společenské aspekty UI, etická pravidla, ochrana spotřebitele a bezpečnostní otázky**

Vývoj českého právního řádu v oblasti umělé inteligence je značně ovlivněn globálními trendy a aktivitami nadnárodních a mezinárodních organizací, kterých je Česká republika členem. Právo Evropské unie hraje klíčovou roli, zejména prostřednictvím stanovení strategických cílů v oblasti UI a tvorby etických zásad, jako jsou Etické pokyny pro vývoj a využívání umělé inteligence. Další mezinárodní organizace, jako je OECD, WTO, OSN a Rada Evropy, také ovlivňují tvorbu právního rámce prostřednictvím modelových zákonů a doporučení. V souladu s evropským přístupem "human centric AI" je nezbytné reagovat na vývoj technologií a nastavovat legislativu tak, aby podporovala výzkum a vývoj UI a zároveň chránila základní a další práva.

Krátkodobé cíle do roku 2021 zahrnují identifikaci legislativních překážek v oblasti UI, analýzu právních předpisů a implementaci evropských principů odpovědnosti za újmu, zřízení expertní Platformy pro monitorování právních a etických pravidel, veřejné konzultace k právním otázkám UI a analýze rizik souvisejících s ochranou osobních údajů.

Střednědobé cíle do roku 2027 zahrnují zavedení nástrojů vývoje UI v souladu s etickými a právními pravidly, vytvoření etických kodexů pro jednotlivé průmyslové sektory a analýzu rizik pro konkurenceschopnost firem. Zároveň je plánována analýza a odstranění legislativních překážek pro UI start-upy a nastavení rámce právního jednání pro ochranu osobnosti a soukromí. Dlouhodobé cíle do roku 2035 zahrnují vytvoření flexibilního právního systému pro adaptaci na technologický vývoj, zajištění standardů v oblastech bezpečnosti a ochrany osobních údajů a zavádění prvků UI v justici pro efektivnější fungování soudního systému. K tomu patří například nasazení přepisu mluveného slova do strojové podoby ve všech soudních agendách a využití umělé inteligence pro vypořádávání požadavků uživatelů a občanů.

Pro dosažení těchto cílů jsou navrženy nástroje jako expertní Platforma a fórum, průběžné vyhodnocování legislativních a právních rizik, podpora vývoje UI řešení v soukromém i veřejném sektoru a edukace v oblasti regulace a etiky UI. Spolupracujícími subjekty jsou Ministerstvo spravedlnosti, Legislativní rada vlády, Ministerstvo průmyslu a obchodu, Ministerstvo dopravy, Platforma pro UI, Hospodářský výbor PSP, Národní úřad pro kybernetickou a informační bezpečnost, Český telekomunikační úřad, Úřad pro civilní letectví a další subjekty podle rozhodnutí gestora (*Národní strategie umělé inteligence v České republice*, 2019, str. 33-36).



## 7. Mezinárodní spolupráce

Úřad vlády, společně s Ministerstvem zahraničních věcí, se zabývá významnými otázkami týkajícími se umělé inteligence na národní i mezinárodní úrovni. Diskuse o UI jsou součástí agendy Evropské unie a dalších mezinárodních organizací, jako je OECD, WTO a OSN. V rámci těchto organizací se zakládají platformy a observatoře pro monitorování relevantních politik a spolupráci různých zájmových skupin. Česká republika má možnost využít svou pozici při předsednictví ve Visegrádské skupině k prosazení tématu UI a posílení spolupráce v této oblasti.

Krátkodobé cíle do roku 2021 zahrnují identifikaci a využití potenciálu spolupráce s ne-EU státy, přípravu strategie komunikace prioritních oblastí UI ČR směrem k mezinárodním partnerům a prosazování tématu UI na summitu předsedů vlád států V4. Střednědobé cíle do roku 2027 zahrnují aktivní účast na tvorbě pracovních programů projektu Digitální Evropa, podporu a spolupráci se třetími zeměmi v oblasti inovací a vývoje UI, a nastavení priorit předsednictví v Radě EU, včetně prosazování UI v programu předsednického tria. Dlouhodobé cíle do roku 2035 zahrnují naplňování Inovační strategie 2030 a koncepce Digitální Česko, stanovení UI jako předmětu bilaterálních a multilaterálních strategických partnerství a etablování mezinárodního obrazu ČR jako inovativní země v oblasti UI.

Nástroje pro dosažení těchto cílů zahrnují začlenění tématu UI do priorit V4, rozvoj bilaterální spolupráce a budování koalic s podobně smýšlejícími zeměmi, a aktivní účast v mezinárodních organizacích a programech, jako je OECD a Digitální Evropa (*Národní strategie umělé inteligence v České republice*, 2019, str. 37-38).

### 1.7.3 Právní základ pro UI v Evropské unii

Umělá inteligence, ačkoli představuje významný technologický pokrok, nemá v současné době právní způsobilost a podle platných zákonů nemůže nést odpovědnost za škody způsobené její činností. Právní postavení umělé inteligence v Evropské unii je dlouhodobým problémem, přičemž její vývoj zasahuje do různých oblastí života. Rozvoj umělé inteligence však vyvolává četné sociální a morální obavy, jako je možnost vzniku závislosti na sociálně interaktivních robotech a zneužívání této závislosti ze strany korporací. Nick Bostrom naznačuje, že umělá inteligence se neustále vyvíjí nad rámec lidských schopností.

Evropský parlament vydal v únoru 2017 usnesení doporučující pravidla pro robotiku, jejichž cílem je řešit etické a bezpečnostní problémy, v souvislosti s umělou inteligencí. Jedním z návrhů bylo udělit robotům zvláštní právní status, tzv. status elektronické osoby, který by zakládal odpovědnost za škody způsobené umělou inteligencí. Evropská komise usnesení

schválila v dubnu 2018 a následně vydala strategii pro umělou inteligenci, jejímž cílem je posílit technologickou kapacitu, připravit se na socioekonomické změny a zajistit etický a právní rámec.

V prosinci 2018 přijala Komise Koordinovaný plán pro umělou inteligenci, který má tuto strategii provádět, a v únoru 2020 následovala Bílá kniha o umělé inteligenci. Umělá inteligence, jakožto všestranná technologie, má dopady na různá odvětví a je považována za hnací sílu inovací a technologického pokroku. Kromě toho kybernetické hrozby a vnímání nejistoty vedly ke zvýšení důrazu na kybernetickou bezpečnost v rámci EU, přičemž v dubnu 2019 byly přijaty předpisy, jako je zákon o kybernetické bezpečnosti. Tento zákon zavedl systém certifikace na úrovni EU a modernizoval agenturu EU pro kybernetickou bezpečnost ENISA.

Kromě toho EU zavedla právní předpisy o zřízení Evropského centra pro výzkum a kompetence v oblasti kybernetické bezpečnosti. EU rovněž podniká kroky k regulaci systémů umělé inteligence – v dubnu 2021 byl zveřejněn návrh nařízení, jehož cílem je vytvořit harmonizované právní normy pro systémy umělé inteligence v EU v souladu s lidskými právy a základními zásadami.

Pokud jde o práva duševního vlastnictví, současné zákony uznávají význam lidského podílu na vynálezech, přičemž pojem vynález bez vynálezce již není akceptován. Někteří odborníci však tvrdí, že USA vyžadují pro udělení práv duševního vlastnictví menší lidskou účast, což může mít vliv na konkurenceschopnost evropských společností. Proces řízení projektů výzkumu a vývoje nyní považuje práva duševního vlastnictví za cenný majetek, který může vyžadovat ochranu, zejména v souvislosti s počítačovými programy a vynálezy vytvořenými samostatně stroji.

Celkově je třeba, aby zákony umožňující ochranu vynálezů nebo děl vytvořených umělou inteligencí byly v souladu s technologickým pokrokem (Oleksiewicz, 2022, str. 61-64).

## **1.8 Tonzilofaryngitida**

Akutní faryngitida, známá také jako tonzilofaryngitida, je zánětlivé onemocnění, které postihuje sliznici hrdla a lymfatickou tkáň patrových mandlí. Toto onemocnění je běžné a správná diagnóza a léčba jsou velmi důležité.

Nejčastěji tonzilofaryngitidu způsobují viry, jako jsou rhinoviry (35 %), virus chřipky (30 %), RSV a paragripa virus. Mezi další patří koronaviry, adenoviry, EBV, Coxsackie a herpes simplex. Bakterie způsobují 15-30 % akutních faryngitid a tonzilitid u dětí a 5-10 % u dospělých. Nejběžnější bakterií je *Streptococcus pyogenes* (skupina A). Příležitostně se

mohou podílet také streptokoky skupiny G a C, *Neisseria gonorrhoeae*, *Mycoplasma pneumoniae*, *Chlamydia pneumoniae*, *Corynebacterium diphtheriae*, *Arcanobacterium hemolyticum* a anaerobní bakterie (Osiejewska et al., 2022, str. 874).

*S. pyogenes* se nejčastěji vyskytuje v zimě a na začátku jara. Nejčastěji se nakazí děti ve věku 5 až 15 let. Bakterie se přenášejí přímým kontaktem, a to i od osob, které jsou nositeli *S. pyogenes*. Streptokokové infekce skupiny A mohou mít epidemický charakter. Inkubace patogenu trvá od 12 hodin až do 4 dnů. Při domácím kontaktu je riziko infekce 25 %, téměř polovina bude mít symptomy a zbytek osob v kontaktu. (Osiejewska et al., 2022, str. 874-875)

Fyzikální vyšetření neposkytuje relevantní informace pro další postup. Změny na sliznici hltanu, jako je otok a zarudnutí, se zdají být podobné u bakteriální i virové etiologie. Hlavním cílem diagnostiky je posoudit pravděpodobnost bakteriální infekce a zavést odpovídající léčbu. Z tohoto důvodu byly vyvinuty tři škály: Centorova/McIsaacova škála a škály Walshova a Breeseova. Běžně se v lékařské praxi používá především první škála, jejíž skóre určuje další postup, neboť posuzuje pravděpodobnost bakteriální infekce (Osiejewska et al., 2022, str. 875).

Zejména u vysoce rizikových pacientů, se doporučuje provést rychlý stěrový test v místě ošetření. Moderní stěrové sady mají citlivost a specificitu srovnatelnou se standardním laboratorním testem. V případech, kdy příznaky přetrvávají i přes negativní test, mohou lékaři test zopakovat nebo použít konvenční kultivaci z krku se standardním laboratorním vyšetřením. Naznačuje-li počáteční skórování nekomplikovanou tonzilitidu a stav pacienta se zhoršuje, mělo by se po 3 dnech zvážit přehodnocení (Guntinas-lichius et al., 2023, str. 4).

Další možností je zahájit symptomatickou léčbu, například vhodnou dávkou rychle působícího paracetamolu přímo v místě ošetření. Pokud nedojde ke zlepšení do 15-30 minut, provede se rychlý stěrový test (Guntinas-lichius et al., 2023, str. 4).

## 2 Praktická část

Praktická část této práce se zaměřuje na využití metod strojového učení při diagnostice streptokokální tonzilofaryngitidy. Cílem této části je tedy vytvoření modelu využívajícího strojové učení pro určování přítomnosti tonzilárních exudátů v krku. Na základě výsledků modelu lze vyplnit pediatrický skórovací algoritmus McIsaac, s jehož pomocí lze určit míru rizika přítomnosti tonzilofaryngitidy.

### 2.1 Data

Pro praktickou část této práce bylo využito veřejně přístupných dat z platformy Kaggle.

Kaggle je platforma pro soutěže v datové vědě a strojovém učení a současně komunita nadšenců pro tyto obory. Byla založena v roce 2010 a v roce 2017 se stala součástí portfolia společnosti Google.

Nabízí prostředí pro spolupráci, kde mohou uživatelé vyhledávat a zveřejňovat datové sady, vytvářet modely pomocí webových nástrojů datové vědy a účastnit se soutěží v řešení reálných problémů.

Soutěže na portálu Kaggle se věnují vývoji modelů strojového učení pro konkrétní úlohy, jako je předpovídání odlivu zákazníků nebo identifikace objektů na obrázcích. Účast v těchto soutěžích umožňuje uživatelům uplatnit své dovednosti, naučit se nové techniky a případně vyhrát ceny.

Kromě soutěží poskytuje Kaggle také vzdělávací zdroje, výukové programy a datové sady pro výuku datové vědy a nových konceptů strojového učení. Uživatelé mohou využívat datové sady, analyzovat trendy a získávat poznatky pomocí nástrojů, jako jsou zápisníky Jupyter.

Kaggle také podporuje spolupráci mezi uživateli prostřednictvím funkcí, jako jsou jádra a diskusní fóra, kde mohou uživatelé sdílet programátorské postupy, analýzy, spolupracovat na projektech a klást otázky.

Pracovní nástěnka platformy umožňuje společně zveřejňovat nabídky práce v oblasti datové vědy a uživatelé mohou zvýšit svou viditelnost pro potenciální zaměstnavatele účastí v soutěžích a přispíváním do komunity (Shukla, 2024).

Jako vstupní data této práce byl použit veřejný datový set snímků z platformy Kaggle, ve kterém figurovaly dvě rozlišené složky, a to snímky zdravého faryngu a snímky faryngitidy. Složka snímků zdravého faryngu obsahovala 195 snímků a složka faryngitidy obsahovala 134 snímků. Vzhledem k výpočetnímu výkonu soustavy, na které byl model tvořen a nutnosti eliminovat z dat lokální extrém (v tomto případě velmi nevhodný úhel záběru a přesvícení snímku), bylo pro výuku modelu ze složky zdravého faryngu vybráno 23 snímků a ze složky

faryngitidy 20 snímků. Model byl následně testován sadou 8 snímků, která se skládala ze 4 snímků zdravého faryngu a 4 snímků faryngitidy.

## **2.2 Orange**

Pro zpracování modelu, byl vybrán software Orange. Orange je open-source software vyvíjen na University of Ljubljana na Faculty of Computer and Information Science ve Slovinsku, konkrétně v laboratoři bioinformatiky pod vedením výzkumné skupiny Biolab. Je distribuován pod licencí General Public License, což umožňuje jeho volné šíření a úpravy. Tento software je určený pro pedagogické účely a výzkum. Slouží jako vizuální programovací jazyk pro data mining a interaktivní analýzu. Uživatelé pracují v grafickém prostředí, kde jednotlivé kroky jsou reprezentovány uzly (widgety) postupu zpracování nazývané workflow. Orange nabízí širokou škálu návodů jak pro začátečníky, tak pro pokročilé uživatele. Instalace softwaru je zdarma dostupná na jejich webových stránkách a uživatelé mohou využívat také oficiální manuál a krátké návody na YouTube. Tyto zdroje jsou nejenom užitečné pro seznámení se s programem, ale také poskytují podrobné informace o jeho funkcích a možnostech (Dobešová, 2022, str. 8).

## **2.3 Model UI**

Cílem této části je navrhnout model, který by měl řešit rozpoznávání přítomnosti tonzilofaryngitidy na základě snímků faryngu. Model by tedy měl být schopen rozlišit mezi napadeným a zdravým faryngem. Výsledek vyhodnocení lze posléze dosadit do výše zmíněného algoritmu pro určování pravděpodobnosti výskytu tonzilofaryngitidy nazvaného McIsaac skóre.

## **2.4 Předzpracování dat**

Jako vstupní data byla použita sada snímků, ve které figurovaly dvě rozlišené složky, a to snímky zdravého faryngu a snímky tonzilofaryngitidy. Složka snímků zdravého faryngu obsahovala 195 snímků a složka tonzilofaryngitidy obsahovala 134 snímků. Pro omezené množství výpočetního výkonu zařízení, a nutnosti odstranit lokální extrémny (snímky zcela se vymykající většině z hlediska přesvícení snímku, nebo zcela nevhodného úhlu focení), na kterém byl model tvořen, bylo ze složky zdravého faryngu vybráno 23 snímků a ze složky faryngitidy 20 snímků. Model byl následně testován sadou 8 snímků, která se skládala ze 4 snímků zdravého faryngu a 4 snímků tonzilofaryngitidy.

## 2.5 Výběr klasifikačního modelu

Při výběru vhodného modelu strojového učení hraje roli několik faktorů jako například druh problému, který chceme řešit, formát kvalita a množství dat. Pro řešení toho problému jsem zvolil metodu strojového učení bez dohledu, a to konkrétně model CN2 Rule. Algoritmus CN2 je klasifikační metoda vytvořená pro efektivní generování jednoduchých a srozumitelných pravidel ve tvaru "jestliže podmínka, pak předpověz třídu", a to i v oblastech, které mohou obsahovat šum. Je tak vhodný pro analýzu snímků, které nejsou vždy foceny ze stejného úhlu a se stejným osvětlením.

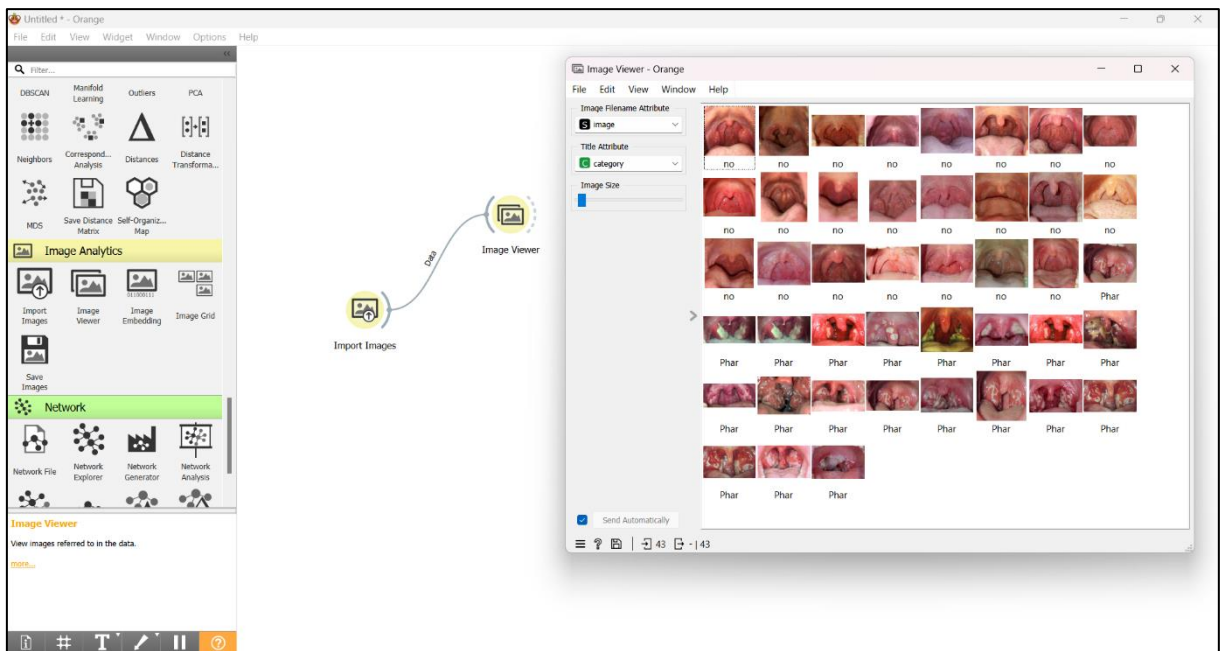
## 2.6 Návrh modelu v programu Orange

Na začátku tvorby v Orange se zobrazí prázdné plátno, toto plátno slouží pro vizualizaci programování, na plátno lze vkládat z nabídky umístěné na pravé straně plátna widgety, u kterých nadefinujeme potřebné parametry a posléze je navzájem propojujeme pro dosažení výsledku.



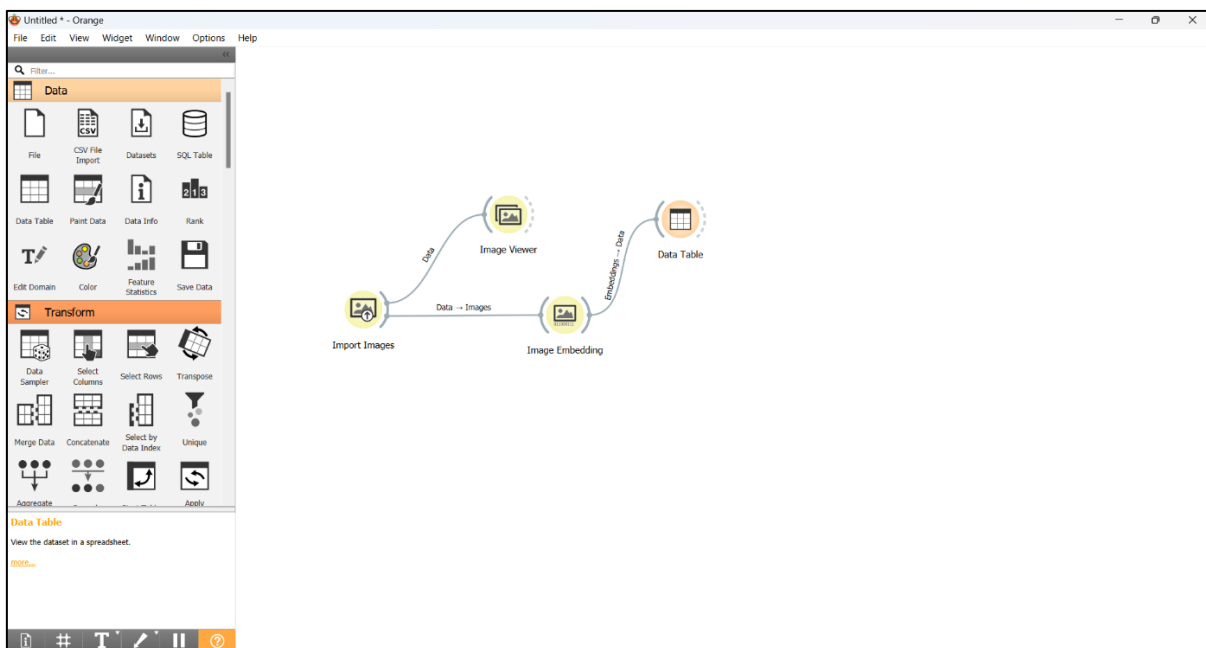
Obrázek 1, Prázdné plátno při započnutí práce v Orange., Zdroj: Vlastní zpracování

Na plátno byl nejprve umístěn widget „Import Images“. Skrz něj lze nahrát složku se snímky rozdělenými do podskupin „Phar“ pro snímky faryngitidy a „no“ pro snímky zdravého hltanu. V návaznosti na widget „Import Images“ byl na plátno přidán widget „Image Viewer“ pomocí kterého lze snímky zobrazit.



Obrázek 2, Vložení widgetu "Import images" a zobrazení snímků., Zdroj: Vlastní zpracování

Pro následující krok byl zvolen widget „Image Embedding“. Tento widget po propojení s widgetem „Import Images“ buď odešle obrázky na vzdálený server, kde jsou převedeny na vektorové hodnoty a odeslány zpět do zařízení, nebo tento proces proběhne přímo v programu Orange, tuto poslední možnost nabízí Embedder SuezNet. V této práci byl zvolen Embedder VGG-19. VGG-19 je hluboká ANN složená z 19 vrstev vytvořená Oxfordskou univerzitou, která byla trénována na více než 1000 0000 obrázků. Pro transparentnost byl k widgetu „Image Embedding“ připojen widget „Data Table“, který zobrazí data zpracovaná Embedderem v tabulce.



Obrázek 3, Vložení widgetu "Data table" pro zobrazení numerických dat., Zdroj: Vlastní zpracování

hidden origin	category	image name	image	size	width	height	n0 True	n1 True	n2 True	n3 True	n4 True	n5 True	n6 True	n7 True	T
18	no	no_pharyngitis...	no/no_pharyngi...	72786	750	629	0.616275	0	0.0812874	0	0.709363	0.384793	0	0	
2	no	no_pharyngitis...	no/no_pharyngi...	70955	750	750	0.647538	0	0.254615	0	0.845803	0.728045	0	0	
17	no	no_pharyngitis...	no/no_pharyngi...	68434	750	759	0.6480187	0	0.222802	0	0.625247	0.660148	0	0	
7	no	no_pharyngitis...	no/no_pharyngi...	36036	513	457	0.544616	0	0.314746	0	0.648882	0.636592	0	0	
4	no	no_pharyngitis...	no/no_pharyngi...	30867	554	328	0.532912	0	0.0898698	0	0.652478	0.848513	0	0	
12	no	no_pharyngitis...	no/no_pharyngi...	26636	396	404	0.446389	0	0.368861	0	1.07118	0.652699	0	0	
15	no	no_pharyngitis...	no/no_pharyngi...	26284	418	395	0.68381	0	0.32089	0	0.727659	0.511341	0	0	
19	no	no_pharyngitis...	no/no_pharyngi...	23971	480	353	0.733618	0	0.305326	0	0.869125	0.689793	0	0	
1	no	no_pharyngitis...	no/no_pharyngi...	23785	379	366	0.560891	0	0.134604	0	0.519844	0.640482	0	0	
5	no	no_pharyngitis...	no/no_pharyngi...	23436	381	337	0.414502	0	0.27691	0	0.633043	0.699092	0	0	
14	no	no_pharyngitis...	no/no_pharyngi...	22980	429	395	0.910294	0	0.227779	0	0.687448	0.536408	0	0	
16	no	no_pharyngitis...	no/no_pharyngi...	22388	349	296	0.566809	0	0.294347	0	0.797686	0.582022	0	0	
6	no	no_pharyngitis...	no/no_pharyngi...	22231	345	326	0.598486	0	0.243551	0	0.564784	0.57891	0	0	
10	no	no_pharyngitis...	no/no_pharyngi...	20700	317	330	0.490311	0	0.287142	0	0.633702	0.567618	0	0	
20	no	no_pharyngitis...	no/no_pharyngi...	20358	324	210	0.486189	0	0.165936	0	0.897583	0.688065	0	0	
23	no	no_pharyngitis...	no/no_pharyngi...	19325	263	288	0.444505	0	0.167678	0	0.598209	0.573022	0	0	
3	no	no_pharyngitis...	no/no_pharyngi...	18293	381	232	0.723042	0	0.233466	0	0.781484	0.755142	0	0	
8	no	no_pharyngitis...	no/no_pharyngi...	18209	407	245	0.69109	0	0.146321	0	0.729473	0.848547	0	0	
13	no	no_pharyngitis...	no/no_pharyngi...	18206	319	264	0.628937	0	0.351896	0	0.712124	0.605115	0	0	
9	no	no_pharyngitis...	no/no_pharyngi...	16905	269	200	0.545056	0	0.0239615	0	0.606608	0.796098	0	0	
21	no	no_pharyngitis...	no/no_pharyngi...	16468	278	205	0.606286	0	0.0191247	0	0.828533	0.51134	0	0	
11	no	no_pharyngitis...	no/no_pharyngi...	16066	290	364	0.564032	0	0.146009	0	0.929035	0.629321	0	0	
22	no	no_pharyngitis...	no/no_pharyngi...	14567	251	231	0.945822	0	0.212404	0	0.829708	0.525056	0	0	
39	Phar	pharyngitis_sma...	Phar/pharyngit...	47822	648	425	0.72911	0	0.275744	0	0.750423	0.34559	0	0	
24	Phar	pharyngitis_sma...	Phar/pharyngit...	43396	640	483	0.647672	0	0.0966396	0	0.673872	0.832526	0	0	
28	Phar	pharyngitis_sma...	Phar/pharyngit...	43369	692	460	0.662682	0	0.182568	0	0.636922	0.290594	0	0	
40	Phar	pharyngitis_sma...	Phar/pharyngit...	42366	479	298	0.543809	0	0.132674	0	0.816194	0.567461	0	0	
41	Phar	pharyngitis_sma...	Phar/pharyngit...	42366	479	298	0.543809	0	0.132674	0	0.816194	0.567461	0	0	
35	Phar	pharyngitis_sma...	Phar/pharyngit...	41939	702	417	0.593567	0	0.131394	0	0.822389	0.392975	0	0	
25	Phar	pharyngitis_sma...	Phar/pharyngit...	41130	606	325	0.527465	0	0.306464	0	1.03272	0.903486	0	0	
26	Phar	pharyngitis_sma...	Phar/pharyngit...	41130	606	325	0.527465	0	0.306464	0	1.03272	0.903486	0	0	
27	Phar	pharyngitis_sma...	Phar/pharyngit...	38418	582	362	0.607365	0	0	0	1.12585	0.563612	0	0	
31	Phar	pharyngitis_sma...	Phar/pharyngit...	37750	608	332	0.620957	0	0.0382273	0	1.14589	0.628437	0	0	

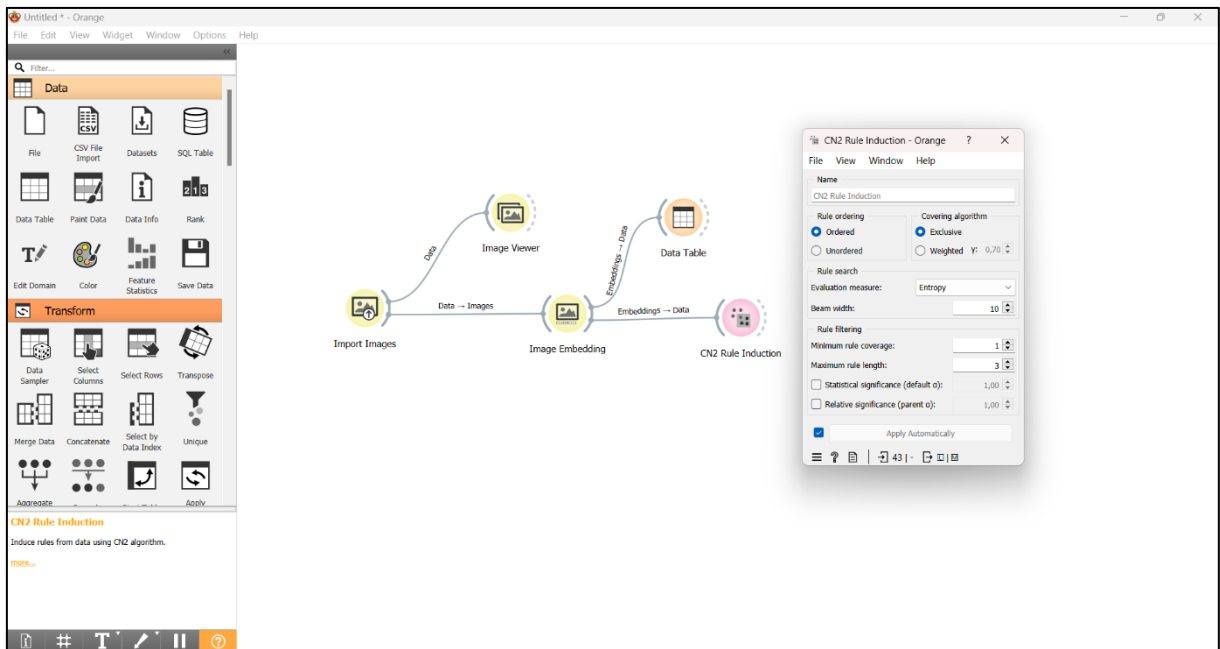
Obrázek 4, Tabulka s výstupními daty widgetu "Image Embedding"., Zdroj: Vlastní zpracování

Po převedení snímků do vektorových hodnot, přichází na řadu widget strojového učení „CN2 Rule Induction“. CN2 Rule je algoritmus strojového učení, popis jeho fungování, je uveden výše.

Widget „CN2 Rule Induction“ nabízí několik volitelných možností jeho fungování. Pro tuto práci bylo zvoleno výchozí nastavení, tedy v první části „Rule ordering“ byla zvolena možnost Ordred, která indukuje uspořádaná pravidla – seznam rozhodnutí (zjistí podmínky a vytvoří pravidla pro přiřazení do třídy). V části „Covering algorithm“ byla ponechána výchozí možnost „Exclusive“, jenž zajistí, že zjištěné pravidlo bude vyjmutu z dalších přezkoumávání. V další části „Rule search“ vybereme heuristiku pro vyhodnocení nalezené hypotézy. Jako výchozí je zvolena možnost „Entropy“ (míra nepředvídatelnosti obsahu), v této části lze volit i v možnosti „Beam width“, která si zapamatuje dosud nejlepší nalezené pravidlo a sleduje pevný počet jeho možných alternativ, zvolené číslo udává počet sledovaných alternativ. Následující část pojmenovaná „Rule filtering“ se věnuje filtrování vygenerovaných pravidel, v této části volíme v nejnižším množství vygenerovaných pravidel („Minimum rule coverage“), kde se opět vycházelo z výchozího nastavení a byl zvolen počet 1, a maximální délce pravidla, kdy nastavujeme maximální počet kombinací podmínek. Pro tento model bylo zvoleno 3. Poslední dvě volby „Default alpha“ (testování významnosti pro vyřazení většiny specializovaných pravidel s ohledem na počáteční rozdělení tříd) a „Parent alpha“ (testování

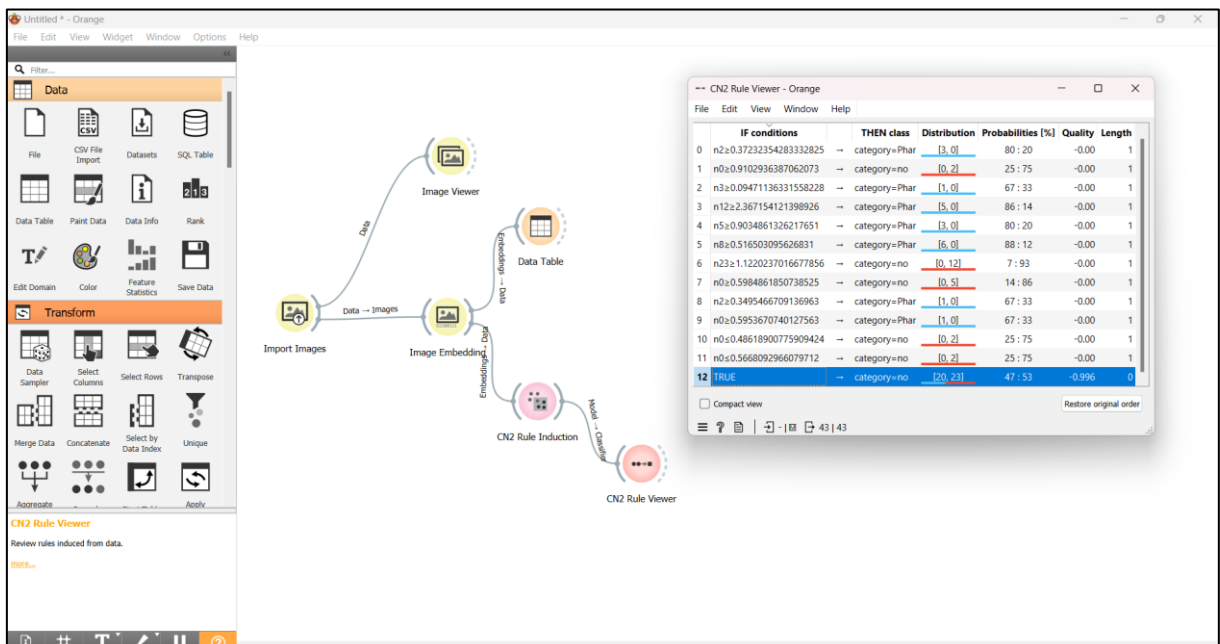


významnosti pro vyřazení nejspecializovanějších pravidel s ohledem na rozdělení nadřazené třídy).



Obrázek 5, Vložení a nastavení widgetu "CN2 Rule induction", Zdroj: Vlastní zpracování

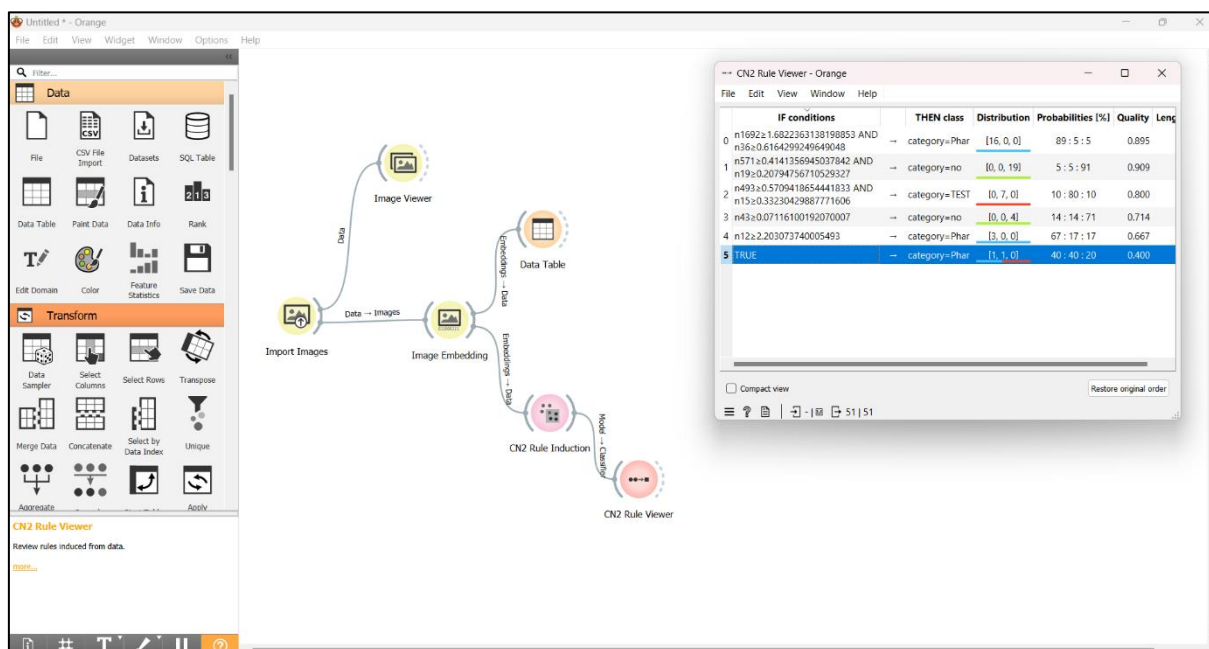
Pro zobrazení pravidel vygenerovaných algoritmem CN2 slouží widget „CN2 Rule Viewer“, ve kterém pro následující kroky označíme řádek „TRUE“, který je nadřazenou podmínkou ze všech indukovaných podmínek.



Obrázek 6, Vložení widgetu "CN2 Rule viewer" a tabulka zobrazující soubor rozhodovacích pravidel., Zdroj: Vlastní zpracování

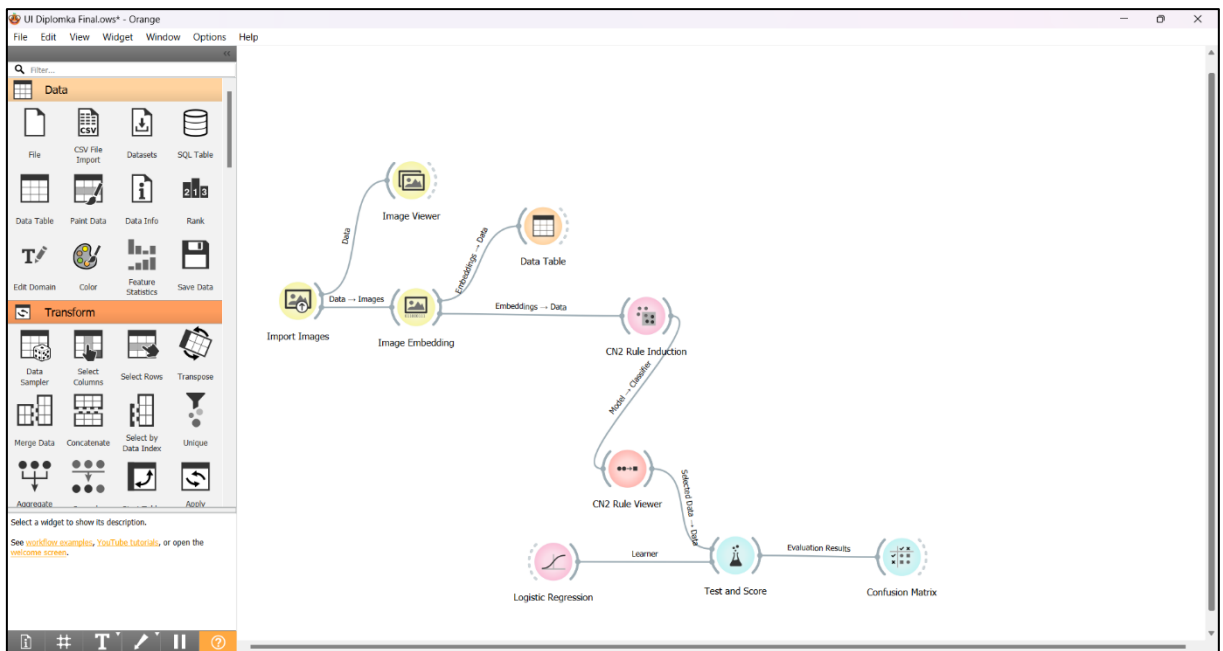
Nyní přejdeme ke schopnosti modelu vyhodnotit nové snímky v závislosti na tom, co se naučil na trénovacích. Do vstupní složky, která obsahuje podsložky „Phar“ a „no“ vložíme další

složku s testovacími snímky s názvem „TEST“, která obsahuje 8 testovacích snímků. Po vložení snímků se celý model znovu přepočítá a pracuje se třemi kategoriemi. Cílem této práce je, aby model přerozdělil testovací snímky správně, a to pouze do dvou kategorií „Phar“ a „no“, což jak lze sledovat ve widgetu „CN2 Rule viewer“ v řádku „TRUE“ také učinil.



Obrázek 7, Tabulka widgetu "CN2 Rule viewer" po vložení testovací sady snímků., Zdroj: Vlastní zpracování

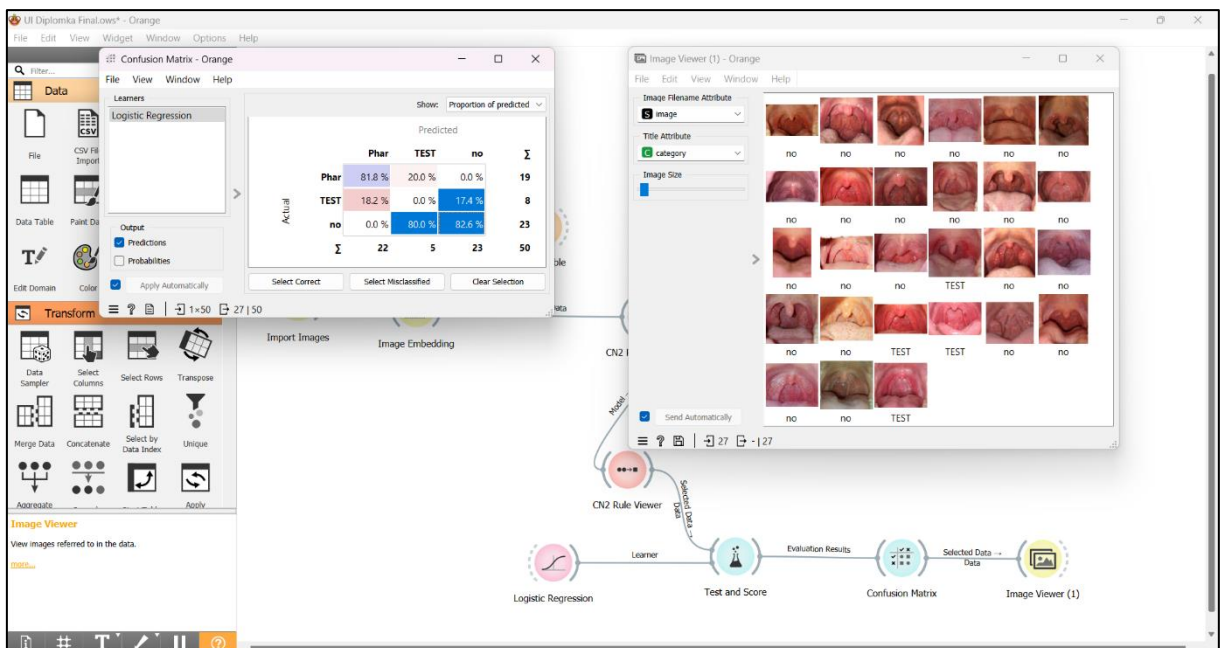
V následujícím kroku na plátno umístíme widget „Test and Score“, který testuje algoritmy učení. Tento widget provádí dvě věci. Jednak zobrazuje tabulku s různými mírami výkonu klasifikátoru, jako je například přesnost klasifikátoru a jednak vypisuje hodnocení, která mohou být použita dalšími widgety pro analýzu výkonnosti modelu. Takovým widgetem je „Confusion matrix“, který byl v této práci propojen právě s widgetem „Test and Score“. „Confusion matrix“ (Matice záměny) udává počet nebo procento správně určených předpovědí modelu ku skutečnému předem danému počtu. Výběr různých prvků lze převést na výstup a tímto způsobem pomocí widgetu „Image viewer“ zobrazit správně a špatně zařazené snímky. Pro to, aby tento testovací komplex fungoval je třeba k němu připojit ještě jeden velmi jednoduchý klasifikační nástroj, který se používá ke klasifikaci obrázků, tímto nástrojem je logaritmická regrese, tu obsahuje widget s názvem „Logistic regression“, její nastavení může být ponecháno jako výchozí.



Obrázek 8, Vložení widgetů "Test and Score", "Logistic Regeresion" a "Confusion Matrix", Zdroj: Vlastní zpracování

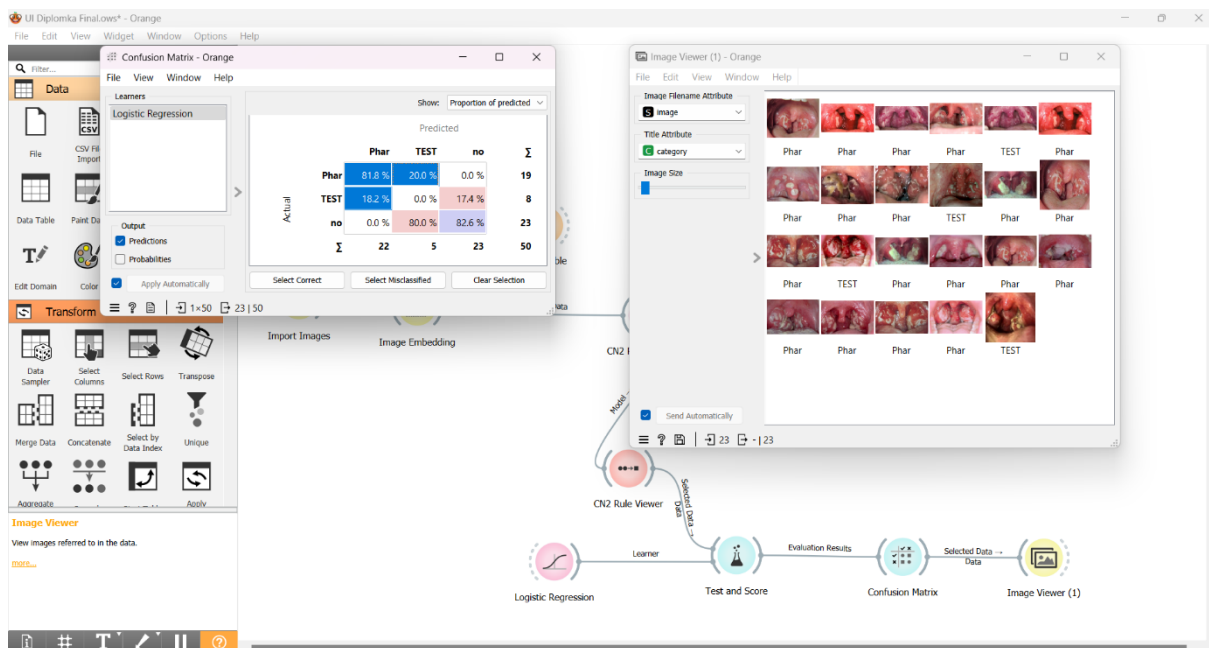
## 2.6.1 Vyhodnocení modelu

Widget „Confusion matrix“ nám umožňuje zobrazit jakým způsobem model snímky rozřídil a zároveň nabízí možnost porovnat správnost třídění vůči vstupním datům. Widgetem „Image viewer“ můžeme vybrané kategorie snímků zobrazit.



Obrázek 9, Vyhodnocení modelu ve widgetu "Confusion Matrix" a zobrazení správně určených snímků zdravého krku ve widgetu "Image Viewer"., Zdroj: Vlastní zpracování

Model správně přiřadil všechny 4 testovací snímky zdravého krku ke skupině „no“. A stejně správně zařadil 4 snímky tonzilofaryngitidy do skupiny „Phar“.



Obrázek 10, Vyhodnocení modelu ve widgetu "Confusion Matrix" a zobrazení správně určených snímků tonzilofaryngitidy ve widgetu "Image Viewer"., Zdroj: Vlastní zpracování

Toto vyhodnocení se může stát součástí algoritmu McIsaac pro určení závažnosti tonzilofaryngitidy a akutnosti lékařské intervence, je-li nutná.

## 2.7 McIsaac skóre

Pro lepší představu byla zpracována tabulka v programu Excel. Do této tabulky, která je zobrazena na obrázku č. byl převeden rozhodovací algoritmus McIsaac. Na obrázku č.11 je zobrazena tabulka s logickým výrokem v horní části, který zpracovává výpočet skóre.

Výpočetní vzorec pro sloupec body zní:

=KDYŽ(B2=1;1;0)+KDYŽ(C2=1;1;0)+KDYŽ(D2=1;1;0)+KDYŽ(E2=0;1;0)+KDYŽ(A(F2>=3; F2<=14); 1; KDYŽ(A(F2>15;F2<=44);0;-1)),

kdy pole A2 je číslo pacienta, pole B2 přítomnost tonzilárních exudátů, C2 zduření předních mízních uzlin, D2 přítomnost horečky nad 38 °C, E2 přítomnost kašle a F2 zastupuje věk. Sloupec skóre je naformátován takovým způsobem, aby se dle závažnosti zbarvil pole od zelené (-1-1 bod) přes žlutou (2 body), oranžovou (3 body) po červenou (4-5 bodů). Co jednotlivé body znamenají pro diagnostiku faryngitidy je objasněno v tabulce č.2.

*Tabulka 1, Tabulka skórovacího systému McIsaac., Zdroj: (Cohen & Shulman, 2024, str. 251)*

McIsaac Skóre	
Kritéria	Body
Horečka >38 °C	1
Absence kašle	1
Zduřené přední krční uzliny	1
Tonzilární otok nebo exudát	1
Věk 3-14 let	1
Věk 15-44 let	0
Věk 45 a více	-1

Číslo pacienta	Tonsilární exudáty	Zduření mizních uzlin	Horečka (nad 38°C)	Kašel	Věk	Body
1	1	1	0	1	0	20
2	2	0	1	0	1	30
3	3	1	1	1	0	10
4	4	0	0	0	1	48
5	5	1	0	0	0	12
6	6	0	1	0	1	5
7	7	1	1	1	1	45
8	8	0	0	0	0	8
9	9	1	1	0	1	55
10	10	1	0	0	0	15
11	11	1	0	1	1	12
12	12	1	1	1	0	16
13	13	1	1	1	1	57
14	14	0	1	0	1	83
15	15	0	1	0	0	26
16	16	1	0	1	0	14
17	17	1	1	0	0	66
18	18	1	0	0	1	74
19	19	1	1	0	1	84
20	20	0	1	1	1	41
21	21	0	1	0	0	19
22	22	1	0	0	1	1

Obrázek 11, Skórovací systém McIsaac převedený do elektronické podoby v programu Excel., Zdroj: Vlastní zpracování

Tabulka 2, Vyhodnocení skóre McIsaac., Zdroj: (Promyslova et al., 2013, str. 3)

Vyhodnocení McIsaac skóre		
Počet bodů	GABHS riziko infekce, v %	Taktika
0-1	5-10 %	Není třeba dalšího vyšetření a léčby.
2-3	28-35 %	Bakteriologický rozbor stěru, antimikrobiální léčba v případě pozitivního výsledku.
>4	51-53 %	Empirická léčba (v případě pyretické horečky, závažných celkových stavů a nedávného začátku) nebo mikrobiologická diagnostika.

### 3 Diskuse

Tato práce splnila vytyčené cíle. V její praktické části byl vytvořen fungující model strojového učení pod dohledem, který je schopen na základě snímků, které vlastní činností převádí do vektorových datových výstupů, které dále zpracovává, schopen správně rozřadit do kategorií snímků obsahujících tonzilofaryngitidu a snímků, které tonzilofaryngitidu neobsahují. Na základě tohoto rozřazení jsme schopni vyplnit skórovací systém McIsaac, který byl představen v závěru. Pomocí tohoto systému jsou lékaři schopni zhodnotit přibližnou pravděpodobnost výskytu akutní tonzilofaryngitidy u svých pacientů.

Práce nebyla tvořena s vidinou přímého využívání modelu v ordinacích, tvorba modelu má poukázat na jednoduchost a účinnost implementace prvků umělé inteligence v kterékoliv části zdravotnictví, kde se pracuje s daty. Tento konkrétní model společně s McIsaac skórovacím systémem převedeným do elektronické formy, tak jako uvádí práce např. v programu Excel, by mohl být vložen na internetové stránky nemocničních zařízení a poskytl by tak nástroj orientačního vyšetření například pro matky dětí, které by pojaly podezření, že jejich dítě trpí tonzilofaryngitidou. Pokud by po nahrání snímku krku dítěte do programu a vyplnění tabulky McIsaac v elektronické podobě systém vypočetl hodnotu skóre vyšší než 2, vznikla by jasná indikace k tomu, aby dítě navštívilo svého pediatra, který by provedl další vyšetření. V případě, že by skórovací systém McIsaac vyhodnotil skóre nižší než jedna, tato indikace by nevznikla. Pro matku dítěte by to znamenalo cennou informaci pro učinění rozhodnutí, zda dítě přivést do ordinace pediatra, kdy zejména v obdobích zvýšeného výskytu sezónních onemocnění, může být toto prostředí pro dítě značně rizikovým.

## 4 Limitace

Hlavní limitací strojového učení jsou data obecně, na efektivitu modelu má významný vliv především jejich kvalita, množství a množství extrémních hodnot v nich obsažených. Nejinak tomu bylo i při tvorbě této práce. Pro vytvoření dokonale fungujícího modelu by bylo třeba zpracovat tisíce snímků různých typů faryngitid, tak, aby byl vyhodnocovací systém co nejkompaktnější, s tím souvisí další limitace, která tkví v množství výpočetního výkonu. Pro zpracování tisíců snímků by bylo třeba využívat mnohem výkonnější výpočetní soustavu, než jaká byla použita v případě této práce. Pro tuto práci byl použit laptop Lenovo Ideapad 330-15 IKB s procesorem Intel(R) Core (TM) i5-8250U CPU @ 1.60GHz 1.80 GHz a nainstalovanou pamětí RAM 8 GB. Tato soustava pro tento typ práce dostačovala. Pokud by měl být tento systém využíván jako součást klinického rozhodování, bylo by nutné ho trénovat na větším množství dat a vytvořit další submodely pro zpracování výsledků klinických testů, v takovém případě by model mohl být plnohodnotným nástrojem pro pomoc v klinické praxi.



## 5 Závěr

Umělá inteligence je téma, které se zcela jistě propíše do životů každého z nás. Pravděpodobně bude přibývat čím dál komplexnějších systémů, které ve značné míře nahradí část našich činností. V honbě za AGI ale vyvstává velké množství etických a právních dilemat, jako například otázka odpovědnosti za její jednání a schopnost její jednání pochopit. Vlády všech zemí ještě dlouhá cesta pro to, aby mohla být UI skutečně plnohodnotnou součástí našich životů a nepředstavovala riziko.

Tato práce tedy usiluje o to ukázat strojové učení v jeho transparentní a pochopitelné podobě za pomoci velmi intuitivně zpracovaného softwaru Orange, který je svými možnostmi a jednoduchostí naprosto unikátní, na problematice zcela běžného onemocnění. Tato práce tak splnila všechny cíle, které si v úvodu kladla a vytvořila jednoduchý, funkční klasifikační model s potenciálem využití v nemocničním prostředí.

Podobné komplexnější modely, by mohly v rámci třídění, komunikace a administrativy usnadnit práci tisícům zdravotníků tak, aby mohli svědomitě a plnohodnotně plnit své důležité životní poslání, starat se o blaho všech nemocných a potřebných.

## 6 Referenční seznam

### 6.1 Teoretická část

Caluori, L. (2023). Hey Alexa, why are you called intelligent? An empirical investigation on definitions of AI. *AI*, 1-15. <https://doi.org/10.1007/s00146-023-01643-y>

High-Level Expert Group on Artificial Intelligence. (2019). *A definition of Artificial Intelligence: main capabilities and scientific disciplines* (1st ed.). European Commission. <https://digital-strategy.ec.europa.eu/en/library/definition-artificial-intelligence-main-capabilities-and-scientific-disciplines>

Grzybowski, A., Pawlikowska-Jagód, K., & Lambert, W. C. (2024). A History of Artificial Intelligence. *Clinics in Dermatology*. <https://doi.org/10.1016/j.clindermatol.2023.12.016>

Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. *Gastrointestinal Endoscopy*, 92(4), 807-812. <https://doi.org/10.1016/j.gie.2020.06.040>

Human- versus Artificial Intelligence. (2021). *Frontiers in Artificial Intelligence*, 4. <https://doi.org/10.3389/frai.2021.622364>

Sookhak, M., & Forestiero, A. (2022). A Survey of Artificial Intelligence Challenges: Analyzing the Definitions, Relationships, and Evolutions. *Applied Sciences*, 12(8), 4054-4054. <https://doi.org/10.3390/app12084054>

La Gatta, V., Moscato, V., Postiglione, M., & Sperli, G. (2024). An eXplainable Artificial Intelligence Methodology on Big Data Architecture. *Cognitive Computation*, 1-18. <https://doi.org/10.1007/s12559-024-10272-6>

Chehrehgani, M. H. (2024). The embeddings world and Artificial General Intelligence. *COGNITIVE SYSTEMS RESEARCH*, 84, 101201-101206. <https://doi.org/10.1016/j.cogsys.2023.101201>

Brundage, M. (2015). Taking superintelligence seriously: Superintelligence: Paths, dangers, strategies by Nick Bostrom (Oxford University Press, 2014). *Futures*, 72, 32-35. <https://doi.org/10.1016/j.futures.2015.07.009>

Triguero, I., Molina, D., Poyatos, J., Del Ser, J., & Herrera, F. (2024). General Purpose Artificial Intelligence Systems (GPAIS): Properties, definition, taxonomy, societal implications and

responsible governance. *Information Fusion*, 103.

<https://doi.org/10.1016/j.inffus.2023.102135>

Sun, K., Roy, A., & Tobin, J. M. (2024). Artificial intelligence and machine learning: Definition of terms and current concepts in critical care research. *Journal of Critical Care*, 82.

<https://doi.org/10.1016/j.jcrc.2024.154792>

Mahesh, B. (2020). Machine Learning Algorithms - A Review. *International Journal of Science and Research (IJSR)*, 2020(9), 381-386. <https://doi.org/10.21275/ART20203995>

Burkart, N., & Huber, M. F. (2021). A Survey on the Explainability of Supervised Machine Learning. *Journal of Artificial Intelligence Research*, 70, 245-317.

<https://doi.org/10.1613/jair.1.12228>

Lo Vercio, L., Amador, K., Bannister, J. J., Crites, S., Gutierrez, A., Macdonald, M. E., Moore, J., Mouches, P., Rajashekar, D., Schimert, S., Subbanna, N., Tuladhar, A., Wang, N., Wilms, M., Winder, A., & Forkert, N. D. (2020). Supervised machine learning tools: a tutorial for clinicians. *JOURNAL OF NEURAL ENGINEERING*, 17(6), 062001-62019.

<https://doi.org/10.1088/1741-2552/abbff2>

Sah, S. (2020). Machine Learning: A Review of Learning Types. *Preprints (www.preprints.org)*, 2020(1), 1-7. <https://doi.org/10.20944/preprints202007.0230.v1>

Heymann, F., Bessa, R., Liebensteiner, M., Parginos, K., Hinojar, J. C. M., & Duenas, P. (2022). Scarcity events analysis in adequacy studies using CN2 rule mining. *Energy and AI*, 8.

<https://doi.org/10.1016/j.egyai.2022.100154>

Chen, M., & Decary, M. (2020). Artificial intelligence in healthcare: An essential guide for health leaders. *Healthcare Management Forum*, 33(1), 10 - 18.

<https://doi.org/10.1177/0840470419873123>

Aggarwal, N., Ahmed, M., Basu, S., Curtin, J. J., Evans, B. J., Matheny, M. E., Nundy, S., Sendak, M. P., Shachar, C., Shah, R. U., & Thadaney-israni, S. (2020). Advancing Artificial Intelligence in Health Settings Outside the Hospital and Clinic. *NAM perspectives*, 2020.

<https://doi.org/10.31478/202011f>

Lee, D., & Yoon, S. N. (2021). Application of Artificial Intelligence-Based Technologies in the Healthcare Industry: Opportunities and Challenges. *International journal of environmental research and public health*, 18(1). <https://doi.org/10.3390/ijerph18010271>

- Seibert, K., Domhoff, D., Bruch, D., Schulte-althoff, M., Fürstenau, D., Biessmann, F., & Wolf-ostermann, K. (2021). Application Scenarios for Artificial Intelligence in Nursing Care: Rapid Review. *Journal of Medical Internet Research*, 23(11), e26522. <https://doi.org/10.2196/26522>
- Adelaja, O. A., & Alkattan, H. (2023). Operating Artificial Intelligence to Assist Physicians Diagnose Medical Images: A Narrative Review. *Mesopotamian Journal of Artificial Intelligence in Healthcare*, 2023(2023), 45-51. <https://doi.org/10.58496/MJAIH/2023/009>
- Ruksakulpiwat, S., Thorngthip, S., Niyomyart, A., Benjasirisan, C., Phianhasin, L., Aldossary, H., Ahmed, B. H., & Samai, T. (2024). A Systematic Review of the Application of Artificial Intelligence in Nursing Care: Where are We, and What's Next? *Journal of Multidisciplinary Healthcare*, *ume 17*, 1603-1616.
- Božić, V. (2023). Integrated Risk Management and Artificial Intelligence in Hospital. *Journal of AI*, 7(1), 63-80. <https://doi.org/10.61969/jai.1329224>
- Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). The role of artificial intelligence in healthcare: A structured literature review. *BMC Medical Informatics and Decision Making*, 21(1), 125. <https://doi.org/10.1186/s12911-021-01488-9>
- Vrontis, D., Christofi, M., Pereira, V., Tarba, S., Makrides, A., & Trichina, E. (2022). Artificial intelligence, robotics, advanced technologies and human resource management: a systematic review. *INTERNATIONAL JOURNAL OF HUMAN RESOURCE MANAGEMENT*, 33(6), 1237-1266. <https://doi.org/10.1080/09585192.2020.1871398>
- Chang, C.-Y., Jen, H.-J., & Su, W.-S. (2022). Trends in artificial intelligence in nursing: Impacts on nursing management. *Journal of Nursing Management*, 30(8), 3644–3653. <https://doi.org/10.1111/jonm.13770>
- Javed, H., Muqet, H. A., Javed, T., Rehman, A. U., & Sadiq, R. (2024). Ethical Frameworks for Machine Learning in Sensitive Healthcare Applications. *IEEE Access*, *Access, IEEE*, 12, 16233-16254. <https://doi.org/10.1109/ACCESS.2023.3340884>
- Trocin, C., Mikalef, P., Papamitsiou, Z., & Conboy, K. (2023). Responsible AI for Digital Health: a Synthesis and a Research Agenda. *Information Systems Frontiers: A Journal of Research and Innovation*, 25(6), 2139-2157. <https://doi.org/10.1007/s10796-021-10146-4>

Genus, A., & Stirling, A. (2018). Collingridge and the dilemma of control: Towards responsible and accountable innovation. *Research Policy*, 47(1), 61-69.

<https://doi.org/10.1016/j.respol.2017.09.012>

*Coordinated Plan on Artificial Intelligence 2021 Review*. (2021) (1st ed.). <https://digital-strategy.ec.europa.eu/en/library/coordinated-plan-artificial-intelligence-2021-review>

Oleksiewicz, I. (2022). Artificial intelligence versus human-a threat or a necessity of evolution? *Przełąd Europejski*, 2022(3), 55-69. <https://doi.org/10.31338/1641-2478pe.3.22.4>

Korteling, J. H., van de Boer-Visschedijk, G. C., Blankendaal, R. A., Boonekamp, R. C., & Eikelboom, A. R. (2021). Human-versus artificial intelligence. *Frontiers in artificial intelligence*, 4, 622364.

## 6.2 Zdroje praktická část

Zdena Dobešová. (2022). *ORANGE: Praktický návod do cvičení předmětu Data mining*.

Cohen, J. F., Tanz, R. R., & Shulman, S. T. (2024). Group A Streptococcus pharyngitis in Children: New Perspectives on Rapid Diagnostic Testing and Antimicrobial Stewardship. *JOURNAL OF THE PEDIATRIC INFECTIOUS DISEASES SOCIETY*.

<https://doi.org/10.1093/jpids/piae022>

Promyslova, E. & Selimzyanova, L. & Vishneva, E.. (2013). DIAGNOSTICS AND THERAPY OF ACUTE STREPTOCOCCAL TONSILLOPHARYNGITIS: MODERN RECOMMENDATIONS. *Pediatric pharmacology*. 10. 10. 10.15690/pf.v10i6.891.

Shukla, H. (2024). *What is Kaggle? Let's Dive into the World of Data Science*. Medium. Retrieved May 3, 2024, from <https://medium.com/yudiz-solutions/what-is-kaggle-lets-dive-into-the-world-of-data-science-82e26dbf1f93>

### Datový set pro tvorbu praktické části:

BEKZAT UTEULIN. (2023). *Pharyngitis images dataset*. Kaggle. Retrieved April 17, 2024, from <https://www.kaggle.com/datasets/bebeaa/pharyngitis-images-dataset/data>

## 7 Seznam obrázků a tabulek

### 7.1 Seznam obrázků

Obrázek 1, Prázdné plátno při započnutí práce v Orange., Zdroj: Vlastní zpracování .....	46
Obrázek 2 , Vložení widgetu "Import images" a zobrazení snímků., Zdroj: Vlastní zpracování .....	47
Obrázek 3, Vložení widgetu "Data table" pro zobrazení numerických dat., Zdroj: Vlastní zpracování.....	47
Obrázek 4, Tabulka s výstupními daty widgetu "Image Embedding"., Zdroj: Vlastní zpracování.....	48
Obrázek 5, Vložení a nastavení widgetu "CN2 Rule induction"., Zdroj: Vlastní zpracování..	49
Obrázek 6, Vložení widgetu "CN2 Rule viewer" a tabulka zobrazující soubor rozhodovacích pravidel., Zdroj: Vlastní zpracování .....	49
Obrázek 7, Tabulka widgetu "CN2 Rule viewer" po vložení testovací sady snímků., Zdroj: Vlastní zpracování .....	50
Obrázek 8, Vložení widgetů "Test and Score", "Logistic Regeresion" a "Confusion Matrix", Zdroj: Vlastní zpracování .....	51
Obrázek 9, Vyhodnocení modelu ve widgetu "Confusion Matrix" a zobrazení správně určených snímků zdravého krku ve widgetu "Image Viewer" .....	51
Obrázek 10, Vyhodnocení modelu ve widgetu "Confusion Matrix" a zobrazení správně určených snímků tonzilofaryngitidy ve widgetu "Image Viewer" .....	52
Obrázek 11, Skórovací systém McIsaac převedený do elektronické podoby v programu Excel., Zdroj: Vlastní zpracování .....	54

### 7.2 Seznam tabulek

Tabulka 1, Tabulka skórovacího systému McIsaac., Zdroj: (Cohen& Shulman, 2024, str. 251) .....	53
Tabulka 2, Vyhodnocení skóre McIsaac., Zdroj: (Promyslova et al., 2013, str. 3).....	54

## 8 Seznam zkratek

<b>AGI</b>	Umělá obecná inteligence
<b>AI SP ČR</b>	Asociace pro umělou inteligenci České republiky
<b>ANN</b>	Umělá neuronová síť
<b>ASI</b>	Umělá superinteligence
<b>CASNET</b>	Kauzálně – asociační síť
<b>COVID-19</b>	Koronavirová choroba 2019
<b>ČR</b>	Česká republika
<b>CT</b>	Počítačová tomografie
<b>EKG</b>	Elektrokardiogram
<b>EBV</b>	Virus Epstein-Barr
<b>EU</b>	Evropská unie
<b>GDPR</b>	Nařízení o ochraně osobních údajů (General Data Protection Regulation)
<b>GABHS:</b>	Beta-hemolytický Streptococcus pyogenes skupiny A
<b>HIPAA</b>	Zákon o přenositelnosti a odpovědnosti za zdravotní pojištění (Health Insurance Portability and Accountability Act)
<b>IT</b>	Informační technologie
<b>KVO</b>	Kardiovaskulární onemocnění
<b>ML</b>	Strojové učení
<b>MRI:</b>	Magnetická rezonance
<b>MYCIN:</b>	Ranný systém pro diagnostiku onemocnění krve
<b>OCT</b>	Optická koherenční tomografie
<b>OECD</b>	Organizace pro hospodářskou spolupráci a rozvoj
<b>OSN</b>	Organizace spojených národů
<b>PCA</b>	Hlavní komponentní analýza

<b>PET</b>	Pozitronová emisní tomografie
<b>RSV</b>	Respirační syncytiální virus
<b>SVM</b>	Vektorové podpůrné stroje
<b>SVR</b>	Vektorová regrese podpůrných strojů
<b>VGG-19</b>	Architektura konvoluční neuronové sítě
<b>WTO</b>	Světová obchodní organizace