



Metody pro odhad budoucího vývoje nových a inovativních technologií

Methods for estimating the future impact of emerging and innovative technologies

Studijní program:	Biomedicínská a klinická technika
Studijní obor:	Systemová integrace procesů ve zdravotnictví
Autor práce:	Bc. Kateřina Freislerová
Vedoucí práce:	Ing. Vojtěch Kamenský
Konzultant práce:	doc. Ing. Lenka Lhotská, CSc.

Kladno 2018

Katedra biomedicínské techniky

Akademický rok: 2017/2018

Z a d á n í d i p l o m o v é p r á c e

Student: **Bc. Kateřina Freislerová**
Studijní obor: Systémová integrace procesů ve zdravotnictví
Téma: **Metody pro odhad budoucího vývoje nových a inovativních technologií**
Téma anglicky: Methods for estimating the future impact of emerging and innovative technologies

Zásady pro vypracování:


Cílem diplomové práce bude odhad budoucího vývoje nových a inovativních v oblasti umělé inteligence ve zdravotnictví. Proveďte analýzu současného stavu zaměření metod pro odhad budoucího vývoje v ČR a ve světě. Dále proveďte analýzu metod využívaných pro odhad budoucího vývoje nových a inovativních technologií ve zdravotnictví a zhodnoťte jejich výhody, nevýhody a limity. Na základě analýzy současného stavu navrhnete vhodnou metodiku pro odhad budoucího vývoje a oslovte experty v oblasti umělé inteligence ve zdravotnictví. Výstupem práce bude ve spolupráci s experty aplikovaný navržený postup odhadu budoucího vývoje a doporučení pro další hodnocení.

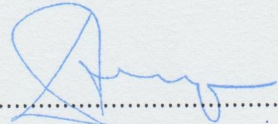
Seznam odborné literatury:

- [1] Brown, Smale, Verma, Momandwall, Medical technology horizon scanning, Australasian Physics & Engineering Sciences in Medicine, ročník 28, číslo 3, 2005
- [2] Clifford S. Goodman, Introduction to Health Technology Assessment, HTA 101, ed. 1.st, National Institute for Health, [Falls Church, Virginia, USA], 2004, [Revidováno 2011]
- [3] Brent, R.J., Cost-benefit Analysis and Health Care Evaluations, Edward Elgar Publishing. USA. , 2003, ISBN 1 84064 844 9

Vedoucí: **Ing. Vojtěch Kamenský**

Zadání platné do: 20.09.2019


.....
vedoucí katedry / pracoviště


.....
děkan

V Kladně dne 19.02.2018

PROHLÁŠENÍ

Prohlašuji, že jsem Diplomovou prací s názvem „Metody pro odhad budoucího vývoje nových a inovativních technologií“ vypracovala samostatně a použila k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k diplomové práci.

Nemám závažný důvod proti užití tohoto školního díla ve smyslu §60 Zákona č.121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon).

V Kladně 17. 5. 2018

.....

Bc. Kateřina Freislerová

PODĚKOVÁNÍ

Na tomto místě děkuji Ing. Vojtěchu Kamenskému za odborné vedení, věcné rady, ochotu a vstřícnost při zpracování této diplomové práce.

Díky patří také konzultantce práce doc. Ing. Lence Lhotské, CSc. za poskytnutí cenných odborných rad a pomoc uvést práci správným směrem.

Děkuji rodině a blízkým, kteří byli skálopevnou oporou ve všech okamžicích.

Vděčnost patří také pracovnímu kolektivu za nekonečnou trpělivost, bez které by tato práce vzniknout nemohla.

ABSTRAKT

Metody pro odhad vývoje nových a inovativních technologií

Diplomová práce se zabývá studiem metod pro odhad vývoje nových a inovativních technologií. Cílem práce je vytvoření metodiky pro odhadování vývoje umělé inteligence ve zdravotnictví a aplikace této metodiky. Je provedena analýza metod používaných pro odhad vývoje nových a inovativních technologií, jsou zjištěny jejich výhody, nevýhody a limitace. Dále je provedena analýza technologií umělé inteligence, na kterou navazuje obsáhlá rešeršní studie zabývající se využitím strojového učení a expertních systémů ve zdravotnictví. Získané informace jsou analyzovány a zasazeny do souvislostí s vývojem umělé inteligence ve zdravotnictví. Je vytvořena metodika pro odhad vývoje umělé inteligence a jiných inovativních technologií spojením technik Horizon scanning, Delphi metody a Trend impact analýzy.

Klíčová slova

odhad inovativních technologií, foresight, umělá inteligence, zdravotnictví

ABSTRACT

Methods for estimating the future impact of emerging and innovative technologies

This thesis focuses on forecasting development of innovative and disruptive technologies. The goal of our work is to create a methodology for creating a foresight of artificial intelligence in healthcare and using this methodology afterward. Firstly, we do an analysis of used methods for the foresight of disruptive technologies, assess their advantages, disadvantages, and limitations. Secondly, we analyze artificial intelligence technologies with following extensive literature review investigating machine learning and expert systems used in the healthcare industry. The gathered information is put into the context of artificial intelligence and related methods in healthcare. We present a new methodology for estimating the future impact of emerging and innovative technologies by a combination of the Horizon scanning, Delphi method and Trend Impact Analysis.

Keywords

estimating of innovative technologies, foresight, artificial intelligence, healthcare

OBSAH

SEZNAM ZKRATEK.....	8
ÚVOD.....	9
1 TEORETICKÉ ZÁKLADY PRÁCE	11
1.1 ODHAD BUDOUCÍHO VÝVOJE A POUŽÍVANÉ METODY	11
1.1.1 <i>Stav problematiky ve světě.....</i>	<i>12</i>
1.1.2 <i>Stav problematiky v České republice.....</i>	<i>14</i>
1.2 PŘÍKLADY POUŽITÍ METOD ODHADU BUDOUCÍHO VÝVOJE	15
1.3 UMĚLÁ INTELIGENCE.....	33
2 METODY.....	41
2.1 SYSTEMATICKÁ REŠERŠE	41
2.2 VYTVOŘENÍ EXPERTNÍ SKUPINY	43
2.3 DELPHI METODA.....	44
3 VÝSLEDKY.....	50
3.1 VÝSLEDKY REŠERŠNÍ ANALÝZY	50
3.1.1 <i>Nalezené články.....</i>	<i>52</i>
3.1.2 <i>Analýza četnosti slov.....</i>	<i>56</i>
3.1.3 <i>Analýza zdrojů nalezených článků.....</i>	<i>58</i>
3.1.4 <i>Tematické oblasti vyhledaných článků.....</i>	<i>61</i>
3.1.5 <i>Příklady studií pro strojové učení.....</i>	<i>64</i>
3.1.6 <i>Příklady studií pro expertní systémy.....</i>	<i>66</i>
3.2 NÁVRH METODIKY PRO FORESIGHT	69
4 DISKUZE.....	72
5 ZÁVĚR	77
SEZNAM OBRÁZKŮ	78
SEZNAM GRAFŮ	78
SEZNAM TABULEK.....	78
SEZNAM POUŽITÉ LITERATURY	80

Seznam zkratek

ALS	Amyotrofická laterální skleróza
ANZHSN	Australia and New Zealand Horizon Scanning Network
ASERNIP-S	Australian Safety and Efficacy Register of New Interventional Procedures-Surgical
CETAP	Canadian Emerging Technology Assessment Program
CT	Computed Tomography
Defra	Department for Environment, Food and Rural Affairs
DICOM	Digital Imaging and Communications in Medicine
ECG	Electrocardiography
EHR	Electronic health records
ES	Expert systém
FSIOS	Federal Social Insurance Office of Switzerland
HCI	Human Computer Interaction
HDRAS	Hazard Detection and Risk Assessment System
HSS	Horizon Scanning Systems
IQR	Interquartile range
IRD	Inherited Retinal Disease
KRNW	Knowledge resource nomination worksheet
ML	Machine learning
MPHO	Medical products of human origin
MRI	Magnetic Resonance Imaging
NHSC	The National Horizon Scanning Centre
PET	Positron Emission Tomography
PM	Personalized medicine
QFD	Quality function deployment
RPM	Remote Patient Monitoring
RS	Reverse salients
SorTek	Programa de Evaluación de Tecnologías Emergentes at the Servicio de Evaluación de Tecnologías Sanitarias
TIA	Trend Impact Analysis
UHC	University HealthSystem Consortium
UI	Umělá inteligence
V&S	Vigilance and surveillance
WHO	World Health Organization

Úvod

Současná doba je charakterizována pojmy jako *inovace, změna, vývoj* či *nejistota*. V takovém prostředí musí být nutně kladen důraz na provádění co možná nejlepších rozhodnutí. Jednou z možností, jak toho dosáhnout je aplikovat některé z mnoha existujících metod pro odhad budoucího vývoje a na jejich podkladě uskutečňovat plánování, přizpůsobovat politiku, směřovat výzkum a mnoho dalšího. Tento proces zároveň učí organizace jak být připravenější, flexibilnější a otevřenější. Formulace předpovědí a tvorba scénářů je také skvělým způsobem, jak stimulovat strategické myšlení a zlepšovat rozhodovací procesy. Samotná tendence předpovídat budoucnost není nová. Co se mění je naléhavost a nevyhnutelnost této činnosti, ve snaze udržet krok s překotným vývojem v mnoha oblastech technologického vývoje.

Zdravotnictví je nepochybně jedno z nejintenzivněji se rozvíjejících odvětví. Protože se jedná o oblast, do které se promítají nejen ekonomické zájmy výrobců a ostatních zainteresovaných stran, ale také zájmy sociální a společenské, je potřeba činit opodstatněná a včasná rozhodnutí o to naléhavější.

Tato práce se zabývá studiem vybraných metod pro odhad budoucího vývoje nových a inovativních technologií. Cílem práce je analyzovat používané metody, zhodnotit jejich výhody a nevýhody, vlastnosti a využití. Na základě tohoto teoretického podkladu je navržena vhodná metodika pro zmapování a odhad vývoje ve vybrané technologické oblasti.

Oblast umělé inteligence, která je nepochybně jedním z vůdčích technologických směrů dnešní doby i budoucích desetiletí, byla zvolena jako předmět pro navrzení postupu zmapování a odhadování vývoje. Jedná se o oblast multioborovou, spojenou s vysokou měrou odhadů a nejistot, která se ve zdravotnictví většinou vyskytuje v rámci vývoje. Cílem je aplikovat na tuto oblast vhodnou metodu nebo jejich kombinaci a za přispění expertního názoru dojít k zajímavým poznatkům o současném i budoucím vývoji umělé inteligence ve zdravotnictví. Výstupem práce bude navržený postup odhadu budoucího vývoje a jeho aplikace, z toho vycházející závěry a doporučení pro další hodnocení.

Potřebné kroky pro splnění cíle jsou následující:

- analýza vhodných metod nebo jejich kombinací,

- analýza technologií (oblastí),
- řešení studií k těmto vybraným technologiím,
- návrh metodiky pro odhad vývoje UI ve zdravotnictví,

Ačkoliv forecasting a s ním spojené procesy nepřinášejí tak konkrétní výsledky, jako jsme zvyklí u jiných analytických metod, mohou snahy o předvídaní budoucího vývoje a mapování nových technologií přispět teorii i praxi. Forecasting napomáhá identifikaci problémů, umožňuje jejich prioritizaci a poskytuje návrhy řešení. Tyto metody mohou produkovat relevantní teoretický průzkum.

1 Teoretické základy práce

Následující stránky jsou věnovány úvodu do problematiky odhadování budoucího vývoje technologií a inovací. Současně je zde zpracován potřebný teoretický úvod do oblasti umělé inteligence.

Existuje široké spektrum nejrůznějších metod a přístupů, díky nimž jsme schopni v různém rozsahu a s různou spolehlivostí nahlížet do možné budoucnosti. Jedná se nejen o zajímavý, ale v dnešní době pro mnohé organizace a skupiny nutný přístup, bez kterého by nebylo možné udržet tempo s prudce se měnícím a vyvíjejícím prostředím.

Teoretická část práce se věnuje aktivnímu přístupu k odhadování vývoje v rámci světa a České republiky. Přiblíženy jsou čtyři vybrané metody, které mají v dané problematice silné zastoupení.

Kromě základních teoretických poznatků jsou zde v souvislosti se zaměřením práce uvedeny příklady využití umělé inteligence v oboru zdravotnictví v České republice a ve světě.

1.1 Odhad budoucího vývoje a používané metody

S rapidně se rozšiřujícími možnostmi moderních technologií a současně narůstajícími zájmy a potřebami zájmových skupin, je pozornost směřována stále více do budoucnosti. Jen díky tomu je možno pružně reagovat na změny a činit dlouhodobě výhodná rozhodnutí.

Pokud máme hovořit o budoucím vývoji, je nutné uvést pojem „Foresight“. Tento termín byl dlouho chápán jako připravenost řešit dlouhodobé problémy. V 90. letech se začal vyskytovat pojem „Technology Foresight“, když se evropské i další země začaly konfrontovat s problematikou vývoje vědy, technologií a inovací. Nyní tento výraz chápeme jako soubor nejrůznějších programů, zabývajících se výzkumem, odhadováním a plánováním technologického vývoje [1].

Nejprve byl „Foresight“ nástrojem zejména vlád a vládních organizací. Postupně se systematické zkoumání možného vývoje začalo rozšiřovat i do ostatních sektorů, mimo jiné také do oblasti zdravotnictví. V této souvislosti začaly vznikat tzv. „Horizon Scanning Systems“ (HSS). Zde nechápeme Horizon scanning jako konkrétní metodu

(nebo skupinu metod), jak je pojednáváno níže. Obecně je cílem HSS sbírat informace a pomáhat kontrolovat a racionalizovat adaptování nových technologií [2].

1.1.1 Stav problematiky ve světě

Většina Horizon Scanning systémů je součástí celku The European Information Network on New and Changing Health Technologies – EuroScan, který reprezentuje agentury v Kanadě, Dánsku, Francii, Izraeli, Norsku, Španělsku, Švédsku, Švýcarsku, Nizozemsku, Rusku, Itálii, Německu, Austrálii, Novém Zélandu, Brazílii a Spojeném království.

V Anglii bylo v roce 1998 zřízeno The National Horizon Scanning Centre (NHSC), malá skupina specialistů financovaná Ministerstvem zdravotnictví. NHSC se zabývá rutinním skenováním dostupných zdrojů ve snaze identifikovat nové technologie. Provádí rovněž specializované programy a studie v této souvislosti [3].

Austrálie a Nový Zéland mají roku 2003 velmi zajímavou síť Australia and New Zealand Horizon Scanning Network (ANZHSN), která byla vytvořena pod záštitou několika ministerstev. Role této sítě je sledovat technologický vývoj v oblasti zdravotnictví a na základě něj poskytovat včasné doporučení [4].

Organizace se věnují nejrůznějším formám sledování vývoje technologií, pro příklad zde uvedu studii z roku 2003, ve které byly sledovány agentury využívající k metodě Horizon Scanning Internet [2]. Výsledkem studie byl seznam agentur, které využívají k systematickému hledání informací internet, rámec skenovaných studií, frekvence skenování a další související informace.

Seznam těchto organizací je uveden v tabulce č. 1 na následující straně. Tabulka 2 obsahuje informace o oblastech vyhledávání.

Tabulka 1. Organizace využívající v HSS Internet k identifikování nových zdravotnických technologií; Zdroj:[2]

HSS	Akronym	Země
Australian Safety and Efficacy Register of New Interventional Procedures-Surgical	ASERNIP-S	Austrálie
Canadian Emerging Technology Assessment Program at the Canadian Coordinating Office for Health Technology Assessment (CCOHTA)	CETAP	Kanada
Danish Centre for Evaluation and Health Technology Assessment	DACEHTA	Dánsko
Programa de Evaluación de Tecnologías Emergentes at the Servicio de Evaluación de Tecnologías Sanitarias (OSTEBA)	SorTek	Španělsko
Federal Social Insurance Office of Switzerland	FSIOS	Švýcarsko
National Horizon Scanning Centre	NHSC	Spojené království
University HealthSystem Consortium	UHC	USA

Tabulka 2. Oblasti vyhledávání v HSS využívajících Internet k identifikování nových zdravotnických technologií Zdroj:[2]

Oblast skenování	Agentury						
	CETAP	NHSC	DACEHTA	SorTek	FSIOS	ASERNIP-S	UHC
<i>Druh technologie</i>	Zdrav. přístroje, procesy, léky	Zdrav. přístroje, procesy, léky	Zdrav. přístroje, procesy, léky	Zdrav. přístroje a procesy	Zdrav. přístroje, procesy, léky	Zdrav. přístroje a procesy	Zdrav. přístroje, procesy, léky
<i>Specializace</i>	Vše	Vše	Onkologie	Vše	Vše	Chirurgie	Vše
<i>Různé stránky pro různé typy technologií</i>	Ne	Ne	Ne	Ano	-	Ne	Ano

„Foresight“ a různé dílčí činnosti v odhadování vývoje technologií jsou předmětem řady komerčních i nekomerčních agentur, organizací, vědeckých skupin atd. Plánování, tvorba scénářů, strategií a mnohé další činnosti jsou dnes již jejich běžnou součástí.

1.1.2 Stav problematiky v České republice

Česká republika nemá ustanovenu žádnou oficiální organizaci či skupinu, která by se věnovala odhalování nových technologií na poli zdravotnictví a jejich vývoji.

V roce 2012 vznikla v rámci „Realizace Regionální inovační strategie Královehradeckého kraje“ studie s názvem „Technologický foresight šesti progresivních odvětví Královehradeckého kraje v oblasti výzkumu, vývoje a inovací“. Tato studie mimo jiné obsahuje kapitolu „Biomedicína“, ve které je provedena analýza sektoru v ČR a kraji. Studie se zde zaměřuje na farmaceutický průmysl a komentuje výzkum a vývoj v tomto odvětví, zaměstnanost a související trendy [5].

V oblasti technologického vývoje a inovací se v České republice významně angažuje Technologické centrum Akademie věd České republiky. V rámci Oddělení strategických studií, které je předním národním výzkumným pracovištěm pro oblast řízení a politiky výzkumu připravuje výhledové studie, projekty a publikace, které se týkají vývoje nových technologií a slouží pro formulaci politik a strategií [6]. Tyto informace jsou přehledně zpracovávány v knihách, brožurách a článcích a jsou dostupným a cenným zdrojem znalostí pro podniky i veřejnou správu. Například publikace s názvem „Foresight – nástroj veřejné správy“ dostupná od ledna 2017 vysvětluje jak poznat nové trendy a události, které budou ovlivňovat budoucí vývoj, poskytuje rady a doporučení pro oblast veřejných služeb a vysvětluje jaké existují metody foresightu a k čemu je využít (konkrétně popisuje Horizon Scanning, Analýzu klíčových dopadů, Delphi metodu, Tvorbu scénářů a Tvorbu cestovních map) [6].

1.2 Příklady použití metod odhadu budoucího vývoje

Horizon scanning

Horizon scanning je pojem sdružující řadu metod a jejich kombinací za účelem důkladného prozkoumávání, shromažďování a vyhodnocování informací, s cílem informovat o možném vývoji v určité oblasti.

UK Department for Environment, Food and Rural Affairs (Defra) definuje horizon scanning jako [7]:

„Systematické zkoumání potenciálních hrozeb, příležitostí a pravděpodobného budoucího vývoje, které jsou na hranici současného myšlení a plánování.“

Horizon scanning umožňuje zkoumat nové a neočekávané otázky, stejně tak jako přetrvávající problémy a trendy.

Ať už tento proces probíhá kontinuálně nebo periodicky, a objektem zájmu je konkrétní technologie nebo širší okruh problematiky, vždy jde o objektivní hodnocení stavu a možných přínosů předvídatelného technologického vývoje, založené na současném výzkumu a důkazech [8]. Různé možnosti této metody a oblasti jejího využití jsou přiblíženy pomocí vybraných studií.

Horizon scanning for Remote Patient Monitoring (RPM) Technology [8]

V roce 2003 byl pod vedením Monash University Centre for Biomedical Engineering proveden na žádost australského Victorian Department of Health projekt, zabývající se vzdáleným monitorováním pacienta. Cílem projektu bylo posoudit technologie v této oblasti a identifikovat možnosti jejich aplikace v souvislosti s domácí péčí o pacienty trpící chronickou obstrukční plicní nemocí a selháním srdce.

Metodologie tohoto výzkumu velmi dobře ilustruje, z jakých jednotlivých součástí se horizon scanning může skládat a jakou na sebe tyto součásti mají návaznost.

Nejprve byla provedena systematická literární rešerše, pro kterou byla zvolena specifická kombinace vyhledávacích termínů a určeny literární zdroje, které budou použity. Výsledky vyhledávání byly později zdrojem zpracovávaných informací.

V dalším kroku studie byly zhodnoceny zájmy zainteresovaných stran (stakeholders), které rozšířily spektrum potřebných informací. Následoval workshop s vybranými

účastníky z řad lékařů, pacientů a dalších osob. Cílem této fáze bylo nasbírat informace o potřebách, zkušenostech a problémech v souvislosti s problematikou vzdáleného monitorování pacienta, a to ze strany uživatelů. Na to navázalo další kolo průzkumu s vybranými experty a stakeholders, kteří poskytli odborné rady a možné perspektivy.

V následující fázi byly vyhledávány již dostupné komerční technologie, a to nejen v rámci Austrálie, ale celosvětově. Pak následovala analýza dostupné literatury, která byla rozdělena do kategorií podle toho, v jaké fázi vývoje se technologie právě nachází (například fáze výzkumu, prototyp, klinická studie atd.). Účelem tohoto kroku bylo zmapovat v jakých fázích se technologie vzdáleného monitorování pacienta právě nacházejí a tudíž zhodnotit úroveň vývoje a dostupnosti.

V konečné fázi byla zformulována zpráva, která obsahovala celkové zhodnocení literatury a výsledků konzultačních procesů, formulovala možné modely zdravotní péče, zahrnující tyto technologie a poskytovala doporučení jejich nejlepšího praktického využití.

New and emerging technologies for the treatment of inherited retinal diseases: a horizon scanning review [7]

Tato studie slouží k identifikování nových a vyvíjejících se technologií, které mají potenciál zpomalit nebo zastavit progresi a/nebo zabránit ztrátě zraku u osob s dědičným onemocněním sítnice (IRD). Studie probíhala mezi listopadem 2013 a lednem 2014. Metoda zahrnovala kombinaci online vyhledávání podle předem definovaných vyhledávacích termínů, názory expertů a pacientů. Jelikož je pro nově vznikající technologie typický nedostatek veřejně dostupných informací, do studie byli zahrnuti i vývojáři a výrobci těchto technologií (přímo vědecké instituce či developeri). Tímto způsobem bylo identifikováno 29 potenciálních technologií. Z toho 9 bylo genových terapií, 10 zdravotnických přístrojů, 5 farmakologických činidel a 5 buněčných terapií. Dalších 11 technologií bylo identifikováno ve velmi brzkém stádiu vývoje a byly zahrnuty do finálního výběru, aby pomohly vytvořit komplexní obraz vývoje na obzoru.

Ke spolupráci byli vyzváni také odborníci, kteří ve výzkumu působili jako poradci. Byli požádáni, aby poskytli informace o nových technologiích ze zkoumané oblasti, které jsou jim známy a komentáře k těm nově nalezeným. Zaměřovali se na: míru inovace, potenciální dopad, přijatelnost, momentální dostupnost. Zorganizovány byly také dvě skupinové diskuze s pacienty a ostatními zájmovými skupinami.

Výsledkem byl seznam 29 technologií s potenciálem pozastavit či zpomalit vývoj onemocnění nebo zvrátit poškození zraku. Zjistilo se, že značná část technologií je vyvíjena komerčními společnostmi ve spolupráci s výzkumnými skupinami univerzit nebo vědeckých institucí. Většina relevantních technologií je nyní ve fázi klinických zkoušek. Mnohé z těchto metod jsou invazivní, zahrnující aplikaci subretinálních injekcí, implantátů apod.

Delphi metoda

Delphi metoda byla vyvinuta v 50. letech 20. století jako nástroj pro získání co nejspolehlivějšího konsenzu skupiny expertů. Technika spočívá ve shromáždění expertů z různých oblastí odbornosti, kteří se soustředí na společné téma, sdílejí názory až do okamžiku dosažení nejlepšího možného souhlasu, na základě jehož je vytvořen společný možný scénář.

Existuje několik variant této metody, ale základem je vždy anonymizovaná kontrolovaná debata, probíhající zpravidla v několika kolech, přičemž každé kolo je vyhodnoceno a jeho výsledky jsou poskytnuty expertům, kteří na jejich podkladě mohou v dalším kole modifikovat své odpovědi. Postup se opakuje do té doby, než je dosaženo požadované shody.

V souvislosti s odhadem a plánováním budoucích událostí jí Glenn [9] přisuzuje tři nejčastější způsoby využití:

- předvídání budoucího vývoje v daném časovém horizontu,
- předvídání toho, že nastane určitá událost a s tím spojená doporučení,
- hledání způsobů, jak docílit nebo naopak vyhnout se možné budoucí situaci,

Výstupy Delphi metody mohou mít různé formy a ačkoliv metoda většinou nepřináší zaručené jistoty, může na základě zkušeností, myšlenkových modelů a očekávání zapojených expertů navrhnout hodnověrné scénáře a přiřadit jim pravděpodobnosti [10].

Delphi method to explore future scenario possibilities on technology and Human Computer Interaction (HCI) [11]

Cílem této studie je porozumět možnostem budoucího technologického vývoje v oblasti interakce člověka s počítačem (HCI) v horizontu nadcházejících 5 – 10 let. Ústřední myšlenka je taková, že interakce, které uživatelé zažívají dnes, budují základy myšlenkového modelu a očekávaných inovací v budoucnosti. Studie je založená na Delphi metodě, které se zúčastnilo 10 odborníků z 5 různých měst (Los Angeles, Amsterdam, Sao Paulo, Lisbon, Rio de Janeiro). Všichni specialisté byli z oblastí spojených s moderními technologiemi a jejich interakcí s člověkem.

Průzkum byl prováděn pomocí e-mailů. Všechna data (ať už se jednalo o zadání nebo odpovědi expertů) byla vždy přeložena, aby byla dostupná jak v angličtině, tak portugalštině a předešlo se tak špatné interpretaci vlivem nedokonalého porozumění jazyku. Každému expertu byl přiřazen číselný kód, takže celý proces zůstal anonymní.

Postup práce by bylo možno rozdělit do čtyř fází:

- 1) V první fázi byl formulován dotazník, a to s důrazem na jasně a objektivně kladené otázky. Tento dotazník byl zodpovězen všemi experty a odevzdán.
- 2) Ve druhé fázi byly všechny odpovědi přeloženy do obou jazyků a uspořádány do jednoho dokumentu. V tomto okamžiku dostal každý expert k přečtení všechny odpovědi, s možností komentovat, přidat nové informace, souhlasit nebo nesouhlasit s jakoukoliv částí.
- 3) Ve třetí fázi se všechny odpovědi opět sloučí do jednoho dokumentu a celý proces se opakuje ve druhém kole expertní analýzy.
- 4) Ve čtvrté fázi jsou všechny odpovědi sesbírány a analyzovány. Finální dokument slouží k přípravě scénáře. V tomto případě byl scénář rozdělen na šest částí podle kategorií otázek pokládaných v dotazníku. Tento finální scénář byl opět zaslán všem expertům jako závěrečné kolo, které mohli komentovat.

Samotný proces Delphi metody trval v tomto případě 8 měsíců. Tomu ale předcházelo několik měsíců příprav, klasifikování a zvaní odborníků. Výsledky přinesly zajímavé odhady v budoucím vývoji na poli mobilních zařízení (kde například očekávali nárůst ovládání pomocí gest, hlasu a optické interakce), v souvislosti s dotykovými obrazovkami, projekcemi na běžné povrchy nebo brain-interface interakcemi.

The Future of imaging techniques for cancer patients in The Netherlands [12]

V roce 1997 byl v Holandsku ustanoven tzv. Výbor pro signalizaci rakoviny (Cancer Signaling Committee), jehož hlavním cílem bylo upozorňovat na vývoj související s bojem proti rakovině a poskytovat poradenskou činnost. Tento výbor vytvořil expertní skupinu z oblastí zobrazovacích technik, a to za účelem sběru, systematizace a hodnocení dostupných znalostí z této oblasti a vytvoření uceleného přehledu o jejich vývoji.

Studie probíhala mezi dubnem 2002 a 2003 a podílelo se na ní 35 expertů. Jejich výběr byl založen na následujících předpokladech:

- a) experti se řadí do skupiny specialistů, kteří buď vyžadují výsledky zobrazovacích technik (chirurgové, gynekologové, praktičtí lékaři atd.) anebo s technikami přímo pracují (např. radiologové),
- b) mají hluboké znalosti ve svém oboru a/nebo v onkologii,
- c) vyvážené geografické rozložení v rámci Nizozemska.

Osloveni byli rovněž zástupci průmyslu a managementu. Výsledná různorodá skupina byla složená z radiologů, chirurgů, radiologických asistentů, vysokých manažerů, onkologů, patologů, praktických lékařů atd.

Studie probíhala dvoukolově. První kolo sestávalo z částečně strukturovaných rozhovorů se všemi 35 panelisty. Témata rozhovorů spadala do třinácti zkoumaných oblastí:

- 1) informace o aplikaci zobrazovacích technik pro vybrané skupiny nádorů – dnes a v roce 2015,
- 2) příčiny a možná řešení kapacitních problémů v kontextu radiologie a nukleární medicíny dnes a v budoucnosti,
- 3) aplikace evidence-based medicine dnes a v budoucnosti,
- 4) užívání zobrazovacích technik do roku 2015 v kontextu respondentovy odbornosti,
- 5) očekávání s ohledem na útlum některých technik v následujících 10 letech,
- 6) technologický vývoj probíhající mimo oblast zobrazovacích metod, který by na ně mohl mít vliv,

- 7) nahrazení technik využívajících ionizující záření,
- 8) očekávání v souvislosti s komerčním dodáváním zobrazovacích přístrojů v horizontu 10 let,
- 9) očekávání budoucích substitučních technik na poli zobrazování,
- 10) vývoj v oblasti mini-invazivní medicíny,
- 11) očekávání pacientů a lékařů první linie v oblasti radiologie a nukleární medicíny,
- 12) očekávání na poli digitalizace,
- 13) málo pravděpodobné události velkého významu, které by mohly ovlivnit vývoj na poli zobrazovacích technik.

Průměrná délka nahraného rozhovoru byla 1–1,5 h. Kompletní přepisy těchto rozhovorů byly vytříděny na základě relevance a rozděleny do skupin. Tyto informace pak sloužily k vytvoření dotazníku pro druhé kolo studie.

Dotazník byl rozdělen na stejných třináct oblastí obsahujících podotázky, hodnotitelné na pětibodové škále. Tento dotazník byl vyplněn a odevzdán 33 experty. Následně byla provedena analýza. Za směrodatné byly považovány výsledky, kdy konsenzus dosáhl 75 % a více. Výsledkem výzkumu byl například odhad, že v následujících 10 letech užívání zobrazovacích technologií k diagnostice rakoviny poroste. Experti předvíдали pokles v užívání ultrazvuku, CT a konvenčních metod založených na kontrastních materiálech. Naopak očekávali vzestup MRI a PET. V oblasti vývoje ze studie vyplynulo, že nejvýznamnější roli bude hrát vývoj „tumor-specific tracers“ pro PET a mini-invazivní chirurgie prováděná pod vedením zobrazovacích technik. Druhé kolo této studie také ukázalo, že odborníci neočekávají drastické změny na poli radiologie a nukleární medicíny. Odhaduje se také, že využití CT, MRI i PET se přesune k diagnostice ranějších stádií onemocnění. V nadcházejících 10 letech experti nepředpokládali vyvinutí radikálně odlišných technologií.

Scenario method

Scénáře jsou užitečným a všestranným nástrojem, používaným v mnoha oborech. Obecně lze říci, že účelem scénářů je připravit se na možné situace, které mohou s určitou pravděpodobností v budoucnosti nastat. Herman Kahn, jeden z průkopníků metody tvorby scénářů je definuje jako „soubor hypotetických událostí v budoucnosti, jejichž cílem je objasnit možný řetězec příčinných událostí a určit rozhodovací body.“ [7]

Existuje mnoho různých definic scénářů i účelů jejich využití, obecně však platí, že se jedná o ucelené pohledy na možné vývoje v budoucnu, díky nimž jsme schopni lépe reagovat na probíhající vývoj a případně jej ovlivnit.

Metod pro tvorbu scénářů je mnoho, je možné je navzájem kombinovat, modifikovat a přizpůsobovat na základě řešeného problému. Bez ohledu na zvolenou metodu však obvykle tvorba scénáře probíhá ve čtyřech fázích:

- definování rámce
- tvorba databáze (porozumění a analýza historických trendů)
- tvorba scénářů
- volba strategických možností

Ze své podstaty je tvorba scénáře vysoce kreativní proces, vyžadující značnou znalost problematiky a analýzu klíčových faktorů, které mohou budoucí scénáře ovlivňovat, aby mohl být vytvořen hodnověrný obraz budoucích událostí.

Combining the scenario technique with bibliometrics for technology foresight: The case of personalized medicine [13]

Účelem této studie bylo prezentovat nový přístup kombinace bibliometrie a tvorby scénářů pro účely odhadu technologického vývoje. Metoda je ilustrována výzkumem na poli personalizované medicíny (PM).

V první fázi studie byla v osmi krocích realizována metoda tvorby scénářů:

1) Definování objektu analýzy

V tomto kroku se autoři soustředí na důkladné porozumění objektu analýzy a určení jeho hranic. Tento krok považují za stěžejní z toho důvodu, že bude tvořit jakýsi základ či rámec celé studie.

2) Identifikování klíčových hnacích sil a deskriptorů

Ve druhém kroku tým identifikuje důležité síly, které zahrnují názory všech stakeholderů. V tomto kroku je vhodné aplikovat vhodnou kvalitativní metodu, která tyto faktory odhalí.

3) Odvození projekcí a rozhodnutí o tom, kolik scénářů bude vytvořeno

V tomto bodě tým utvoří projekce pro možné budoucí scénáře na základě zjištěných informací. Množství projekcí se zpravidla řídí tím, kolik finálních scénářů by mělo být vytvořeno. Nejčasněji užívaný je třiscénářový model, kdy dva scénáře jsou extrémní a jeden kopíruje trend.

4) Sdružení projekcí do konzistentních skupin jednotlivých alternativ

V tomto kroku tvůrci seskupí jednotlivé projekce do skupin a vytvoří první hrubé verze scénářů.

5) Popis scénářů

Toto je nejkreativnější část celého procesu. Tvůrci dotvoří scénáře tak, aby vyobrazovaly možnou budoucnost. Scénáře by měly být konzistentní, věrohodné, měly by být schopny propojit existující historická data s hypotetickou budoucností.

6) Identifikace rušivých událostí a jejich efektů na scénáře

Rušivé události jsou možné budoucí stavy s nízkou pravděpodobností, že nastanou, ale velkým vlivem. Jsou to unikátní hrozby, které by měl vzít scénář v úvahu.

7) Identifikace nových technologií pro každý scénář

V této chvíli jsou analyzovány dostupné technologie a zakomponovány k výsledku předchozích kroků.

8) Zkoumání důsledků pro technologickou strategii a odvození plánů pro akci.

V každém z těchto určených kroků tvůrci scénářů ukázali, jak je možné zakomponovat bibliometrii a těžit z jejího kvantitativního charakteru. Výstupy bibliometrické analýzy byly integrovány do jednotlivých kroků tvorby scénáře. Výsledkem bylo vytvoření tří možných scénářů – Regulatory Issue Scenario, Technology Scenario a Business Model Scenario.

Scenario planning for the electricity generation in Indonesia [14]

Cílem studie je pomocí metody tvorby scénářů vypracovat dlouhodobý plán dodávek elektřiny pro systém Jáva – Madura – Bali. Studie konfrontuje konvenční metodu plánování, užívanou původně v tomto sektoru, právě s metodou tvorby scénářů. Autoři se opírají o tvrzení, že tvorba scénářů má mnohem větší návaznost mezi současnou situací a budoucností. Bere v úvahu nejen historii a současné trendy, ale zahrnuje i možnosti, které by mohly v různé formě ovlivnit budoucí vývoj, v tomto případě například nové technologie nebo zpřísnění regulací pro ochranu životního prostředí. Důležitá je zde také skutečnost, že jelikož je tvorba scénářů ze své podstaty založena na mnoha možných budoucnostech, je potřeba zahrnout všechny tyto možnosti jako rovnocenné. Navrhovatelé proto vytvořili několik možností a poté rozhodli, která z nich poskytuje výsledek s nejmenším možným nesouladem. Cílem pak bylo vybrat takový plán, který podává nejsilnější výsledky bez ohledu na události, které nastanou v budoucnosti.

Ve studii se postupovalo ve třech krocích. Prvním krokem bylo psaní scénářů, proces, během něhož jsou identifikovány možné budoucí události, které by mohly mít efekt na poptávku po elektrické energii. Úspěch každého scénáře byl velmi závislý na tom, jak dobře byly popsány všechny externí faktory. Následovala analýza scénářů, proces, ve kterém se zkoumaly důsledky kombinací různých faktorů (v tomto případě možnosti dodávek a tvorby elektřiny). Ve třetí fázi probíhal rozhodovací proces (decision-making), ve kterém tvůrci identifikovali nesoulady, které obsahoval každý z možných scénářů, a vybrali nejspolehlivější z nich. V tomto okamžiku byl proces tvorby scénářů ukončen.

Trend impact analysis

Trend impact analýza (TIA) byla vyvinuta v 70. letech 20. století jako reakce na potřebu řešení stále obtížnějších důležitých otázek na poli budoucího výzkumu [15].

TIA spojuje kvantitativní a kvalitativní přístup k odhadování budoucích událostí. Tento přístup dovoluje využít silné stránky a překonat nedostatky metod, které využívají pouze jeden z těchto přístupů. Kvantitativní metody založené na historických datech (například regresní analýza) nedokáží pracovat s neočekávanými událostmi a vytvářejí poměrně nepřizpůsobivý a statický obraz budoucích událostí. Naproti tomu čistě kvalitativní metody (metoda Delphi) jsou často velmi subjektivní a nepřesné. TIA se umí vyrovnat se změnami v trendech a dovoluje uživateli specifikovat faktory, které mohou

nastat a ovlivnit budoucí trend a zvolit pravděpodobnosti s jakými tyto faktory nastanou [14].

Při použití TIA jsou zásadní tři kroky [15]:

- vytvoření základního („surprise-free“) scénáře, založeného na historických datech bez ohledu na nečekané budoucí vlivy
- identifikace důležitých faktorů, které my mohly mít na vývoj vliv, pomocí některé z kvalitativních metod (nejčastěji skupinou expertů v Delphi studii)
- generování všech možných scénářů samotným TIA algoritmem a pomocí metody Monte Carlo (případně jiné)

V následujících studiích je proces probrán podrobněji.

A systematic way of identifying and forecasting technological reverse salients using QFD, bibliometrics, and Trend Impact Analysis: A carbon nanotube biosensor case [16]

Studie se zabývá vytvořením metodiky pro identifikaci tzv. „*reverse salients*“ (RS) v oblasti výzkumu a vývoje. Obecně se jedná o takové součásti systému, které jsou tak nedokonalé, že brání celému systému dosáhnout kýženého výsledku či pokroku. Podle autorů studie je nyní odhalování a předvídaní výskytu těchto překážek o to složitější, neboť narůstá technologická komplexita a zkracují se životní cykly technologií. Pro toto dynamické prostředí proto navrhuje novou systematickou metodu, kde kombinují QFD (quality function deployment), bibliometrii a trend impact analýzu. Předmětem této studie jsou Carbon Nanotube biosenzory.

V první fázi studie byla vytvořena literární rešerše za účelem zjištění informací. Na podkladě těchto dat byla skupinou expertů provedena metoda QFD kterou identifikovali klíčové RS. Ve druhé fázi se pomocí bibliometrie sbírala relevantní data o patentech a studiích.

Ve třetí fázi byla použita TIA k předpovídání řady budoucích klíčových hodnot, ovlivňujících RS. Trend impact analýza byla v tomto případě zvolena jako kvantitativní metoda pro odhad budoucího vývoje, ve kterém byl vývoj v čase ovlivňován budoucími nejistotami. Jak bylo vysvětleno výše, TIA identifikuje soubor důležitých budoucích událostí, které se mohou odchylovat od extrapolace založené na historických datech. Posuzuje pak pravděpodobnost a dopady těchto událostí.

Výsledkem studie byl výčet pravděpodobných technologických RS v nadcházejících letech.

Application of Trend Impact Analysis for predicting future fruit consumption [17]

Studie je součástí projektu ISAFRUIT, integrovaného evropského výzkumu zaměřeného na konzumaci ovoce. Studie byla prováděna ve čtyřech zemích severní Evropy a jejím cílem bylo lepší porozumění silám, které ovlivňují spotřebu ovoce a odhalení možností pro stimulaci této spotřeby.

Podle výše zmíněného postupu se tato studie dělí do tří fází:

- 1) sesbírání dat o spotřebě ovoce ze čtyř zemí a vytvoření základu (baseline) na základě trendů v minulých letech
- 2) získání informací o potenciálních budoucích trendech od expertů a odhad časového rámce, kdy by tyto trendy mohly nastat
- 3) dosazení těchto zjištěných dat do trend impact analýzy

Dotazníky a rozhovory

Autoři požádali 6 expertů na spotřebu ovoce a 6 expertů na spotřebu mimo tento sektor. Byli dotazováni, jaké faktory ovlivňovaly spotřebu ovoce do roku 2007 a jaké faktory ji budou ovlivňovat do roku 2025. Pro každý faktor expert určil jeho míru vlivu na historickou a budoucí konzumaci a určil pravděpodobnost, s jakou tento faktor v budoucnosti nastane. Pro každou zemi byly určeny tři nejvýznamnější faktory. Informace získané od expertů byly zkombinovány, přičemž každý expert měl v tomto hodnocení stejnou váhu.

Určení baseline

Aby bylo možné vytvořit základní odhad budoucnosti pomocí extrapolace trendu v čase, musela být prozkoumána historická data. V minulosti se pro tyto účely používalo několik regresních rovnic.

K vytvoření předpovědi byla na datech spuštěna simulace Monte Carlo, forma statistického zpracování, která odhadovala výsledný dopad faktorů v jednotlivých letech. TIA model byl implementován pomocí Excel Visual Basic a sestával tedy z následujících komponent: baseline data, expertní data s pravděpodobnostmi, agregovaná expertní data, Monte Carlo simulace a grafická prezentace modelu.

Výsledkem studie byl odhad, že se spotřeba ovoce na člověka do roku 2025 zvýší o 2,12 kg jako výsledek tří nejvýznamnějších faktorů – zdraví, dostupnost a variabilita produktu.

Tabulka 3. Tabulka vybraných studií

Název	Autor	Zdroj	Publikováno	Metoda
<i>Delphi Method to Explore Future Scenario Possibilities on Technology and HCI</i>	Adriano Bernardo Renzi, Sydney Fernandes de Freitas	Springer International Publishing	2015	Delphi metoda
<i>Future imaging techniques for cancer patients in The Netherlands</i>	Theo J. B. M. Postma ¹ , Janneke C. Alers, Sijmon Terpstra, Arjan Zuurbier	Springer Medizin Verlag	2006	Delphi metoda
<i>New and emerging technologies for the treatment of inherited retinal diseases</i>	J. Smith, D. Ward, M. Michaelides, A.T. Moore, S. Simpson	Eye, Macmillian Publishers	2015	Horizon scanning
<i>Horizon scanning for Remote Patient Monitoring (RPM) Technology</i>	Hospital admission risk program	Australasian Physical & Engineering Sciences in Medicine	2003 (2005)	Horizon scanning
<i>Scenario planning for the electricity generation in Indonesia</i>	C. Rachmatullah, Lu Aye, R.J. Fuller	Elsvier Energy policy	2007	Metoda tvorby scénářů
<i>Combining the scenario technique with bibliometrics for technology foresight: The case of personalized medicine</i>	Birgit Stelzer, Fabian Meyer-Brötz, Edgar Schiebel, Leo Brecht	Elsvier Technological Forecasting & Social Change	2015	Metoda tvorby scénářů
<i>Application of Trend Impact Analysis for predicting future fruit consumption</i>	W. H. G. J. Hennen, J. Benninga	Journal of Horticultural Science & Biotechnology	2009	Trend impact analýza
<i>A systematic way of identifying and forecasting technological reverse salients using QFD, bibliometrics, and trend impact analysis: A carbon nanotube biosensor case</i>	Kyunam Han, Juneseuk Shin	Elsvier Technovation	2014	Trend impact analýza

Zhodnocení metod

Foresight metody lze dělit podle různých kritérií. Nejrozšířenější dělení je podle typu techniky na kvantitativní, kvalitativní a semi-kvantitativní. Je však nutné podotknout, že i tato klasifikace nemá pevně stanovené hranice a podle způsobu provedení se metody mohou mezi skupinami prolínat.

Vlivem narůstajících výpočetních možností se v současnosti zvyšuje četnost používání kvantitativních metod. Tyto metody se často řídí přesně daným postupem zpracování dat a jsou tak v jistém smyslu jednodušší než metody kvalitativní. U těch je zapotřebí velkého množství taktických znalostí.

Existují také metody, které se snaží využít silných stránek obou těchto kategorií. Vždy je při výběru metody stěžejní z jakých dat vycházíme, jaké očekáváme výstupy, jaké jsou naše časové, technické, personální či finanční možnosti[18].

Následující tabulka pochází z knihy *The Handbook of Technology Foresight: Concepts and Practice* [18], kde v kapitole *Foresight Methodology* R. Popper rozděluje metody do zmíněných tří skupin (viz. Tabulka č. 4 na následující straně).

Tabulka 4. Klasifikace foresight metod podle typu, Zdroj: [18]

Kvantitativní	Kvalitativní	Semi-kvantitativní
<i>Tyto metody se zaměřují na pochopení jevů a událostí. Mají tendenci být založené na subjektivitě, kreativitě, které je často těžké ověřit.</i>	<i>Tyto metody měří proměnné a aplikují statistické analýzy. Důležitá je spolehlivost vstupních dat, jestliže mají být výstupy věrné.</i>	<i>Metody aplikují matematické principy pro kvantifikaci subjektivity, úsudků a pohledů expertů a komentátorů.</i>
Backcasting	Benchmarking	Cross-impact/Structural Analysis
Brainstorming	Bibliometrics	Delphi
Citizens Panels	Indicators/Time Serie Analysis	Key/Critical technologies
Conferences/Workshops	Modelling	Multi-criteria analysis
Essays/Scenario Writing	Patent Analysis	Polling/Voting
Expert Panels	Trend Extrapolation/Impact Analysis	Quantitativ scenarios/SMIC
Genius Forecasting		Roadmapping
Interviews		Stakeholder Analysis/MACTOR
Literature Review		
Morphological Analysis		
Relevance Trees/Logic Charts		
Role Play/Acting		
Scanning		
Scenario workshops		
Science Fictioning		
Simulation Gaming		
Surveys		
SWOT analysis		
Weak Signals/Wild Cards		

Kromě této základní klasifikace lze metody rozdělovat podle mnoha dalších hledisek.

V následující části jsou zhodnoceny výhody a nevýhody metod Delphi, Horizon scanning, Tvorby scénářů a Trend impact analýzy.

Delphi metoda

Tato metoda využívá skupiny odborníků odhadu budoucího vývoje. Jde o propojování subjektivních názorů v kontrolovaném několikakolovém procesu, dokud nedojde k požadovanému konsenzu.

Metoda Delphi se pohybuje na hranici mezi kvalitativním a semi-kvantitativním přístupem. **Výhody** této metody jsou například možnost provádět studii prostřednictvím

internetu, takže jsme schopni docílit spolupráce odborníků i z geograficky velmi vzdálených oblastí. Výhodou je také používání dotazníků, které jsou přehledné, jasné, týkají se tématu. Pozitivní je i možnost využití víceúrovňových odpovědí či hodnocení na škále. Taková data jsou dobře hodnotitelná. Výhodou je také možnost přiřazovat k odpovědím váhy. Tato metoda je dobrým způsobem pro shromažďování expertních informací o určité oblasti a jako nástroj je flexibilní.

Nevýhodou této metody je zejména její náročnost na organizaci a zpracování. Zejména zpracování výsledků vyžaduje velké množství času. Slabinou Delphi metody může být samotný výběr expertů. Nesprávně zvolená skupina odborníků může významně zhoršit výsledky studie. Kritická je také subjektivita a s tím související riziko špatného zpracování hodnotitelem. Metoda je také zcela závislá na ochotě panelistů zúčastnit se studie a často selže na tom, že experti výsledky neodevzdají. Studie je také citlivá na ovlivnění v důsledku toho, jaké otázky jsou tazatelem kladeny. Je velmi náročné sestavit dotazník tak, aby byl objektivní a nenaváděl k žádné odpovědi.

Horizon scanning

Horizon scanning je systematická metoda, která pomocí důkladného zkoumání přináší upozornění na různé fenomény, trendy, hrozby a nabízí tak možnosti nahlížet na budoucí vývoj ve zkoumané oblasti.

Hlavní **výhodou** této metody je skutečnost, že velmi efektivně vyhledává příležitosti a rizika. Je kvalitním nástrojem pro vyhledávání trendů a signálů, které budou ovlivňovat budoucnost. Výstupy metody horizon scanning jsou často velmi zajímavé a obsáhlé soubory dat, vhodných pro další analýzu. Opomenuta by neměla být ani možnost pomocí vhodného softwaru realizovat skenování informací v podstatě v reálném čase.

Mezi **nevýhody** patří značná náročnost na zdroje a čas. Má nedostatky v zachycování všech trendů a slabých signálů, které by mohly ovlivňovat vývoj. Také se můžeme setkat se subjektivním vyhodnocováním dat.

Metoda tvorby scénářů

Jedná se o kreativní tvorbu možných variant vývoje, kdy jsou určeny ovlivňující faktory a v podstatě pomocí simulace vytvořeny různé varianty vývoje.

Výhoda této metody spočívá například v tom, že se nesnaží o vytvoření jednoho co nejpřesnějšího odhadu, ale vytváří několik rovnocenných variant vývoje. Umožňuje

efektivně rozpoznat i slabé signály a diskontinuity a umožňuje tak lepší připravenost, zejména v souvislosti s plánováním. Pokud se používá jako strategický nástroj umožňuje otevřít debatu, zlepšuje komunikaci a stimuluje strategické myšlení. Tyto vlastnosti metodu předurčují k tomu, být významným nástrojem při strategickém managementu. Metoda je také flexibilní.

Nevýhodou metody může být velká subjektivita a následně i nedůvěryhodnost produkovaných scénářů. Metoda je také časově velmi náročná. Úspěch je často silně závislý na správném výběru účastníků procesu. Velmi důležité je jejich hluboké porozumění problému. Metoda také vyžaduje velmi důkladný sběr dat v přípravné fázi.

Trend impact analýza

TIA je prognostická metoda, která umožňuje extrapolaci historických trendů s ohledem na očekávání některých budoucích událostí. Umožňuje během zkoumání určitého trendu sledovat účinky možných budoucích událostí, které jsou považovány za důležité [15].

Velkou **výhodou** této metody je její propojení kvantitativního přístupu a kvalitativního hodnocení expertů. Těží tak to nejlepší z obou přístupů a bere v úvahu události, které mohou ovlivnit trend. Výstupy TIA se jeví jako spolehlivé a pokud jsou data zpracována správně, přináší zajímavé a poměrně přesné odhady.

Mezi **nevýhody** řadíme nemožnost vytvořit kompletní seznam ovlivňujících událostí. Prakticky vždy se jedná o úzký výběr několika nejdůležitějších (nejvlivnějších) faktorů. Pozornosti tak unikají nepravděpodobné a neočekávané události, které ale mohou mít zásadní vliv. Diskutabilní je také přesnost pravděpodobností, s jakými faktory ovlivňují vývoj. Vše je založeno na pouhých „očekávaních“ expertů, což může jinak exaktní metodu významně ovlivnit. Je proto důležité dbát na správný výběr expertní skupiny. Opět je významným ovlivňovatelem výsledku subjektivita.

Uváděné charakteristiky jsou dále zpřehledněny v tabulce č. 5.

Tabulka 5. Srovnání metod pro odhad budoucího vývoje

Metoda	Typ	Výhody	Nevýhody
Delphi	Kvalitativní (semi-kvantitativní)	<ul style="list-style-type: none"> - virtuální účast expertů - možnost používat dotazníky, víceúrovňové odpovědi, váhy - dobrá hodnotitelnost - shromažďování expertních informací z určité oblasti - flexibilní 	<ul style="list-style-type: none"> - náročné na organizaci a čas - kritický výběr expertů, odbornosti - subjektivita - riziko malého množství odpovědí - ovlivnění výsledku charakterem otázek - nerovnoměrné rozložení expertních znalostí
Horizon scanning	Kvantitativní	<ul style="list-style-type: none"> - efektivně vyhledává příležitosti a rizika - hledání signálů a trendů - kvalitní soubor dat pro další analýzu - možnost skenování v reálném čase, tvorba databází 	<ul style="list-style-type: none"> - náročné na zdroje a čas - neschopnost zachytit všechny vznikající trendy a slabé signály - subjektivní interpretace
Scenario method	Kvantitativní i kvalitativní	<ul style="list-style-type: none"> - tvorba několika variant vývoje - rozpoznává slabé signály a diskontinuity - stimulace strategického myšlení - debata, komunikace - významné při strategickém managementu - flexibilní metoda 	<ul style="list-style-type: none"> - značná subjektivita, nedůvěryhodnost - časově náročná metoda - kritický je výběr účastníků - nutné hluboké porozumění problému - důkladný sběr dat před tvorbou scénáře
TIA	Kvantitativní i kvalitativní	<ul style="list-style-type: none"> - bere v úvahu události, které mohou ovlivnit trend - důvěryhodný, podložený výsledek - přesné odhady na určené časové období 	<ul style="list-style-type: none"> - nekompletní/nedokonalý seznam ovlivňujících faktorů - diskutabilní přesnost pravděpodobností - faktory nemají stabilní podklad, jsou „očekáváním“ expertů - subjektivita

Není možné říci, která z metod je pro odhad budoucího vývoje lepší a která horší. Každá z uvedených metod má své opodstatnění a pokud je správně zvolena a provedena, je mocným nástrojem nejen pro odhadování vývoje technologií.

1.3 Umělá inteligence

Ačkoliv je odvětví umělé inteligence (UI) známé již od 50. let 20. století, dodnes nepanuje shoda na konkrétní definici vyjadřující obsah tohoto oboru. Podle V. Maříka a kol. je umělá inteligence [19]:

„...soubor metod, teoretických přístupů a algoritmů, které sjednocuje úsilí o počítačové řešení velmi složitých úloh.“

Pokud chceme blíže charakterizovat vlastnosti souboru těchto metod a kroky vedoucí k řešení složitých úloh, můžeme uvést definici umělé inteligence, jak ji podává Kotek a spol. [20]:

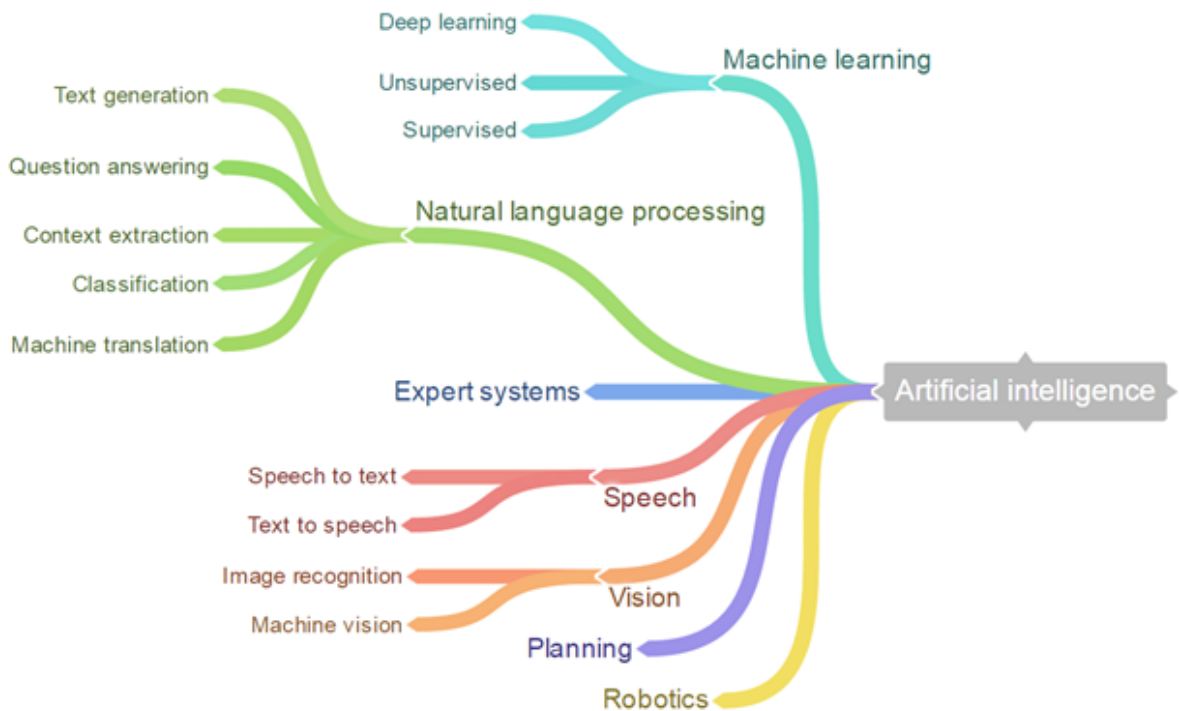
„Umělá inteligence je vlastnost člověkem uměle vytvořených systémů vyznačujících se schopností rozeznávat předměty, jevy a situace, analyzovat vztahy mezi nimi, a tak vytvářet modely vnitřního světa, ve kterých tyto systémy existují a na tomto základě pak přijímat účelná rozhodnutí, za pomoci schopností předvídat důsledky těchto rozhodnutí a objevovat nové zákonitosti mezi různými modely nebo jejich skupinami.“

Jako vědní obor umělá inteligence studuje syntézu a analýzu výpočetních agentů, kteří fungují inteligentně. Agentem se zde rozumí věc, která provádí nějakou činnost. Může jím být například člověk, stroj, společnost atd. V případě umělé inteligence je výpočetním agentem software (nebo jeho část). Předpoklady inteligentního chování pak jsou [24]:

- činy přiměřené okolnostem a cílům, s přihlédnutím ke krátkodobým a dlouhodobým důsledkům,
- flexibilita vůči měnícím se prostředím a cílům,
- schopnost učit se ze zkušenosti,
- schopnost provádět vhodná rozhodnutí s ohledem na své vnímání a výpočetní omezení,

Velice zešíroka řečeno je UI nejen odvětví informatiky, ale multidisciplinární přístup vedoucí k porozumění modelování a replikování inteligence a kognitivních procesů pomocí různých výpočetních, matematických, logických, mechanických a dokonce biologických principů a nástrojů [21].

Ve snaze přehledně zobrazit jednotlivá odvětví umělé inteligence je zde použit následující diagram (obrázek č. 1). Jedná se však o částečné zjednodušení, neboť jednotlivé oblasti se mezi sebou vzájemně překrývají a mnohé z nich nejsou uvedeny.



Obrázek 1. Diagram běžného dělení umělé inteligence na hlavní větve

V následujících části jsou přiblíženy jednotlivé hlavní větve UI.

Strojové učení (*Machine learning*)

Strojové učení je schopnost počítače učit se ze zkušeností, tj. modifikovat svůj způsob zpracování na základě nově získaných informací [22]. Systém k těmto změnám nedochází výslovným naprogramováním, ale právě procesem učení. Tyto modifikace pak vedou mimo jiné k lepší efektivitě či adaptabilitě v prostředí. Za tímto účelem programy zpracovávají velké objemy dat.

Definování obsahu strojového učení svádí k používání kognitivních pojmů. Na tomto místě ale uvedu jednu z často citovaných formálních definic procesu učení, formulovanou T. Mitchellem [23]:

„O počítačovém programu můžeme říct, že se učí ze zkušenosti E s ohledem na určitou třídu úloh T a míru úspěšnosti P, pokud se jeho výkon při úkolech T, měřený pomocí P, zlepšuje se zkušeností E.“

Tzn. že se algoritmus učí opakovaným pozorováním dat při řešení úlohy a postupným zlepšováním, ke kterému dochází minimalizací chyby. Strojové učení úzce souvisí se statistikou a matematickou optimalizací [24]. Jedná se o velmi důležitou metodu na poli datové analýzy, kde se strojové učení používá k tvorbě složitých modelů a algoritmů pro prediktivní analýzu.

Zpracování přirozeného jazyka (*Natural language processing*)

Obecně řečeno jde o aplikaci výpočetních technik pro analýzu a syntézu přirozeného jazyka. Cílem aplikace těchto technik je komunikace s počítačem v přirozeném jazyce, a to jak psanou, tištěnou i mluvenou formou [25].

System, který umožňuje zpracování přirozeného jazyka je pak schopen přijmout a rozpoznat člověkem vyprodukovanou zprávu, dokáže jí porozumět a realizovat adekvátní odpověď [25].

Jedná se o oblast, do které kromě informatiky zasahují i obory jako lingvistika či akustika. Tato kategorie metod se snaží řešit problémy jako je strojový překlad (převod jednoho přirozeného jazyka na druhý), chatboti (tj. automatizované komunikování s lidmi, odpovídání na otázky), automatické vytváření přehledů atd. Spadá sem i kategorie zpracování řeči, která je dále uvedena samostatně.

Expertní systémy (*Expert systems*)

Jedná se o software, který využívá databáze odborných znalostí k poskytování poradenství nebo rozhodování ve specializovaných oblastech. Velmi zjednodušeně tedy takový program za pomoci umělé inteligence simuluje chování a úsudek lidského odborníka. Fiegenbaum a kol. [26] definují expertní systémy následujícím způsobem:

„Expertní systémy jsou počítačové programy simulující rozhodovací činnost specialistů (expertů) při řešení složitých úloh rozhodování a využívající vhodně zakódovaných speciálních znalostí převzatých od expertů s cílem dosahovat ve zvolené problémové oblasti kvality rozhodování na úrovni experta.“

Zpracování řeči (*Speech processing*)

Tato oblast UI se prolíná s výše uvedeným zpracováním přirozeného jazyka. Řeší se zde velmi komplexní a obtížné problémy související se zpracováním mluveného slova, ať už se jedná o syntézu řeči (převod psaného textu na mluvené slovo), rozpoznávání řeči (převod mluveného slova na psaný text) nebo jiné související úlohy, například izolace a přepis mluveného slova jednoho řečníka ze skupiny několika hovořících. V souhrnu se tedy zpracování řeči zabývá její analýzou, zpracováním signálů, jejich získáváním, manipulací a podobně.

Počítačové vidění (*Computer vision*)

Počítačové vidění je soubor metod a technik pro zpracování a porozumění vizuálním obrazům [25].

Jako všechny podoblasti umělé inteligence, patří i počítačové vidění mezi obory s širokým záběrem, prolínající se s mnoha dalšími oblastmi. Ve své podstatě se zabývá zpracováním digitálního obrazu (včetně videí). Využívá k tomu mimo jiné matematiku, fyziku (optika, radiometrie) a počítačovou grafiku. Počítačové vidění se snaží zpracováním obrazu napodobit lidský zrakový systém, tedy vnímat, analyzovat a chápat optické vjemy. Jako příklad může posloužit rozpoznávání poznávacích značek a převod jejich obsahu na text, počítání nebo rozpoznávání osob na fotografii a podobně [27].

Plánování (*Planning*)

Plánovací systémy jsou v umělé inteligenci takové systémy, které hledají optimální sekvenci akcí, vedoucích od počátečního stavu (přítomném v reálném světě) k požadovanému cíli. Vytváří tak inteligentní strategie vedoucí ke splnění úkolu. Spadají sem nejrůznější úkoly, od hledání nejvhodnějších cest pro doručování balíků až po plánování vesmírných průzkumů [28].

Robotika (*Robotics*)

Hovoříme-li o robotice bez návaznosti na umělou inteligenci, pohybujeme se v původní oblasti strojního inženýrství, ze kterého moderní robotika vychází. Kromě prostých mechanických úkonů ale umělá inteligence umožňuje robotům plnit mnohem komplexnější úlohy [21]. Robotiku v dnešní době můžeme chápat jako oblast se širokým spektrem úloh, vhodných pro umělou inteligenci. Takto robotiku v souvislosti s UI popisuje Mařík a spol. [19]:

„... pohlížíme na robotiku jak na širší, samostatnou vědeckou a technickou disciplínu, která je sice součástí umělé inteligence z pohledu historického, avšak z hlediska robotiky jako již samostatné disciplíny je dnes především významnou aplikační oblastí umělé inteligence.“

Současný stav problematiky UI ve světě

Napříč všemi obory, spojenými s využíváním nových technologií, v současnosti rezonují zprávy o nebývalém nárůstu dostupných dat. Toto bezprecedentní navýšení, spojené se zlepšováním schopností počítačů a možnostmi datové analýzy nazýváme jako *datová revoluce*. Data expandují ve třech hlavních úrovních (dimenzích), které je následně charakterizují: rychlost (*velocity*), objem (*volume*) a rozmanitost (*variety*). Setkáváme se tady s pojmem *Big data*, který slouží k označení takových skupin dat, které jsou příliš velké na zpracování konvenčními softwarovými způsoby [29].

Tento fenomén se nevyhýbá ani oblasti zdravotnictví. Mluvíme zde o datech z mnoha různých zdrojů, ve strukturované i nestrukturované formě: elektronická zdravotnická data, data z domácích monitorovacích zařízení, informace o léčivech, informace z klinických registrů, data dostupná ze zobrazovacích metod a mnohé další [29].

Zde se otevírají dveře pro vstup umělé inteligence, která má potenciál data zpracovat a využít. Stává se tak nejen vědecky zajímavou, ale i nutnou součástí technologického vývoje a v nadcházejících desetiletích bude nepochybně hrát významnou roli nejen ve zdravotnictví, ale i v jiných rozvíjejících se oborech. Využívání UI ve zdravotnictví je snahou přinést snazší a dostupnější zdravotní péči, rychlejší a přesnější diagnostiku či lepší léčebná doporučení, jak ve své práci podotýká A.C. Chang [29]:

„Zdravotní péče by měla přijmout zpracování velkých dat pomocí datové analýzy a umělé inteligence k získání smysluplných zdravotnických dat a informací v nich obsažených, za účelem zlepšení kvality a výsledků zdravotní péče.“

Potenciál a potřeba využití umělé inteligence ve zdravotnictví samozřejmě neunikly společnostem, vývojářům ani výzkumníkům, kteří se UI zabývají, a již v dnešní době se objevuje celá řada funkčních aplikací. Tractica forecast [30] uvádí, že globální trh pro UI software ve zdravotnictví, hardware a služby se zvýší z \$234 milionů v roce 2016 na \$19.3 bilionů v roce 2025. Jiný zdroj uvádí, že trh s UI pro zdravotní péči se zvýší o 40% mezi lety 2014 a 2021 [31].

V následující části jsou uvedeny dvě studie, ilustrující využití umělé inteligence na konkrétním problému ve zdravotnictví.

CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning [32]

V této studii je představen algoritmus sloužící k detekci pneumonie z rentgenových snímků, dosahující přesnosti praktikujícího radiologa. Model je založen na 121vrstvé konvoluční neuronové síti, pro kterou jsou vstupním zdrojem dat rentgenové snímky plic a výstupem je pravděpodobnost výskytu pneumonie a tepelná mapa signalizující místa nejpravděpodobnějšího výskytu pneumonie. Neuronová síť byla trénována na momentálně největším dostupném datasetu rentgenových snímků hrudníku ChestX-ray14, který obsahuje 112 120 snímků hrudníku označených až 14 různými chorobami.

Výsledek značí, že testovaná neuronová síť překonala výsledky čtyř zúčastněných radiologů, kteří hodnotili snímky. AUROC (oblast pod křivkou Receiver Operating Characteristic, která je rovna pravděpodobnosti, že binární klasifikátor ohodnotí náhodně vybraný pozitivní vstup více jako pozitivní než náhodně vybraný negativní vstup) vyšla 0.828, což značí velmi dobrý výsledek algoritmu.

Automatizovaná detekce onemocnění z rentgenových snímků by měla obrovský klinický vliv a byla by nesmírně důležitým posunem při poskytování péče populacím s nedostatečným přístupem ke specialistům.

Artificial intelligence in neurodegenerative disease research: use of IBM Watson to identify additional RNA-binding proteins altered in amyotrophic lateral sclerosis [33]

Studie popisuje využití IBM Watson, počítačového systému schopného získávat informace z přirozeného jazyka pomocí metod strojového učení, zpracování přirozeného jazyka, reprezentace znalostí a dalších. Zde byl použit k identifikování nových na rRNA navázaných proteinů (RBPs) v genomu. Při onemocnění amyotrofickou laterální sklerózou jsou některé z těchto proteinů pozměněny. Watson extrahoval informace z dostupné literatury a na základě sémantických podobností identifikoval nová spojení. Systém analyzoval všechny dosud publikované abstrakty týkající se RBPs u ALS a poté aplikoval tuto znalost na všechny RBPs v genomu tak, že je seřadil podle sémantických podobností. Takto získaných top-ten RBPs výzkumníci zhodnotili na RNA úrovni na

vzorcích tkání s ALS a tkáních bez neurologického onemocnění. Tato hodnocení pak probíhala kombinací imunohistologických metod a RNA a proteinové analýzy.

System Watson byl v tomto případě schopen prohledat stovky záznamů a najít požadované souvislosti, což je podle autorů pro podobné výzkumy obrovským přínosem. Využití strojového učení a dalších nástrojů umělé inteligence podle nich v budoucnu uspíší vědecké objevy nejen na poli amyotrofické laterální sklerózy.

Současný stav problematiky UI v ČR

Sledovat problematiku umělé inteligence ve zdravotnictví v České republice je nesmírně obtížný úkol. Ačkoliv je výzkum nejrůznějších vědních odvětví v České republice nepochybně na velmi vysoké úrovni, není snadné identifikovat věrohodné zdroje, které by situaci spolehlivě zachycovaly. Většina zpráv o používání umělé inteligence v českém zdravotnictví tedy pochází z šedé literatury. Důvodem bude jistě i to, že se tyto aplikace nacházejí zpravidla ve fázi vývoje nebo nenesou přímo označení umělá inteligence.

V následující části jsou uvedeny příklady využití umělé inteligence – konkrétně systémů pro podporu rozhodování – v českém zdravotnictví.

Clinical Decision Support System in Dentistry [34]

V tomto článku autoři popisují systém pro podporu rozhodování, který má za cíl pomáhat poskytovatelům zubní péče při léčbě dětských pacientů se zvláštními potřebami a s větším množstvím kariézních lézí. Jedná se o software speciálně připravený pro dentální kliniky, jehož jádrem je rozhodovací strom. Vstupními daty jsou kooperace pacienta a množství lézí. Algoritmus hodnotí, zda bude pacient léčen ambulantně nebo zda se jedná o jednodenní chirurgický zákrok nebo bude hospitalizován a jaká bude vhodná sedace. Při vytváření schématu byly použity diagnostické a léčebné protokoly využívané na Stomatologické klinice dětí a dospělých 2. lékařské fakulty Univerzity Karlovy a fakultní nemocnice v Motole.

Výsledný software má vytvořeno odpovídající uživatelské rozhraní a je určen zejména pro použití na klinikách, kde vytváří standart pro péči o tyto dětské pacienty.

Diagnostic Software for Decision Support of Detection and Interpretation of Tumor Markers [35]

V této studii je prezentován software pro podporu rozhodování při detekci a interpretaci nádorových markerů. Tento systém je spojením dvou existujících programových balíčků na podporu rozhodování. Prvním z nich je BIANITA, systém pro primární a suspektní nádorovou diagnostiku. Klíčové je pro tento program určení typu a lokalizace primárního nádoru. Systém je založen na teorii Bayesovských sítí. Vstupními daty pro software jsou výsledky nádorových markerů z krevního séra, věk, pohlaví a lokalizace metastáz, pokud byly nalezeny.

Druhým použitým softwarem je CRACTES, který slouží k interpretaci nádorových markerů u pacientů po léčbě. Hlavní úlohou programu je včasná diagnostika recidivy. Program je aplikován na pacienty, kteří jsou v remisi a jeho úkolem je zodpovědět otázku, zda je pravděpodobné, že se u pacienta do jeho příští plánované návštěvy objeví klinicky evidentní metastázy. Vstupními daty jsou zjištěné nádorové markery a ke zjištění se dochází metodami statistické analýzy.

V článku je popisován způsob, jakým jsou tyto dva softwary propojeny ve funkční systém pro podporu rozhodování, využitelný v praxi. Kromě samotného propojení systémů došlo k vytvoření uživatelského rozhraní a vytvoření způsobu pro anonymizaci dat. Systém je úspěšně používán v několika českých zdravotních zařízeních.

2 Metody

Jak bylo vysvětleno v rámci teoretického úvodu, pro sledování vývoje technologií existuje řada metod. Tyto metody (případně jejich kombinace) by měly být voleny na základě charakteristik sledované oblasti, s ohledem na přínosy a limity, které jednotlivé metody mají. Postup, který je navržen v této práci, se opírá zejména o Delphi metodu a systematickou rešerši (tedy horizon scanning). Delphi metoda slouží jako nástroj pro identifikování oblastí zájmu v úvodní fázi sledování vývoje. Expertní názor je s ohledem na složitost a neurčitost tématu umělé inteligence nezbytný pro výběr potenciálně významných oblastí UI, které zasahují do zdravotnictví. Dále navržený postup obsahuje zmíněnou rešerši studií vybraných témat. Dalším krokem k vytvoření funkčního postupu pro odhad technologií je analýza výstupů rešerše. Ke zjištěným poznatkům jsou pak dohledány aktuální studie, které ilustrují vývoj a využití technologií v této oblasti.

V následujících odstavcích budou detailně přiblíženy jednotlivé kroky, které pak tvoří navrhovaný postup pro foresight.

2.1 Systematická rešerše

Systematická rešerše je nástroj často používaný pro Horizon scanning, kde slouží k vyhledání relevantních studií k určeným tématům ve vybraném časovém horizontu. Rešeršní studie tvoří podstatnou část této práce. Je stěžejní pro získání informací o vybrané problematice a výstupy rešerše pak slouží pro další analýzu. Je součástí navrhovaného postupu pro foresight a zde byla aplikována na téma umělé inteligence.

Postup tvorby rešerše provedené v této práci byl následující:

1 Výběr tématu

Expertním hodnocením byly jako oblasti zájmu zvoleny dvě kategorie:

- Strojové učení (*machine learning*)
- Expertní systémy (*expert systems*)

2 Vyhledání literatury

Prvním krokem bylo určení klíčových slov. Pro kategorii strojové učení byly vyhledávány kombinace slov *machine learning* a *healthcare* nebo *medicine*.

Pro expertní systémy nebylo možné zvolit tak jednoznačná klíčová slova a bylo nutné vyhledávat několik variant: knowledge based, expert system a decision support system v kombinaci s healthcare nebo medicine.

Jako citační databáze byly použity Web of Science a Science Direct. Články byly vyhledávány v letech 2013 – 2017, pro každou kombinaci klíčových slov z jednotlivých kategorií ke každému roku zvlášť.

V databázi Science Direct byla klíčová slova vyhledávána v polích title, abstract, keywords. V databázi Web of Science se slova vyhledávala v polích topic, title.

Články byly vybírány pouze z kategorií research article, article, review article.

U všech nalezených článků byla relevance zhodnocena přečtením názvu, abstraktu, případně obsahu článku. Vybrané články sloužily k další analýze. Ke správě vyhledané literatury byl použit software Mendeley.

3 *Analýza vyhledané literatury*

Prvním krokem v analýze literatury je zhodnocení počtu nalezených relevantních článků v jednotlivých letech a jejich vývoj. Z toho lze získat základní představu o tom, jak se zkoumaná oblast vyvíjí v čase.

Dalším krokem je analýza četnosti slov (v tomto případě dvojic slov) obsažených v názvech a abstraktech vybraných článků. Po seřazení vyhledaných slovních spojení sestupně a odstranění těch, která jsou pro analýzu nadbytečná nebo nevhodná, získáme možnost odhalit důležité faktory, ovlivňující vývoj technologie a podobně.

Následuje analýza zdrojů, ve kterých byly vyhledané články publikovány. Sestavením žebříčku časopisu, ve kterých se články na danou tematiku nejčastěji publikovaly, je dobrým vodítkem pro získávání dalších informací nebo sledování vývoje. Tento krok má význam zejména tehdy, když se předpokládá periodické sledování technologie a provádění foresightu. Zaměření se na určité literární zdroje může zjednodušit a zrychlit získávání nových informací.

Posledním krokem je rozdělení jednotlivých článků do skupin podle oborů medicíny, do kterých spadají. Zařazování do jednotlivých skupin probíhá přečtením názvu, abstraktu, případně obsahu článku a následným zhodnocením. Pokud nelze článek jednoznačně přiřadit ke konkrétnímu oboru medicíny, nachází se ve skupině *nezařazeno*. Tato informace přispívá k dotvoření přehledu o tom, v jakých oblastech se technologie

využívá. Zároveň může být vodítkem k tomu, kam technologie dále směřuje a kde má potenciál.

Informace získané pomocí systematické rešerše a její analýzy se pak opakovaně využijí v průběhu foresight metody.

Na straně číslo 53 je schematicky zobrazen průběh systematické rešerše, včetně detailů o parametrech vyhledávání a počtech nalezených článků.

2.2 Vytvoření expertní skupiny

Pro fungování v práci navrhovaného postup foresightu je v mnoha krocích klíčová práce expertní skupiny. Proto bude v metodách popsán postup vytvoření expertní skupiny. V literatuře se vyskytují různé postupy, jak expertní skupinu sestavit. Ch. Okoli a spol. [36] navrhuje pětifázový postup.

1. Přípravení pracovního listu s potřebnými kvalifikacemi expertů (knowledge resource nomination worksheet, KRNW), který pomáhá kategorizovat experty ještě před jejich samotnou identifikací a vybírá nejvhodnější disciplíny, do kterých by měli panelisté spadat.
2. Obsazení KRNW konkrétními jmény.
3. Nominování expertů, během kterého dojde ke kontaktování osob z vytvořeného listu. Ti jsou pak požádáni mimo jiné o nominaci dalších expertů dle svého uvážení. Poskytnut je zde stručný popis studie a vysvětlení, proč právě oni byli identifikováni jako vhodní experti. Dotážeme se zde na jednotlivá bibliografická data pro následné hodnocení.
4. Ohodnocení expertů dle sesbíraných dat o kvalifikaci
5. Pozvání expertů do studie. Kontaktován je každý jednotlivý expert, je mu vysvětlen předmět studie a proces, který bude následovat (včetně odhadu časového závazku). Samotný dotazník je expertům odeslán v den potvrzení jejich účasti.

Tento postup je velmi výhodný, pokud disponujeme velkou řadou potenciálních expertů nebo studie vyžaduje rovnoměrnou účast odborníků z většího množství oborů a vyžadujeme specifickou úroveň kvalifikace.

Pro účely specifických studií, ve kterých se nepředpokládá získání velkého množství účastníků, je vhodná metoda non-probability sampling (purposive sampling). Výběr panelistů se tedy podřizuje potřebám studie a závisí na subjektivním úsudku výzkumníka. Tento účelový výběr expertů zajišťuje, že budou osloveni pouze ti účastníci, kteří splňují daná kritéria. Jsou zvoleny například tyto základní požadavky:

- zkušenost a znalost daného oboru (v případě studie o UI ve zdravotnictví by se jednalo o oblast medicíny, lékařské informatiky, biomedicíny, informačních technologií či jiných souvisejících oborů),
- zájem o řešenou problematiku,
- čas se zúčastnit,
- ochotu a kapacitu se zúčastnit,
- adekvátní komunikační schopnosti.

Snahou je vytvořit heterogenní expertní panel o přibližném počtu 10 účastníků. Podle Ch. Okoli a spol. [36] se optimální počet pohybuje mezi 10 a 18. Čím diverzifikovanější je panel, tím širší rozsah alternativ a perspektiv jsou experti schopni poskytnout, což může vést k lepším výsledkům [37].

2.3 Delphi metoda

Tato část kapitoly metod je věnována Delphi metodě, která je obsažená v navrhovaném postupu pro foresight. Delphi metoda byla vyvinuta jako nástroj pro získání co nejspolehlivějšího konsenzu skupiny expertů. Technika spočívá ve shromáždění expertů z různých odborných oblastí, kteří se soustředí na společné téma, sdílejí názory až do okamžiku dosažení nejlepšího možného souhlasu. Tato metoda tvoří důležitou část navrhovaného postupu pro foresight, takže je její teorii věnován značný prostor.

Tato metoda je vhodná pro řešení komplexních problémů, vyžadujících značnou úroveň expertízy, pro které je typická vysoká úroveň nejistoty. Složitě problémy většinou vyžadují kombinaci znalostí lidí z různých oborů, což Delphi metoda umožňuje bez nutnosti odborníků se fyzicky setkat. Delphi metoda se v mnohém podobá klasickému průzkumu, se kterým sdílí řadu prvků. Podle Ch. Okoli a spol. [36] dokáže Delphi metoda

odpovídat na otázky přesněji než tradiční průzkum a její flexibilní design umožňuje sběr bohatších dat, což vede k hlubšímu pochopení problému.

V následující části je uvedeno srovnání klasického průzkumu a Delphi metody v několika aspektech [36].

Požadavky na sestavení dotazníku pro Delphi metodu a pro klasický průzkum jsou v podstatě stejné. V případě průzkumu je zkonstruován dotazník, vybrán vzorek populace, na který je vhodné průzkum aplikovat, tyto lidé vyplní dotazník, který je pak po vrácení analyzován. U Delphi metody je rovněž sestaven dotazník, je vybrána skupina a po vrácení jsou odpovědi analyzovány. Liší se však samotná skladba dotazníku, charakter skupiny odpovídajících i způsob analýzy. A co je velmi důležité, delphi proces je iterativní, tudíž dochází k několika opakujícím se kolům, které mají výsledky směřovat k co nejdůvěrnějšímu konsenzu.

Co se týče reprezentativnosti vzorku, klasický průzkum vybírá skupinu, která bude statisticky nejlépe reprezentovat zkoumaný vzorek. Tradiční průzkum se snaží generalizovat výsledky, a proto je důležité volit skupinu dostatečně velkou na to, aby bylo dosaženo statisticky významného efektu na vybranou populaci. Delphi metoda ale nezávisí na tomto aspektu, ale spíše na dynamice skupiny a schopnosti dopracovat se ke konečným výsledkům. Velikost vzorku pro Delphi metodu je mnohem menší.

Důležitým pojmem při provádění průzkumu je „construct validity“, tedy stupeň do jaké míry test měří to, co tvrdí že měří. Tradiční průzkum této jistoty dosahuje opatrnou konstrukcí otázek a pre-testováním. Delphi metoda má tyto zásady stejné. Dodatečné jistoty pak mohou výzkumníci dosáhnout tak, že požádají experty aby ověřili interpretaci a kategorizaci výsledků. Tento krok je možný právě díky tomu, že panelisté nejsou pro výzkumníka anonymní, tudíž je může opakovaně kontaktovat a o tento krok požádat. S tím souvisí skutečnost, že data plynoucí z Delphi metody jsou potenciálně bohatší.

Existuje několik variant Delphi metody, ale základem je vždy anonymizovaná kontrolovaná debata, probíhající zpravidla v několika kolech. Každé kolo je vyhodnoceno a jeho výsledky jsou poskytnuty expertům, kteří na jejich podkladě mohou v dalším kole modifikovat své odpovědi. Postup se opakuje do té doby, než je dosaženo požadované shody.

Měření požadované shody, tedy hodnocení konsenzu, je velmi citlivou částí Delphi metody. Napříč studiemi se setkáme se širokým spektrem používaných metod, přičemž

neexistuje jednoznačný návod na to, kterou z nich použít. Způsob, jakým se rozhodneme měřit konsenzus, bude záviset na charakteru každé konkrétní studie, jejím rozsahu, počtu expertů, možnostech hodnotitele a mnohém dalším. Zde je uveden přehled nejpoužívanějších metod [38]:

Stanovení počtu kol – Předem je stanoven počet kol, které mají proběhnout (například tři). Tento počet je považován za dostatečný.

Subjektivní analýza – Dotazování je zastaveno v okamžiku, kdy se subjektivně předpokládá, že by další kolo nepřineslo upřesnění výsledků.

Určitá úroveň souhlasu – Konsenzus je hodnocen zpravidla v procentech, tzn. například 60% expertů souhlasí s tvrzením.

Modus – Tedy nejčastěji se vyskytující hodnota.

Interquartile range (IQR) – Za dosažení konsenzu je považován okamžik, kdy IQR ($IQR = Q_1 - Q_2$, Q_1 – medián první poloviny, Q_2 – medián druhé poloviny) je menší než určená hodnota. Například $IQR < 1,75$.

Kendall's W koeficient – Jedná se o hodnocení míry shody pro otázky v Delphi metodě, které se ptají na seřazení (např. nejlepší – nejhorší). Kendallovo W může nabývat hodnot 0 – 1, kde 1 znamená úplnou shodu a 0 odpovídá náhodnému seřazení.

t-statistika – Jedná se o porovnávání kol mezi sebou. Porovnává se rozdíl ve shodě, vyjádření, zda je změna významná a nebo není.

Výstupy Delphi metody mohou mít různé formy a ačkoliv metoda většinou nepřináší zaručené jistoty, může na základě zkušeností, myšlenkových modelů a očekávání zapojených expertů navrhnout hodnověrné scénáře a přiřadit jim pravděpodobnosti [10].

Experti jsou zpravidla kontaktováni pomocí emailu. První dotazník je zaslán vybraným expertům spolu s úvodním emailem se žádostí o účast. Součástí tohoto emailu je i definování konsenzu, kritéria pro jeho dosažení nebo zastavení procesu. Účastníky informujeme i o tom, na co přesně se budeme dotazovat, jak budou využita jejich data a získané odpovědi.

Dotazník 1: Úvodní sběr informací

První dotazník je tvořen pouze několika velice dobře formulovanými otevřenými otázkami. Účelem je hrubé vygenerování seznamu technologií důležitých faktorů. Experti

jsou požádáni, aby vyjmenovali co největší množství aplikací a aby své odpovědi vysvětlili. Výstupem prvního kola je tedy co nejširší zdroj informací (jedná se o formu brainstormingu). Vysvětlení expertů poslouží ke správnému pochopení a kategorizaci uvedených informací.

Analýza odpovědí z prvního kola sestává z odstranění identických odpovědí, uspořádání a seskupení a vytvoření dokumentu, který shrnuje všechny identifikované technologie. Tento dokument je dále použit ve druhém kole. Je nutné držet se odpovědí expertů, nijak je nepozměňovat a vyvarovat se generalizování nebo vynechávání některých dat.

Dotazník 2: Validace

Každému expertu je zaslán dokument s příloženými komentáři. Ve druhém kole se nepokládají nové otázky, expertů se dotazujeme jednak na ověření, zda jsme korektně interpretovali jejich odpovědi, ale i na to, zda jsme je správně zařadili. Bez tohoto kroku neexistuje žádný důvod k tvrzení, že byl vytvořen platný a pevný seznam technologií.[36] Experti jsou tak navíc schopni navrhnout dodatečné odpovědi, které je například při prvním kole dotazníku nenapadly.

Konstrukce dalších kol vychází vždy z kola předchozího. Každému účastníku je odeslán personalizovaný dotazník, který zahrnuje:

- a) kvantitativní výsledky
- b) kvalitativní feedback (abstrakt komentářů jednotlivých panelistů)
- c) účastníkovu vlastní odpověď k ilustrování jeho relativní pozice mezi ostatními experty

Vhodné je i přiložení vizuálního feedbacku (bar charts), který poskytuje informaci o distribuci dat.

Dotazník 3: Výběr technologií

Ve třetím dotazníku je předložen výběr technologií a faktorů na základě shody z předchozích dvou kol. Otázky je vhodné formulovat v uzavřené formě, vhodné je použití Linkertovy škály (1-6, bez možnosti neutrální odpovědi). Ke každé otázce je vhodné přiložit prostor, ve kterém je expert vybídnut ke krátkému slovnímu vysvětlení, proč se pro svoji odpověď rozhodl. Doporučuje se otázky seřadit náhodně, aby nedošlo ke zkreslení vlivem seřazení [36]. Zde je vhodné zvážit i použití možnosti „bez komentáře“

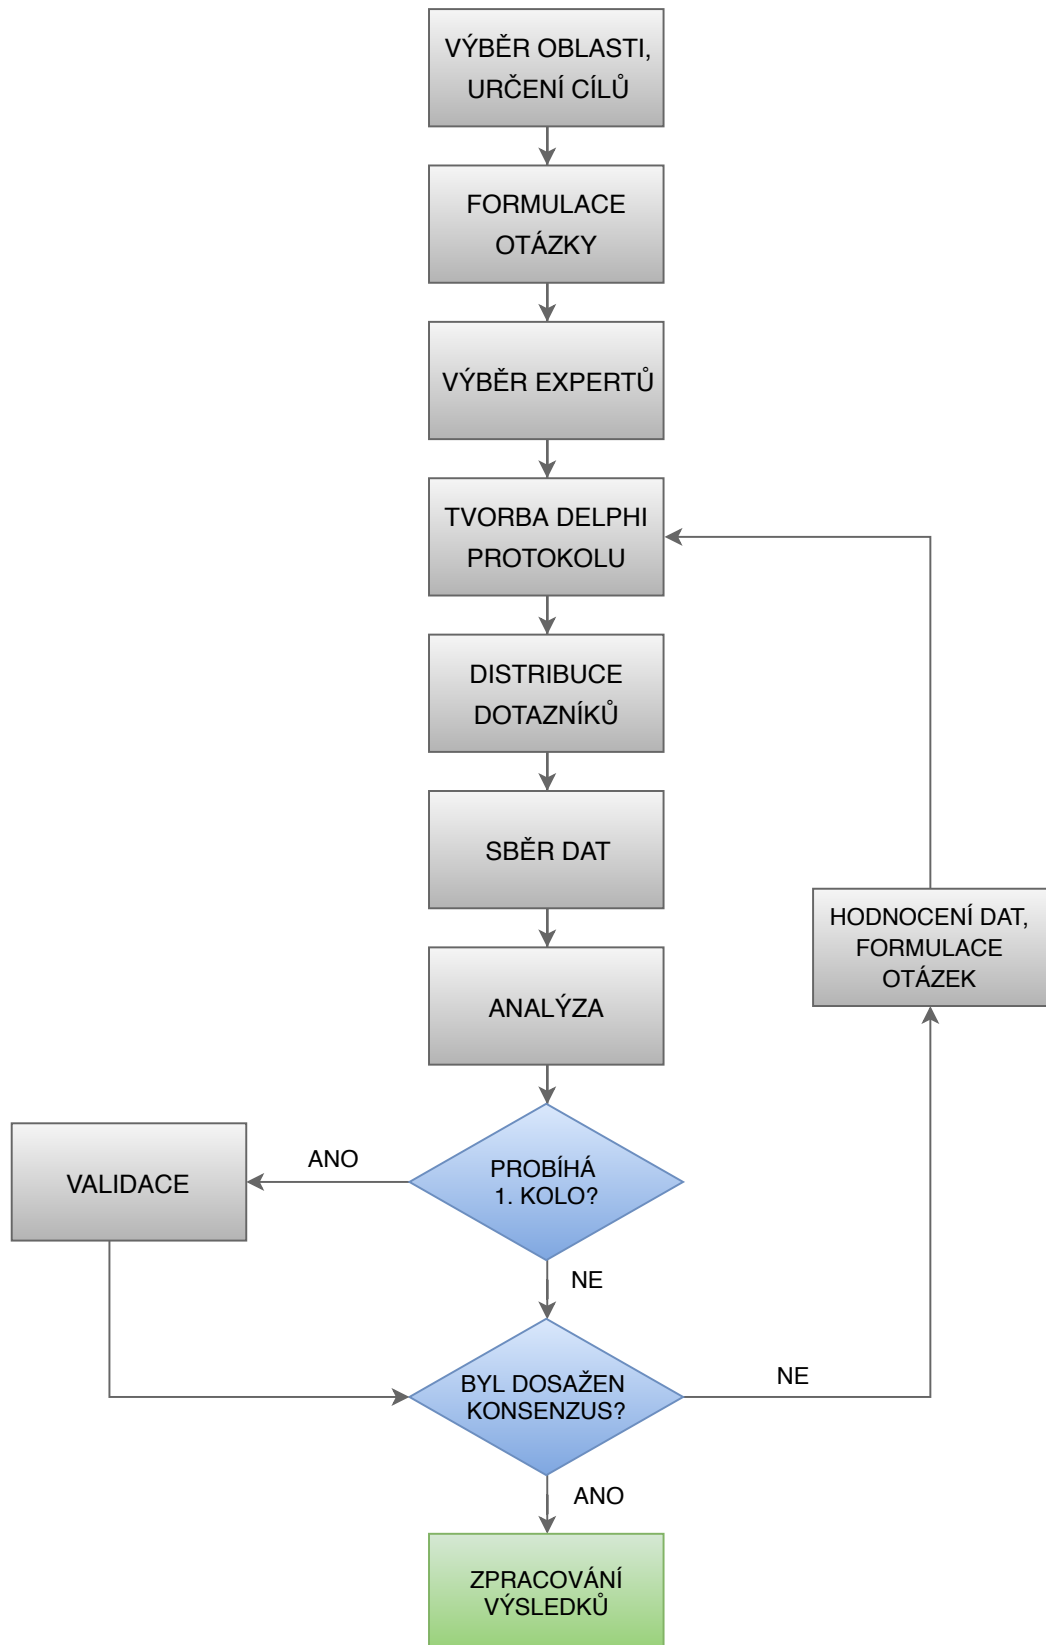
v případě, že otázka nespadá do odbornosti experta [44]. Vyvarujeme se tak dalším zkrácením. Po získání odpovědi z třetího kola je provedena analýza. Pokud je konsenzus nedostatečný a účastníci studie jsou ochotní, je možné v průzkumu pokračovat čtvrtým kolem.

V okamžiku, kdy dojde k požadované shodě a nebo zjistíme, že se bez ohledu na počet dalších kol odpovědi nemění, dochází k ukončení procesu. Následuje analýza získaných dat. Schématicky je průběh Delphi metody znázorněn na obrázku č. 2 na straně 50.

Delphi metoda byla zvolena jako nejvhodnější způsob pro zhodnocení a výběr oblastí zájmu při odhadování budoucího vývoje a jako taková je prvním krokem v navrhované metodice. Umožňuje propojovat subjektivní názory řady odborníků i na komplikovaná a obsáhlá témata a je tak vhodným nástrojem pro určité zacílení a výběr oblastí, na kterou se foresightu zaměřit.

Samotný průběh Delphi studie je ale velmi časově i technicky náročný. Příkladem může být výše uváděná studie [11], ve které průběh samotné Delphi metody trval 8 měsíců, kterým předcházelo několik měsíců příprav. Ačkoliv se jedná o studii s poměrně dlouhým průběhem a nepochybně se setkáme i s kratšími, dobře ilustruje náročnost procesu, který přesahuje možnosti této práce. Vedle náročnosti provedení Delphi je zde důvodem i problematický výběr expertů z oblasti umělé inteligence. Delphi metoda byla začleněna do teoretického návrhu pro foresight, ale pro účely této diplomové práce byla nahrazena expertním názorem konzultantky doc. Ing. Lenky Lhotské, CSc.

Na následující straně je na obrázku č. 2 vyobrazen diagram průběhu delphi metody.



Obrázek 2. Diagram průběhu Delphi metody

3 Výsledky

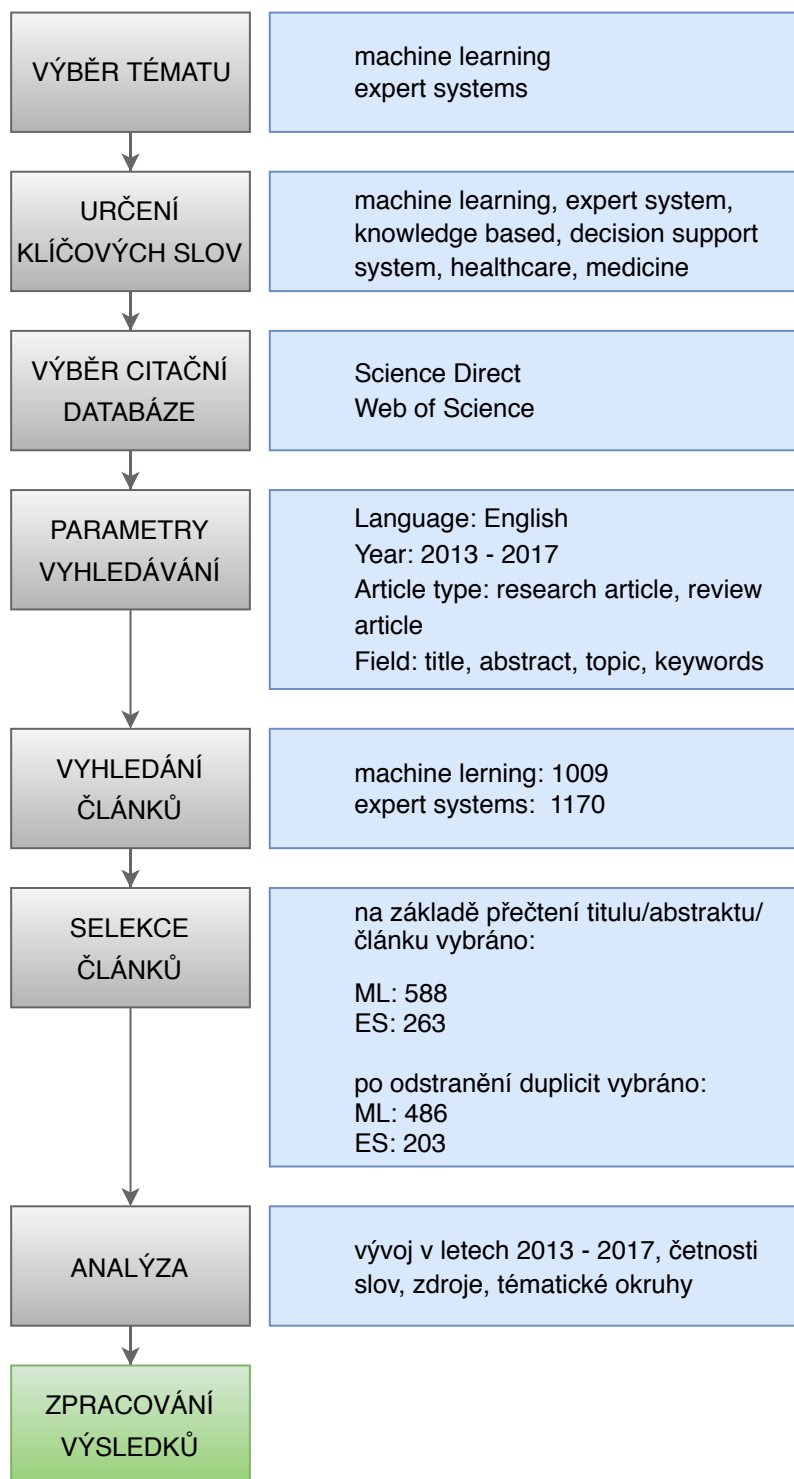
V této části budou prezentovány dosažené výsledky získané při plnění cílů diplomové práce. První část obsahuje výsledky rešeršní analýzy, tj. vyobrazení průběhu rešerše pomocí diagramu, podrobnosti o parametrech vyhledávání a nalezených článcích. Dále jsou dostupné výsledky analýzy četnosti slov, analýzy zdrojů a tematických okruhů nalezených článků. Data jsou uspořádána v tabulkách s vysvětlujícími komentáři. Výsledky jsou zasazeny do souvislostí a podpořeny příklady reprezentativních studií.

Další část výsledků se věnuje návrhu metodiky pro foresight. Tento nevržený postup je vyjádřen pomocí diagramu a vysvětlen.

3.1 Výsledky rešeršní analýzy

Podle zadaných parametrů, které byly podrobně popsány v metodologické části, byly systematickou rešerší vyhledány odborné články zabývající se problematikou strojového učení a expertních systémů ve zdravotnictví v letech 2013 – 2017. Zadáváním výše popsaných parametrů vyhledávání bylo v citačních databázích ScienceDirect a Web of Science nalezeno celkem 1009 článků ke strojovému učení a 1170 článků k expertním systémům. Z těchto článků bylo nakonec vybráno 486 článků pro strojové učení a 203 článků pro expertní systémy. Tato selekce probíhala na základě přečtení titulu, abstraktu, případně samotného článku. Hlavním parametrem v rozhodování, jestli článek zařadit do výběru byla skutečnost, zda byla využita umělá inteligence. Všechny vybrané články byly v anglickém jazyce. Po odstranění duplicit po spojení obou citačních databází zůstalo 486 článků pro strojové učení a 203 článků pro expertní systémy. Velké množství vyřazených článků v kategorii strojového učení bylo způsobeno zejména skutečností, že pojmem „expertní systém“ se často označuje i takový systém, který je založen například na optimalizaci procesů bez použití umělé inteligence. Všechny takové studie byly vyřazeny.

Postup průběhu rešerše je patrný z uvedeného diagramu.



Obrázek 3. Diagram průběhu systematické rešerše

3.1.1 Nalezené články

V následujících tabulkách jsou uvedeny parametry vyhledávání a výsledné počty nalezených článků pro kategorie strojové učení a expertní systémy v jednotlivých letech 2013 – 2017.

Tabulka č. 6 obsahuje parametry vyhledávání pro strojové učení v citační databázi ScienceDirect a přehled nalezených a vybraných článků.

Tabulka 6. Strojové učení – ScienceDirect

Citační databáze	ScienceDirect	
Klíčová slova	machine learning, healthcare, medicine	
Pole	title, abstract, keywords	
Typ	research article, review article	
Rok	Nalezeno	Vybráno
2013	12	7
2014	16	10
2015	30	18
2016	40	32
2017	69	44

V tabulce č. 7 jsou výsledky pro stejnou kategorii, ale citační databázi Web of Science.

Tabulka 7. Strojové učení – Web of Science

Citační databáze	Web of Science	
Klíčová slova	machine learning, healthcare, medicine	
Pole	topic, title	
Typ	article, review	
Rok	Nalezeno	Vybráno
2013	60	38
2014	102	50
2015	132	79
2016	207	126
2017	308	184

Články, které byly z výběru vyřazeny, buď nesplňovaly předpoklad použití umělé inteligence (například byly pojmy strojové učení a umělá inteligence obecně jen zmíněny v abstraktu, ale v článku se s nimi dál nepracovalo) anebo se nejednalo o využití ve zdravotnictví. Z počtu článků je patrný značný nárůst aplikací strojového učení ve

zdravotnictví. Na rozdíl od roku 2013 je počet relevantních článků v roce 2017 pětinasobný. Růst můžeme sledovat na grafu č. 1 a ve srovnání s expertními systémy na grafu č. 3.

V tabulce č. 8 jsou uvedeny součty vybraných relevantních článků ke strojovému učení v obou databázích v jednotlivých letech po odstranění duplicit. Celkový počet článků byl 486.

Tabulka 8. Machine learning – součet článků z databází po odstranění duplicit

Rok	Po odstranění duplicit
2013	39
2014	51
2015	80
2016	121
2017	195
Celkem	486

V tabulce č. 9 jsou uvedeny parametry vyhledávání a výsledky pro Expertní systémy v citační databázi ScienceDirect.

Tabulka 9. Expertní systémy – ScienceDirect

Citační databáze	ScienceDirect	
Klíčová slova	expert system, knowledge based, decision support system, healthcare, medicine	
Pole	title, abstract, keywords	
Typ	research article, review article	
Rok	Nalezeno	Vybráno
2013	49	16
2014	52	21
2015	55	15
2016	54	14
2017	81	23

Tabulka č. 10 je opět věnována vyhledávání článků o expertních systémech, ale pro databázi Web of Science.

Tabulka 10. Expertní systémy – Web of Science

Citační databáze	Web of Science	
Klíčová slova	expert system, knowledge based, decision support system, healthcare, medicine	
Pole	topic, title	
Typ	article, review	
Rok	Nalezeno	Vybráno
2013	130	18
2014	144	26
2015	188	30
2016	192	45
2017	225	61

Stejně jako v předchozím případě se zde hodnotilo, zda se v článcích přímo využívají metody umělé inteligence a zda aplikace souvisí se zdravotnictvím. U expertních systému bylo vyřazeno větší množství článků. Důvodem je již zmíněná skutečnost, že expertní systémy (nebo decision support systémy – systémy pro podporu rozhodování) jsou často založeny na metodách, které jako umělou inteligenci neoznačujeme.

I u expertních systémů můžeme sledovat nárůst počtu relevantních článků, je ovšem mnohem mírnější než v případě strojového učení.

V tabulce č. 11 jsou uvedeny počty článků v kategorii expertních systémů pro obě citační databáze po odstranění duplicit. Celkový počet článků za období 2013 – 2017 byl 203.

Tabulka 11. Expertní systémy – součet článků z databází po odstranění duplicit

Rok	Po odstranění duplicit
2013	30
2014	31
2015	34
2016	50
2017	58
Celkem	203

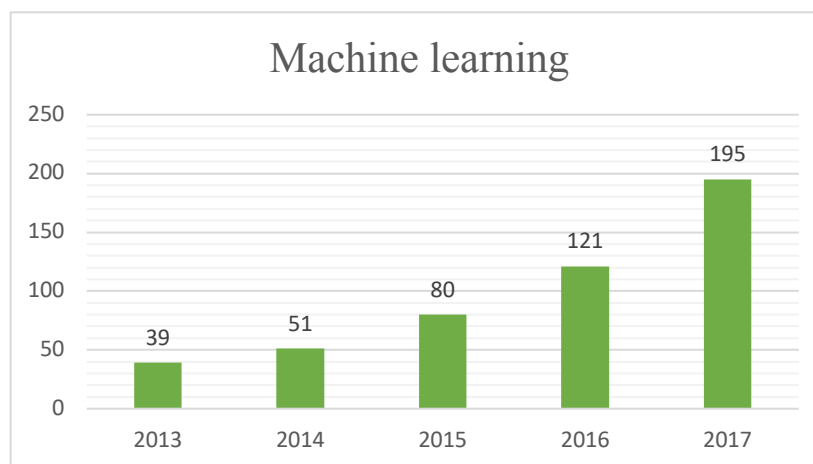
V následující tabulce jsou pro srovnání uvedeny počty článků pro obě kategorie.

Tabulka 12. Machine learning a Expert systems – souhrn nalezených článků

Rok	Machine learning	Expert systems
2013	39	30
2014	51	31
2015	80	34
2016	121	50
2017	195	58
Celkem	486	203

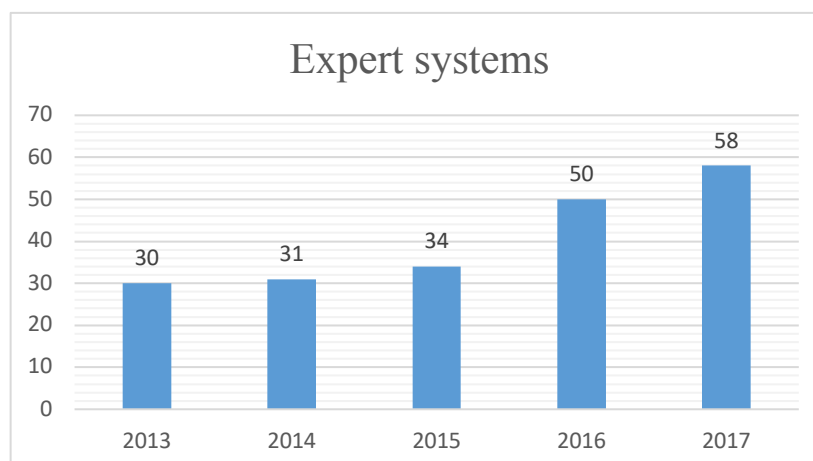
Data získaná pomocí systematické rešerše jsou dále uvedena v grafech. Graf č. 1 zobrazuje nárůst počtu relevantních článků v letech 2013 – 2017 pro machine learning.

Graf 1. Machine learning – množství nalezených článků v letech 2013 – 2017



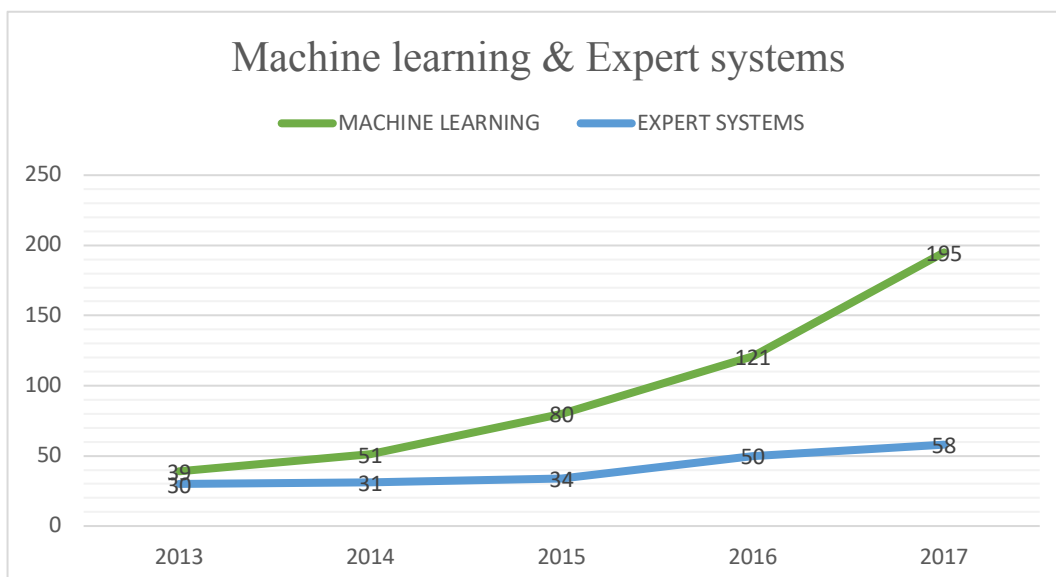
Graf č. 2 zobrazuje počty článků v kategorii expertních systémů.

Graf 2. Expert systems – množství nalezených článků v letech 2013 – 2017



Z obou grafů je patrné, že význam strojového učení i expertních systémů ve zdravotnictví roste. Jak je ale viditelné z grafu č. 3, který se nachází níže, růst počtu publikovaných článků na téma strojové učení ve zdravotnictví je mnohem prudší. Ačkoliv jsou expertní systémy jako odvětví umělé inteligence přítomné již od 70. let minulého století a mají tedy značnou historii a stabilní zakotvení [39] a ve zdravotnictví mají nepochybně své místo, nedostává se jim zdaleka tolik pozornosti jako strojovému učení. Důvodů pro tento rozdílný růst může být mnoho. Jedním z nich je ale nepochybně pozornost, která je aplikacím strojového učení v posledních letech věnována. Tato oblast prožívá tzv. *technologický hype* [40], tzn. nachází se ve fázi značného růstu nebo na jeho vrcholu a jsou s ním spojena vysoká očekávání.

Graf 3. Machine learning a Expert systems – vztah počtu nalezených článků



3.1.2 Analýza četnosti slov

V dalším kroku byla na vyhledaných člancích provedena analýza četnosti dvojic slov. Tato základní textová analýza může sloužit k odhalení důležitých faktorů, které oblast ovlivňují a hledání spojitostí v jednotlivých studiích. Analýza probíhala na 10 skupinách, tj. strojové učení a expertní systémy v pěti po sobě jdoucích letech. Četnosti byly zjišťovány z textových souborů obsahujících název a abstrakt článku. Z nalezených dvojic slovy byla odstraněna klíčová slova, obecné pojmy, případně nesmyslná nebo

nevýznamná slovní spojení. Prezentováno je zde vždy pět nejčastějších pojmů v každé kategorii. Vysoký výskyt nalezených slovních spojení v jednotlivých letech naznačuje význam těchto pojmů.

V tabulce č. 13 jsou znovu uvedeny počty analyzovaných článků v jednotlivých letech.

Tabulka 13. Počet analyzovaných článků v jednotlivých letech

Rok	Machine learning	Expert systems
2013	39	30
2014	51	31
2015	80	34
2016	121	50
2017	195	58

V tabulce č. 14 je uvedeno vždy pět nejčastěji se objevujících slovních spojení v jednotlivých kategoriích za příslušný rok.

Tabulka 14. Nejčastější pojmy v jednotlivých kategoriích

Machine learning		Expert systems		
Rok	Slovní spojení	Počet	Počet	
2013	learning algorithms	9	computerized decision	9
	emergency department	7	paper-based guideline	9
	clinical data	6	search engine	8
	predictive models	5	clinical protocol	6
	computational models	5	nursing documentation	5
2014	text classification	10	clinical decision	14
	social media	9	expert systems	9
	learning algorithms	9	bayesian network	7
	classification models	8	neural network	7
	anatomical structures	7	clinical data	6
2015	emergency department	12	expert systems	8
	electronic health	12	data mining	8
	predictive modeling	11	clinical decision	8
	data mining	10	bayesian network	6
	big data	9	big data	6
2016	clinical data	16	clinical decision	32
	electronic health	16	electronic health	18

	Machine learning		Expert systems	
Rok	Slovní spojení	Počet	Slovní spojení	Počet
	big data	14	health record	11
	neural network	14	clinical data	10
	stem cell	14	domain knowledge	10
2017	big data	40	clinical decision	25
	neural network	25	breast cancer	14
	precision medicine	25	decision making	8
	deep learning	21	desease diagnosis	8
	clinical decision	18	electronic health	7

Významné pojmy *learning algorithms* nebo *text classification* v kategorii machine learning nebudou žádným překvapením, stejně tak jako *computerized* nebo *clinical decision* v kategorii expertních systémů. Tyto pojmy odpovídají charakteru využití těchto technologií. Důležité jsou také pojmy *electronic health record*, tedy elektronický zdravotní záznam. Právě tato data jsou cennými vstupními zdroji pro fungování těchto technologií.

Co ale považuji za velmi zajímavé je výskyt pojmů *big data* a *data mining* napříč oběma kategoriemi v pozdějších letech. Právě zpracovávání velkých objemů dat je jedním z hlavních důvodů proč používat umělou inteligenci, jak je zmíněno i v teoretickém úvodu k této práci, a proč má umělá inteligence tak velký potenciál. Důležité jsou i pojmy *neural network*, tedy neuronové sítě a *deep learning* (hluboké učení, které bylo rovněž zmíněno v teoretickém úvodu k umělé inteligenci). Podrobné vysvětlení těchto pojmů přesahuje možnosti tohoto textu, ale s určitostí můžeme říct, že všechny výše zmíněné techniky souvisejí se značným rozmachem použití umělé inteligence jako celku. A oblast zdravotnictví není výjimkou.

3.1.3 Analýza zdrojů nalezených článků

Dalším krokem bylo zjištění, v jakých časopisech byly vybrané články publikovány. Články z kategorie strojové učení byly publikovány celkem v 281 časopisech, u expertních systémů to bylo 118. V každém sledovaném roce byly vybrány tři časopisy s největším počtem nalezených článků s danou tematikou. Nakonec je vyhodnoceno pět nejvýznamnějších časopisů pro strojové učení i expertní systémy. Díky této informaci je

možné se při periodickém provádění horizon scanning zaměřit na určité zdroje u kterých předpokládáme větší množství vyskytujících se relevantních studií.

V tabulce č. 15. jsou uvedeny tři nejčastější zdroje článků pro téma strojové učení v jednotlivých letech.

Tabulka 15. Machine learning – top 3 časopisy v jednotlivých letech

Machine learning		
Rok	Časopis	Počet
2013	PLOS ONE	3
	Artificial Intelligence in Medicine	3
	Medical Physics	2
2014	Journal of Biomedical Informatics	5
	Medical Physics	3
	Artificial Intelligence in Medicine	2
2015	Journal of Biomedical Informatics	4
	Medical Physics	3
	Ultrasound in Medicine and Biology	3
2016	Journal of Biomedical Informatics	7
	Medical Physics	4
	Journal of the American Medical Informatics Association	3
2017	Journal of Biomedical Informatics	8
	Medical Physics	7
	PLOS ONE	7

V tabulce 16. na následující straně vidíme pět nejčastějších časopisů za celé období 2013 – 2017 pro machine learning. Nejčastějším zdrojem byl v této kategorii Journal of Biomedical Informatics.

Tabulka 16. Machine learning – top 5 časopisů za sledované období 2013 – 2017

Machine learning		
Rok	Časopis	Počet
2013 - 2017	Journal of Biomedical Informatics	24
	Medical Physics	19
	PLOS ONE	12
	Journal of the American Medical Informatics Association	11
	Artificial Intelligence in Medicine	10

V následující tabulce jsou opět uvedeny tři nejčastější zdroje článků u jednotlivých let, tentokrát pro kategorii expertní systémy.

Tabulka 17. Expert systems – top 3 časopisy v jednotlivých letech

Expert systems		
Rok	Časopis	Počet
2013	Artificial Intelligence in Medicine	6
	Decision Support systems	3
	Journal of Biomedical Informatics	3
2014	Journal of Biomedical Informatics	3
	Knowledge-based Systems	2
	Journal of Evaluation in Clinical Practice	2
2015	Artificial Intelligence in Medicine	4
	Computers in Biology and Medicine	2
	Expert Systems with Applications	2
2016	Procedia Computer Science	5
	Artificial Intelligence in Medicine	3
	Journal of Biomedical Informatics	2
2017	Journal of Biomedical Informatics	4
	Procedia Computer Science	2
	Computer Methods and Programs in Biomedicine	2

V tabulce č. 18 je pak seznam pěti nečastějších zdrojů článků za celé období Pro expertní systémy je nejčastějším zdrojem relevantních článků časopis Artificial Intelligence in Medicine.

Tabulka 18. Expert systems – top 5 časopisů za sledované období 2013 - 2017

Expert systems		
Rok	Časopis	Počet
2013 - 2017	Artificial Intelligence in Medicine	14
	Journal of Biomedical Informatics	12
	Procedia Computer Science	9
	Decision Support Systems	6
	Knowledge-based systems	5

Výsledky této analýzy značí, že se momentálně články související se strojovým učením a expertními systémy nesdružují do nějaké úzké skupiny časopisů, ale objevují se v mnoha různých zdrojích. I přesto, ale můžeme zdroje s největším nalezeným počtem článků považovat za významné a v případě, že chceme nějakou problematiku sledovat pravidelně, je vhodné se na ně zaměřit.

3.1.4 Tematické oblasti vyhledaných článků

V následujících tabulkách jsou v rešerši nalezené články rozděleny podle oborů medicíny, ve kterém je daná technologie aplikována. V tabulkách jsou uvedeny počty přiřazených článků v každé kategorii. Pokud nebylo možné jednoznačně určit příslušný obor medicíny, nachází se článek v kategorii *nezařazeno*. Do této kategorie spadají také všechny studie, které mají obecný charakter, tedy například využití umělé inteligence pro tvorbu univerzálního decision support systému. Poměrné množství nezařazených článků v kategorii expertních systémů je větší než v kategorii strojového učení právě z toho důvodu, že byla podstatná část studií obecného charakteru. Expertní systémy se tady využívají jako podpora rozhodování, pro predikci onemocnění, jako pomoc při zdravotnickém managementu a podobně. Neomezují se tedy na konkrétní oblast medicíny, ale mají širší využití. Články využívající umělou inteligenci v kategorii strojové učení se naproti tomu často úzce specializují na určitou oblast nebo úlohu.

Barevně jsou v tabulkách vyznačena pole se třemi nejčastějšími hodnotami výskytu v každém roce. V tabulce č. 19 jsou rozděleny články podle oboru medicíny pro kategorii expertní systémy.

Tabulka 19. Expertní systémy – rozdělení nalezených článků podle oblastí medicíny

Obor medicíny	2013	2014	2015	2016	2017	celkem
biochemie	1	1	0	1	1	4
farmakologie	3	0	0	1	1	5
gastroenterologie	1	2	1	0	6	10
genetika	1	0	0	1	0	2
infektologie	0	0	1	1	0	2
kardiologie	1	5	3	4	2	15
mikrobiologie	0	0	1	1	0	2
nefrologie	0	1	1	2	0	4
neurologie	1	1	1	1	2	6
oftalmologie	0	0	0	1	0	1
onkologie	3	1	3	5	11	23
ortopedie	0	1	1	0	1	3
patologie	1	0	1	0	1	3
pneumologie a alergologie	1	3	2	1	0	7
psychologie	3	0	1	2	1	7
radiologie a zobr. metody	2	1	2	0	1	6
stomatologie	0	0	0	2	0	2
urgentní medicína	2	1	1	3	3	10
nezařazeno	10	14	15	24	28	91
celkem	30	31	34	50	58	203

Z analýzy je patrné, v jakých oblastech medicíny byla daná technologie aplikována nejčastěji. Sledovat můžeme i vývoj v jednotlivých letech.

Pro expertní systémy byly zjištěny jako významné oblasti onkologie, kardiologie, gastroenterologie a urgentní medicína. Důležitá je také skutečnost, že téměř polovinu článků nebylo možno konkrétně přiřadit k žádnému z oborů. Velkou část této skupiny tvořily decision support systémy s širším záběrem, nástroje pro personalizovanou medicínu, nástroje pro pomoc s určováním diagnóz a podobně.

V tabulce č. 20 se nacházejí data pro skupinu strojové učení.

Tabulka 20. Strojové učení – rozdělení nalezených článků podle oblastí medicíny

Obor medicíny	2013	2014	2015	2016	2017	celkem
biochemie	0	2	2	3	5	12
dermatologie	0	1	0	0	1	2
farmakologie	1	3	6	5	8	23
gastroenterologie	1	3	4	6	5	19
genetika	5	0	2	6	10	23
geriatrie	0	0	0	0	1	1
gynekologie	1	1	0	0	0	2
hematologie	0	0	0	0	2	2
hematologie	0	0	0	0	3	3
imunologie	0	0	1	0	2	3
infektologie	2	0	1	3	7	13
kardiologie	2	4	3	6	10	25
mikrobiologie	2	0	1	3	6	12
nefrologie	0	0	0	3	1	4
neurologie	4	4	5	6	8	27
oftalmologie	0	2	1	1	4	8
onkologie	3	4	10	16	23	56
ortopedie	0	0	1	2	0	3
patologie	0	0	1	1	0	2
pneumologie a alergologie	2	2	5	3	8	20
psychologie	1	2	4	6	12	25
radiologie a zobr. metody	2	2	6	9	15	34
urgentní medicína	2	1	4	4	5	16
nezařazeno	11	20	23	38	59	151
celkem	39	51	80	121	195	486

V kategorii strojové učení byly významné obory onkologie, radiologie a zobrazovací metody a neurologie. Za zmínku stojí ale i další obory, jako psychologie, kardiologie, farmakologie nebo genetika. Nezařazených článků je v tomto případě poměrně méně, než jak tomu bylo u expertních systémů.

Obě technologie spolu úzce souvisejí a nelze je hodnotit úplně zcela samostatně. Metody využívané v tzv. expertních systémech se se strojovým učení často prolínají.

I když jsou expertní systémy i strojové učení podoblasti umělé inteligence, jsou mezi nimi významné odlišnosti. Strojové učení představuje oblast datově intenzivních metod, zatímco expertní systémy jsou znalostně intenzivní. Expertní systémy pracují s bázi

znalostí. Cílem je obsáhnout široké množství informací a znalostí, se kterými expertní systém pracuje. Metody strojového učení zpravidla vycházejí z velkého souboru vstupních dat, na kterých se nejdříve naučí a následně mohou klasifikovat nová vstupní data.

V následující části jsou uvedeny příklady využití strojového učení a expertních systémů ve zdravotnictví právě na základě analýzy oblastí medicíny.

3.1.5 Příklady studií pro strojové učení

Onkologie

Články zabývající se strojovým učením v oblasti onkologie se velmi často věnovaly predikcím, jak je vidět na uvedených příkladech.

Machine Learning Prediction of Cancer Cell Sensitivity to Drugs Based on Genomic and Chemical Properties [41]

Autoři: Menden M. P., Iorio F., Garnett M. et al.

Studie se zabývá predikváním odpovědi určitých typů rakoviny na léčbu. Metoda prezentovaná v této studii je založena na strojovém učení a kombinuje předpověď založenou na genomických vlastnostech buněčných linií a na chemických vlastnostech uvažovaných léčiv.

Big Data Analytics Using Neural Networks for Earlier Cancer Detection [42]

Autoři: Ahmed A. Shah M. A., Wahid A.

V této studii autoři předkládají několik algoritmů strojového učení, které slouží k předpovědi a analýze rakoviny v počátečních fázích. Popisují výběr, trénování a klasifikaci dat při použití různých neuronových sítí.

Predicting cancer type from tumour DNA signatures [43]

Autoři: Soh K.P., Szczurek E., Sakoparnig T.

Autoři zde pracují s údaji o změnách genu z nádorové DNA při identifikaci typů rakoviny. Používají tři techniky strojového učení ve snaze přinést diagnostický nástroj pro predikci typu rakoviny.

Radiologie a Zobrazovací metody

Strojové učení v oblasti radiologie a zobrazovacích metod má velký potenciál v klasifikaci a detekci nálezů. Aby bylo vůbec možné pro tyto účely strojové učení využít, slouží strojové učení i pro anonymizaci vstupních dat.

A De-Identification Pipeline for Ultrasound Medical Images in DICOM Format [44]

Autoři: Monteiro E., Costa C., Oliveira J.

V této studii je navrhován postup pro anonymizaci citlivých patientských údajů přítomných v DICOM formátu ultrazvukové dokumentace. Algoritmus strojového učení zde slouží k nalezení a anonymizaci těchto citlivých údajů, aby bylo možné obrazovou dokumentaci dále používat a sdílet.

A Machine-Learning Algorithm Toward Color Analysis for Chronic Liver Disease Classification, Employing Ultrasound Shear Wave Elastography [45]

Autoři: Gatos I., Tsantis S., Spiliopoulos S. et al.

V článku je prezentován diagnostický systém pro klasifikaci chronického onemocnění ledvin za pomoci obrazů získaných z dynamické elastografie (shear wave elastography) a metod strojového učení.

Intelligent and automatic in vivo detection and quantification of transplanted cells in MRI [46]

Autoři: Afridi M., Ross A., Liu X. et al.

Tato studie se zabývá sledováním transplantovaných buněk pomocí magnetické rezonance. Magneticky označené mesenchymální kmenové buňky byly transplantovány do mozku potkanů, kde byly za pomoci metod strojového učení detekovány.

Neurologie

Strojové učení v neurologii se orientuje zejména na diagnostiku onemocnění. Vedle zpracování obrazových dat, podobně jako je tomu u radiologie a zobrazovacích metod, do strojového učení v neurologii vstupují další data. Příkladem mohou být data ze sociálních sítí, záznamy pohybu a podobně.

Machine learning and social network analysis applied to Alzheimer's disease biomarkers [47]

Autoři: Di Deco J., González A., Díaz J. et al.

V článku je prezentován postup pro odhalování Alzheimerovy choroby pomocí strojového učení na datech získaných pomocí magnetické rezonance a Social Network analysis, která sleduje vztahy.

Machine learning-based classification of simple drawing movements in Parkinson's disease [48]

Autoři: Kotsavasiloglou C., Kostikis N., Hristu-varsakelis D., Arnaoutoglou, M.

Tato práce se zabývá studiem rozdílů pohybů rukou a koordinací svalů mezi zdravými subjekty a pacienty s Parkinsonovou chorobou. K tomu zde využívají jako základní pomůcku pero a tablet. Metodami strojového učení zde rozlišují mezi normálním a patologickým pohybem rukou, na základě kreslených vodorovných čar.

Wavelet Features for Recognition of First Episode of Schizophrenia from MRI Brain Images [49]

Autors: Dluhos P., Schwarz D., Kasperek T.

V tomto článku je prezentováno schéma pro rozpoznávání a klasifikaci schizofrenie ze snímků pořízených magnetickou rezonancí na základě vlnových funkcí zpracovávaných strojovým učením.

3.1.6 Příklady studií pro expertní systémy

Onkologie

Expertní systémy v onkologii mají za úkol zejména poskytovat podporu při rozhodování v diagnostice onemocnění a optimalizaci plánování terapie.

Computer-Assisted Decision Support System in Pulmonary Cancer detection and stage classification on CT images [50]

Autoři: Masood A., Sheng B., Li P. et al.

V této práci autoři navrhnou Computer-Assisted Decision Support systém pro detekci a klasifikaci karcinomu plic. Používají přitom model založený na hlubokém učení a informace o metastázách získané z wearables.

Clinical decision support of radiotherapy treatment planning: A data-driven machine learning strategy for patient-specific dosimetric decision making [51]

Valdes G., Simone Ch. B., Chen J. et al.

V článku je prezentován systém pro podporu rozhodování při plánování radioterapie.

CT Image-based Decision Support System for Categorization of Liver Metastases Into Primary Cancer Sites [52]

Ben-Cohen A., Klang E., Diamant I. Et al.

Zde je navrhován systém na podporu rozhodování pro přiřazování metastáz k jejich primárnímu zdroji. Vstupními daty jsou CT snímky.

Kardiologie

V kardiologii se expertní systémy využívají k podpoře diagnostiky onemocnění a klasifikaci.

ECG assessment based on neural networks with pretraining [53]

Autoři: Ribas V. J., Wojdel A., Romero E. et al.

Zde je prezentována nová screeningová metoda, která pomáhá rozhodovat, zda by měl být pacient z ambulantní nebo urgentní péče odeslán ke kardiologickému vyšetření. Využívá k tomu hluboké neuronové sítě, pro kterou jsou vstupní data EKG signály.

Fuzzy Soft Expert System in Prediction of Coronary Artery Disease [54]

Autoři: Hassan N., Sayed O., Khalil A. et al.

V této studii autoři vyvinuli knowledge-based systém na predikci ischemické choroby srdeční z dat: systolický krevní tlak, LDL cholesterol, maximální tepová frekvence, a krevní cukr.

Ontology Driven Controlled Natural Language Clinical Decision Support System for the Cardiovascular Specialty [55]

Autoři: Mendes D., Rodrigues I. P., Baeta C. F.

V článku je prezentován systém založený na zpracování přirozeného jazyka, který má sloužit jako znalostní databáze pro lékaře se zaměřením na kardiiovaskulární medicínu.

Urgentní medicína

Expertní systémy se v této kategorii zaměřují zejména na optimalizaci chodu pracovišť, plánování, diagnostiku nebo řazení činností podle priorit.

A Multi-Agent Based Modeling and Simulation Data Management and Analysis System for the Hospital Emergency Department [56]

Autoři: Saoud S., Boubetra, A., Attia S.

V tomto článku je prezentován výzku, který využívá multiagentní systémy a data mining techniky pro vytvoření systému na podporu rozhodování v rámci urgentního oddělení.

Predicting frequent emergency department visits among children with asthma using EHR data [57]

Autoři: Das L. T., Abramson E., Stone A. E., et al.

Autoři ve studii navrhují systém, který na základě elektronických zdravotnických dat napomáhá predikovat možnost časté návštěvy pohotovostního oddělení u dětí s astmatem.

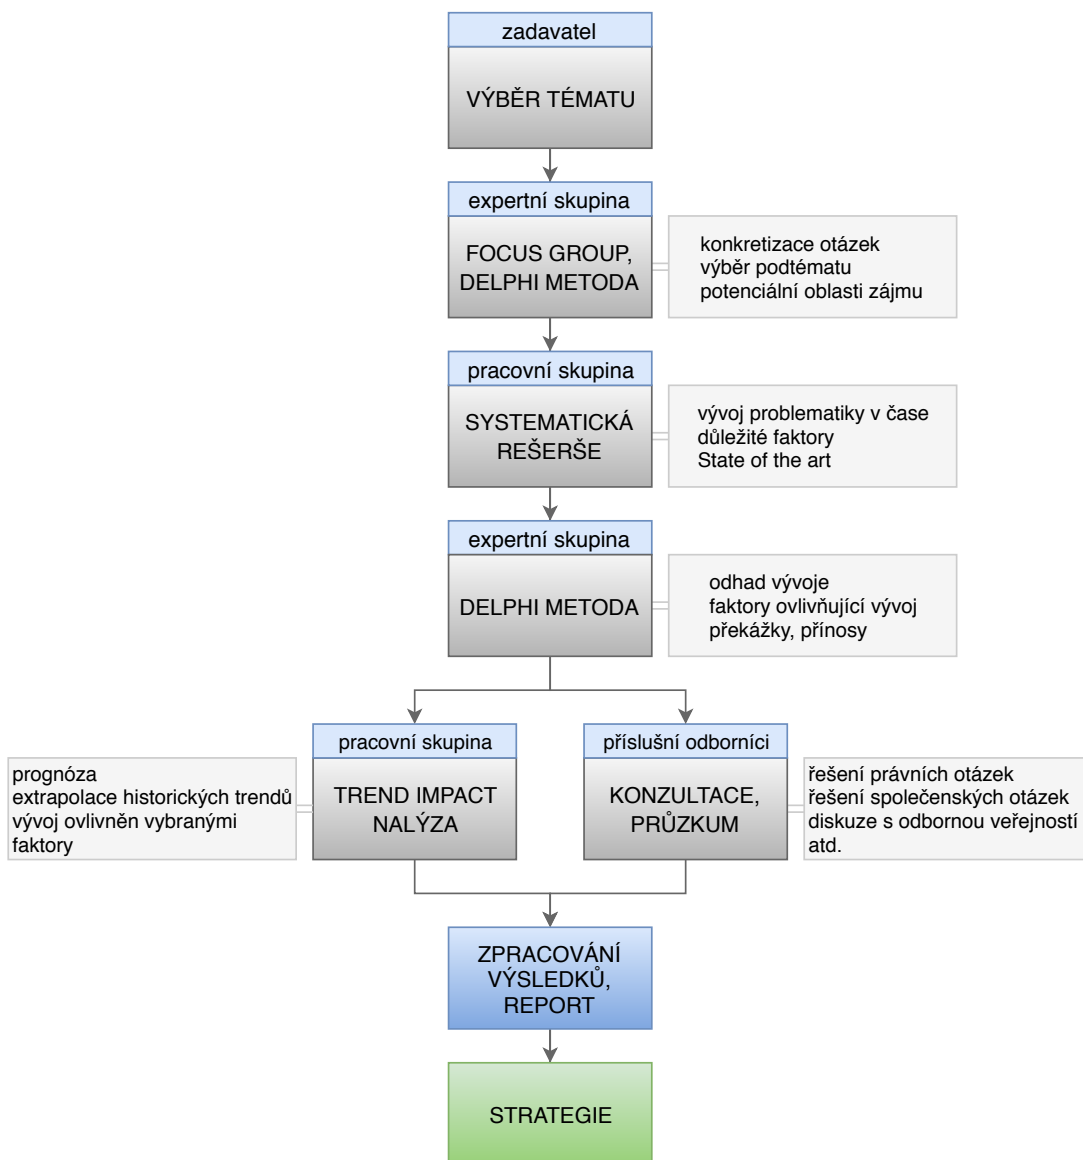
A Simulation Knowledge Extraction-based Decision Support System for the Healthcare Emergency Department [58]

Autoři: Sauod M., Boubetra A., Attia S.

Ve této studii je řešen systém pro podporu rozhodování a plánování v rámci oddělení urgentního příjmu. Systém zpracovává dostupná data o personálu, pacientech, časové údaje apod. ve snaze zefektivnit činnost urgentního příjmu.

3.2 Návrh metodiky pro foresight

Na základě studia vybraných metod pro odhadování budoucího vývoje technologií a studia problematiky umělé inteligence byl vytvořen obecný postup pro provádění foresightu v této oblasti. Postup je aplikovatelný na sledování vývoje technologií nejen úzce souvisejících s umělou inteligencí.



Obrázek 4. Diagram navrhovaného postupu pro foresight

Provádění odhadu vývoje technologií vyžaduje nemalé časové a lidské zdroje. Esenciální je ustanovení stabilní **expertní skupiny**, která bude splňovat určené požadavky a bude k dispozici pro všechny potřebné úseky prováděného foresightu. Žádoucí je také možnost provádět foresight periodicky.

Dále je zapotřebí tzv. **pracovní skupina**, která má za úkol zpracovávání všech dílčích částí, jako je příprava protokolů, komunikace s odborníky, zpracovávání výsledků. Významnou roli má také v provádění systematické rešerše a analýzy.

Nepostradatelnou součástí této metodiky je také spolupráce s externími **odborníky**, kteří jsou schopni zodpovědět otázky společenského, právního či jiného charakteru, které v souvislosti s inovativními technologiemi přicházejí.

Postup sestává z několika na sebe navazujících metod, tak jak jsou vyjádřeny v diagramu na obrázku č. 3 (diagram navrhovaného postupu pro foresight).

1. **Výběr tématu:** V tomto kroku zadavatel (kterým může být například jednotlivec, organizace, vláda atd.) určí téma, kterým se bude studie zabývat. Určí také časový horizont, případně zda se bude studie provádět periodicky.
2. **Focus group, Delphi metoda:** V druhém kroku expertní skupina konkretizuje otázky, které budou předmětem sledování. Problematika inovativních technologií bývá natolik složitá a rozsáhlá, že je zapotřebí už v těchto prvotních fázích odhadu identifikovat podstatné oblasti.
3. **Systematická rešerše:** Zde pracovní skupina na základě informací, které jí poskytl panel expertů, vypracuje rešerši literatury. Ta má zmapovat současnou situaci, odhalit důležité faktory vývoje, hlavní oblasti využití technologie a další sledované parametry. Tyto získané informace jsou využity v následujících krocích.
4. **Delphi metoda:** V tomto kroku je za pomoci expertní skupiny provedena Delphi studie, která se má soustředit na odhad vývoje v dalších letech. Dále jsou identifikovány faktory ovlivňující vývoj a implementaci technologie, její přínosy, možná rizika, bariéry pro její vstup.
5. a) **Trend impact analýza:** Na tomto místě je na základě informací zjištěných z předchozích kroků (faktory ovlivňující vývoj ze systematické rešerše a Delphi studie) provedena TIA nebo jiná kvalitativně-quantitativní analýza. Ta slouží k predikci vývoje v určitém časovém horizontu v závislosti na zjištěných faktorech, které mohou vývoj ovlivnit.

b) **Konzultace s externími odborníky:** Během studia problematiky vývoje inovativní technologie se nepochybně začnou objevovat otázky zejména společenského a právního charakteru. Toto je typické pro tzv. *disruptive innovations*

(nebo *disruptive technologies*) [59], tedy inovace, které nepředpokládaným způsobem radikálně změní stávající technologie. Včasné a důsledné řešení této problematiky je nezbytnou součástí přípravy na novou technologii a její adaptaci.

6. **Zpracování výsledků:** V tomto kroku jsou získané informace pracovní skupinou zanalyzovány a přehledně zpracovány pro další použití.
7. **Tvorba strategie:** Samotné provedení foresightu nemá příliš smysl, pokud výsledky z něj získané nemáme v úmyslu dál využít. Logicky navazujícím krokem je tedy tvorba strategie, která má informace o možném vývoji využít pro plánování, přípravu a začleňování nové technologie.

4 Diskuze

V této práci byla zkoumána problematika metod pro odhadování vývoje nových a inovativních technologií ve zdravotnictví.

Důležitost sledování vývoje inovativních tchnologií ve zdravotnictví neunikla ani Ministerstvu zdravotnictví ČR, které ve své tiskové zprávě ze zasedání přístrojové komise ze dne 11. 4. 2018 [60] zmiňuje zájem zavést mechanismus „horizon scanning“, který by kontinuálně monitoroval vývoj nákladných přístrojových technologií s horizontem pěti let. Technologický foresight může přinést cenné poznatky o nových technologiích, jejich potenciálních dopadech na zdravotní systém a pomáhá tak včasné reakci na přicházející změny.

Úvodní část práce se věnovala teorii foresightu a vybraným metodám pro provádění odhadu vývoje. Hodnoceny byly metody: horizon scanning, delphi metoda, metoda tvorby scénářů a trent impact analýza.

Hodnocením těchto metod byly přiblíženy jejich vlastnosti, výhody a nevýhody jejich použití. Zvláštní pozornost byla dále věnována delphi metodě, která byla na základě zjištěných vlastností vybrána nako jedna ze stěžejních metod pro sestavování modelu foresightu, prezentovaného v této práci. Důvodem výběru metody byl jednak její kvalitativní až semi-kvantitativní přístup k problematice, který umožňuje diskutovat i témata se značnou nejistotou. Dalším velkým pozitivem této metody je její forma, tzn. přehledné dotazníky, které jsou distribuovány pomocí internetu. Hlavním rysem delphi metody je to, že je založena na komunikaci skupiny expertů. Tato skutečnost je v mnoha ohledech obrovskou výhodou, neboť vyvoláním kontrolované odborné debaty a kombinací názorů můžeme získat odpovědi i na velmi složité otázky. Ovšem co je hlavní výhodou této metody se zároveň jeví i jako její největší úskalí, jak je zmíněno v dalších částech diskuze. Zejména se jedná o náročnost provedení metody a sestavení stabilní expertní skupiny.

Po provedení analýzy metod byly poznatky využity k navržení modelu pro provádění foresightu na téma nových a inovativních technologií. Původní představa byla navrhnout postup pro foresight pouze pro vybranou technologii – umělou inteligenci – avšak ukázalo se, že má metodika natolik obecný charakter, že se dá využít i pro sedování jiné inovativní technologie ve zdravotnictví. V kapitole 3.2 je tento návrh uveden. Jedná se o poměrně obsáhlý model, rozdělený do sedmi na sebe navazujících úrovní. Jak se ukázalo,


problematika odhadování vývoje inovativních technologií se nedá efektivně řešit pomocí prostého výběru nejvhodnější metody a její aplikace. Z navrhovaného postupu vychází, že foresight v oblasti inovativních technologií je spojením mnoha kroků od výběru a konkretizace otázek, mapování současné situace, hodnocení důležitých faktorů, přes samotný odhad vývoje a tvorbu prognózy až po tvorbu strategie. Z toho důvodu byla v této práci řešena obsáhlá rešerše, která má pro navržený foresight důležitý význam. Přináší nezbytné informace, na které je vhodné navázat dalšími kroky, jak je navrženo ve vytvořené metodologii.

Realizace navrhovaného postupu předpokládá značné časové i personální možnosti. Na foresightu se podílí tři důležité skupiny osob.

- Skupina pracovní, která má za úkol zpracování systematické rešerše, práci na trend impact analýze a zpracování všech dílčích informací v průběhu foresightu.
- Skupina externích odborníků zaměřených na problematiku společenskou, právní, případně jinou. To má velký vliv právě v oblasti inovativních technologií, které jsou často nesprávně prezentovány veřejnosti, problematicky se vypořádávají se zavedenými zvyklostmi, právními otázkami a podobně. Konzultace s těmito odborníky je klíčová pro tvorbu strategie.
- Expertní skupina pro potřeby delphi metody. V tomto kroku se ukazuje stinná stránka delphi metody. Sestavení expertní skupiny je totiž složité a vyžaduje značné množství času a prostředků. Stabilita výsledné skupiny je navíc velmi nejistá. Pro správné provádění foresightu je potřeba věnovat sestavení expertní skupiny značnou pozornost a pokud možno utvořit ji tak, aby byla schopna se tématice věnovat periodicky.

Navržen byl komplexní model foresightu pro oblast inovativních technologií, ale v této práci byla uskutečněna jen jeho malá část. Důvodem je skutečnost, že aplikace všech dalších částí tohoto postupu, které následují po systematické rešerši, vyžaduje velké množství času a prostředků. V prvé řadě je zapotřebí stabilní expertní panel s dostatečným množstvím odborníků. Neméně důležité jsou i další skupiny osob zapojených do foresightu. I se zapojením těchto skupin se proces sledování vývoje technologií počítá v řádech měsíců.

Systematická rešerše byla provedena na vybraných oblastech umělé inteligence: strojové učení a expertní systémy (ve spojení se zdravotnictvím). Prohledávány byly citační databáze ScienceDirect a Web of Science v jednotlivých letech 2013 – 2017. Detailní výsledky vyhledávání jsou dostupné v tabulkách č. 6 – 12. Z počtu nalezených relevantních článků jsou patrné rostoucí tendence, zejména v oblasti strojového učení. Na tomto místě je příhodné uvést Gartnerův diagram pro *Hype cycle* [61], který znázorňuje fáze dospívání, adaptování a aplikování specifických inovativních technologií. Strojové učení (Machine learning), spolu s dalšími technologiemi umělé inteligence, se na tomto grafu nacházejí ve fázi vysokých očekávání.



Obrázek 5. Technologický Hype cycle pro rok 2017, Gartner. Zdroj: [61]

Na systematickou rešerši navazuje analýza nalezených článků. Nejříve byla provedena analýza četnosti dvojic slov a to v 10 skupinách, tj. pro strojové učení a expertní systémy vždy v jednotlivých letech 2013 – 2017. Tato textová analýza odhalila několik zajímavých pojmů, zejména v pozdějších letech. Těmito pojmy jsou *deep learning*, *neural networks*, *big data* a další. Tyto pojmy souvisejí s velkými objemy dostupných dat. Tato datová exploze se nevyhýbá ani zdravotnictví. A právě tyto objemy dat nemá potenciál smysluplně zpracovat nic jiného než umělá inteligence.

V dalším kroku byly analyzovány zdroje nalezených článků. Výsledky ukázaly, že se články nacházely napříč širokým spektrem periodik. Pro strojové učení to bylo 281 časopisů, pro expertní systémy 118 časopisů. V závěru bylo vyhodnoceno pět nejčastějších zdrojů pro každou skupinu. Ačkoliv výsledky přímo nepoukazují na vysokou koncentraci článků okolo úzké skupiny periodik, jistě se vyplatí v rámci foresightu časté zdroje článků dlouhodobě sledovat.

O tom, v jakých oblastech zdravotnictví se strojové učení a expertní systémy využívají, svědčí další analýza. Tentokrát byly k nalezeným článkům přiřazovány oblasti medicíny, ve kterých byly technologie aplikovány. Ne všechny články byly jednoznačně zařaditelné a zejména u skupiny expertních systémů se často objevovaly obecné systémy na podporu rozhodování, které se neomezovaly konkrétně na určitou oblast. Pro expertní systémy byly nejčastějšími obory onkologie, kardiologie, gastroenterologie a urgentní medicína. Pro strojové učení to byly onkologie, radiologie a zobrazovací metody a neurologie. V poslední fázi pak byly k nejčastějším oborům vybrány reprezentativní studie, které ilustrují využití umělé inteligence v praxi.

Na základě nalezených článků lze sledovat, že se využití umělé inteligence v medicíně často orientuje na diagnostiku onemocnění nebo jejich klasifikaci. Je to způsobeno právě dostupností velkého množství dat z různých zdrojů. Ať už se jedná o zdravotní záznamy, obrazová nebo laboratorní data, metodami umělé inteligence je možné ve velkých objemech dat hledat souvislosti. Extrémně důležité je i využívání dat, které mají s exaktními metodami medicíny zdánlivě jen málo společného. Příkladem může být studie *Machine learning and social network analysis applied to Alzheimer's disease biomarkers* [47] (kapitola 3.5.1), kde se mimo jiné využívají také data získaná ze sociálních sítí.

V kontextu všech zjištěných informací můžeme říci, že je umělá inteligence velice silným nástrojem pro zpracování dat, dostupných nejen ve zdravotnictví. Metody umělé inteligence jsou v současnosti na vzestupu a jejich potenciál se setrvale projevuje i v oblasti medicíny, kde nachází využití při řadě specializovaných úloh. Nepochybně je žádoucí, aby se vývoj umělé inteligence ve zdravotnictví pozorně sledoval. K tomu může sloužit například navrhovaný postup pro technologický foresight. Pro každé období je charakteristický vývoj v určité oblasti. V naší současnosti jsme konfrontováni s extrémním nárůstem využitelných dat a s novými, revolučními způsoby jejich zpracování. Umělá inteligence je potenciálně velice mocný nástroj, který už dlouho není

jen teorií. S každou novou technologií ale přicházejí výzvy a překážky, které je potřeba odhalovat včas. A právě k tomu je odhad budoucího vývoje nových a inovativních technologií nezbytný.

5 Závěr

Tato práce se soustředila na téma inovativních technologií a způsoby jejich odhadování, a to v souvislosti se zdravotnictvím. Bylo zde poukázáno na důležitost pojmu technologický foresight, který je klíčem pro včasnou adaptaci na přicházející technologie a tvorbu efektivních strategií pro jejich začleňování.

Cílem této práce bylo zanalyzovat vybrané metody pro odhad budoucího vývoje inovativních technologií a na základě těchto poznatků navrhnout metodiku pro odhad vývoje, aplikovatelnou na vybranou technologii ve zdravotnictví. Zformulovaný postup pro foresight obsahuje řadu konkrétních kroků, obecně jej lze ale aplikovat na široké spektrum sledovaných technologií.

Zkoumanou technologií v rámci této práce byla umělá inteligence. Na vybraných podtématech – strojové učení a expertní systémy – byla provedena rešeršní studie a výsledky byly následně analyzovány a zasazeny do souvislostí. Prohledáno bylo 1009 článků v rámci strojového učení a 1170 článků pro expertní systémy. Z toho bylo do studie zařazeno 486 článků pro strojové učení a 203 článků pro expertní systémy. Na základě hodnocení počtu článků byl zjištěn nárůst popularity těchto témat v souvislosti se zdravotnictvím v posledních letech. Analýza četnosti slov poukázala na významné pojmy vyskytující se v jednotlivých letech a také faktory, které mohou vývoj technologií ovlivňovat. Z další analýzy byl získán seznam zdrojů, ve kterých byly články nejčastěji publikovány, a tedy i seznam periodik potenciálně vhodých pro sledování v rámci foresightu. Hodnocením tématických oblastí nalezených článků vyšlo najevo, které oblasti medicíny jsou pro využití strojového učení a expertních systémů významné. Ke kategoriím pak byly přiřazeny příklady studií, dále přibližující konkrétní využití těchto technologií.

Provedením obsáhlé rešeršní studie a její analýzy byl zmapován vývoj vybraných technologií v rámci umělé inteligence na poli medicíny. Tento krok spoluutváří navržený model metody pro odhad nových a inovativních technologií ve zdravotnictví.

Seznam obrázků

Obrázek 1. Diagram běžného dělení umělé inteligence na hlavní větve	34
Obrázek 2. Diagram průběhu Delphi metody.....	49
Obrázek 3. Diagram průběhu systematické rešerše	51
Obrázek 4. Diagram navrhovaného postupu pro foresight.....	69
Obrázek 5. Technologický Hype cycle pro rok 2017	74

Seznam grafů

Graf 1. Machine learning – množství nalezených článků v letech 2013 – 2017.....	55
Graf 2. Expert systems – množství nalezených článků v letech 2013 – 2017.....	55
Graf 3. Machine learning a Expert systems – vztah počtu nalezených článků	56

Seznam tabulek

Tabulka 1. Organizace využívající v HSS Internet k identifikování nových zdravotnických technologií	13
Tabulka 2. Oblasti vyhledávání v HSS využívajících Internet k identifikování nových zdravotnických technologií	13
Tabulka 3. Tabulka vybraných studií.....	27
Tabulka 4. Klasifikace foresight metod podle typu.....	29
Tabulka 5. Srovnání metod pro odhad budoucího vývoje.....	32
Tabulka 6. Strojové učení – ScienceDirect	52
Tabulka 7. Strojové učení – Web of Science.....	52
Tabulka 8. Machine learning – součet článků z databází po odstranění duplicit	53
Tabulka 9. Expertní systémy – ScienceDirect.....	53
Tabulka 10. Expertní systémy – Web of Science	54
Tabulka 11. Expertní systémy – součet článků z databází po odstranění duplicit	54
Tabulka 12. Machine learning a Expert systems – souhrn nalezených článků	55
Tabulka 13. Počet analyzovaných článků v jednotlivých letech	57
Tabulka 14. Nejčtenější pojmy v jednotlivých kategoriích.....	57

Tabulka 15. Machine learning – top 3 časopisy v jednotlivých letech	59
Tabulka 16. Machine learning – top 5 časopisů za sledované období 2013 – 2017.....	60
Tabulka 17. Expert systems – top 3 časopisy v jednotlivých letech.....	60
Tabulka 18. Expert systems – top 5 časopisů za sledované období 2013 - 2017.....	61
Tabulka 19. Expertní systémy – rozdělení nalezených článků podle oblastí medicíny..	62
Tabulka 20. Strojové učení – rozdělení nalezených článků podle oblastí medicíny	63

Seznam použité literatury

- [1] MILES, I. The development of technology foresight: A review. *Technological Forecasting and Social Change* [online]. 2010, **77**(9), 1448–1456. ISSN 00401625. Dostupné z: doi:10.1016/j.techfore.2010.07.016
- [2] DOUW, Karla, Hindrik VONDELING, Drea ESKILDSEN a Sue SIMPSON. Use of the internet in scanning the horizon for new and emerging health technologies: A survey of agencies involved in horizon scanning. *Journal of Medical Internet Research* [online]. 2003, **5**(1), 33–45. ISSN 14388871. Dostupné z: doi:10.2196/jmir.5.1.e6
- [3] PACKER, Claire. The National Horizon Scanning Centre (NHSC): Early warning for new and emerging health technologies in England. *Evidence-Based Healthcare and Public Health* [online]. 2005, **9**(6), 410–413. ISSN 17442249. Dostupné z: doi:10.1016/j.ehbc.2005.09.005
- [4] MUNDY, L, T L MERLIN, A PARRELLA, W J BABIDGE, D E ROBERTS a J E HILLER. The Australia and New Zealand horizon scanning network. *Aust Health Rev* [online]. 2005, **29**(4), 395–397. ISSN 0156-5788. Dostupné z: doi:10.1071/ah050395
- [5] BERMAN, Group. *Technologický foresight šesti progresivních odvětví Královéhradeckého kraje v oblasti výzkumu, vývoje a inovací*. 2012.
- [6] PAZOUR MICHAL, POKORNÝ ONDŘEJ, Valenta Ondřej. *Foresight - efektivní nástroj veřejné správy*. 2017.
- [7] SMITH, J, D WARD, M MICHAELIDES, A T MOORE a S SIMPSON. New and emerging technologies for the treatment of inherited retinal diseases: a horizon scanning review. *Eye* [online]. 2015, **29**, 1131. Dostupné z: <http://dx.doi.org/10.1038/eye.2015.115>
- [8] BROWN, I T, A SMALE, A VERMA a S MOMANDWALL. Medical technology horizon scanning. *Australasian Physics & Engineering Sciences in Medicine* [online]. 2005, **28**(3), 200. ISSN 1879-5447. Dostupné z: doi:10.1007/BF03178717
- [9] GLENN JEROME CLAYTON, 1945-, Theodore J GORDON, U N Millennium PROJECT a Rockefeller FOUNDATION. *Futures research methodology*. Version 3. B.m.: [Washington, DC]: The Millennium Project, 2009. ISBN 9780981894119.
- [10] RENZI, Adriano Bernardo a Sydney FREITAS. The Delphi Method for Future Scenarios Construction. *Procedia Manufacturing* [online]. 2015, **3**, 5785–5791. ISSN 2351-9789. Dostupné z: doi:<https://doi.org/10.1016/j.promfg.2015.07.826>
- [11] RENZI, Adriano Bernardo a Sydney Fernandes DE FREITAS. Delphi Method to Explore Future Scenario Possibilities on Technology and HCI. In: Aaron MARCUS, ed. *Design, User Experience, and Usability: Design Discourse*. Cham: Springer International Publishing, 2015, s. 644–653. ISBN 978-3-319-20886-2.
- [12] POSTMA, Theo J B M, Janneke C ALERS, Sijmon TERPSTRA a Arjan ZUURBIER. The future of imaging techniques for cancer patients in The Netherlands. *The European Journal of Health Economics* [online]. 2006, **7**(2), 117–122. ISSN 1618-7601. Dostupné z: doi:10.1007/s10198-006-0342-5
- [13] STELZER, Birgit, Fabian MEYER-BRÖTZ, Edgar SCHIEBEL a Leo BRECHT. Combining the scenario technique with bibliometrics for technology foresight: The case of personalized medicine. *Technological Forecasting and Social Change* [online]. 2015, **98**, 137–156. ISSN 0040-1625. Dostupné

- z: doi:<https://doi.org/10.1016/j.techfore.2015.06.008>
- [14] RACHMATULLAH, C, Lu AYE a R J FULLER. Scenario planning for the electricity generation in Indonesia. *Energy Policy* [online]. 2007, **35**(4), 2352–2359. ISSN 0301-4215. Dostupné z: doi:<https://doi.org/10.1016/j.enpol.2006.08.015>
- [15] THEODORE, Gordon. *Trend Impact Analysis*. 1994.
- [16] HAN, Kyunam a Juneseuk SHIN. A systematic way of identifying and forecasting technological reverse salients using QFD, bibliometrics, and trend impact analysis: A carbon nanotube biosensor case. *Technovation* [online]. 2014, **34**(9), 559–570. ISSN 0166-4972. Dostupné z: doi:<https://doi.org/10.1016/j.technovation.2014.05.009>
- [17] HENNEN, W.H.G.J. a J BENNINGA. Application of Trend Impact Analysis for predicting future fruit consumption [online]. 2009, **84**(6 Isafruit Suppl), 18–21. ISSN 1462-0316. Dostupné z: <http://edepot.wur.nl/53673>
- [18] GEORGHIOU, Luke, Jennifer CASSINGENA HARPER, Michael KEENAN, Ian MILES a Rafael POPPER. The handbook of technology foresight : concepts and practice. *Prime series on research and innovation policy* [online]. 2008, **10**(5), xxv, 428 p. ISSN 1463-6689. Dostupné z: doi:10.1108/14636680810918522
- [19] MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence 1*. Praha: Academia, 1993. ISBN 80-200-0496-3.
- [20] KOTEK, Z, V MAŘÍK a Z ZDRÁHAL. Metody rozpoznávání a umělá inteligence. In: *Kybernetika ve výzkumu a výuce*. Plzeň: ČSVTS FE VŠSE, 1983, s. 16–30.
- [21] FRANKISH, Keith a William M. RAMSEY. *The Cambridge Handbook of Artificial Intelligence* [online]. Cambridge, UK: Cambridge University Press, 2014. ISBN 9780521691918. Dostupné z: doi:10.1017/CBO9780511816789
- [22] OXFORD DICTIONARIES. *Definition of Machine Learning in English by Oxford Dictionaries* [online]. Oxford: Oxford University Press. 2018. Dostupné z: https://en.oxforddictionaries.com/definition/learning%0Ahttps://en.oxforddictionaries.com/definition/machine_learning
- [23] HIERONS, Rob. Machine learning. Tom M. Mitchell. Published by McGraw-Hill, Maidenhead, U.K., International Student Edition, 1997. ISBN: 0-07-115467-1, 414 pages. Price: U.K. £22.99, soft cover. *Software Testing, Verification and Reliability* [online]. 1999, **9**(3), 191–193. ISSN 0960-0833. Dostupné z: doi:10.1002/(SICI)1099-1689(199909)9:3<191::AID-STVR184>3.0.CO;2-E
- [24] MANNILA, H. Data mining: machine learning, statistics, and databases. In: *Proceedings of 8th International Conference on Scientific and Statistical Data Base Management* [online]. 1996, s. 2–9. ISBN VO -. Dostupné z: doi:10.1109/SSDM.1996.505910
- [25] MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence 2*. Praha: Academia, 1997. Umělá inteligence. ISBN 9788020005045.
- [26] FEIGENBAUM, MCCORDUCK a NII. *The Rise of the Expert Company : How Visinary Companies are Using Artificial Intelligence to Achieve Higher Productivity and Profit* [online]. B.m.: Times Books, 1989. Computer science. ISBN 9780812917314. Dostupné z: <https://books.google.cz/books?id=yNnz6HcigqEC>
- [27] SZELISKI, Richard. *Computer vision: algorithms and applications* [online]. 2011. ISBN 97818488293430. Dostupné z: doi:10.1007/978-1-84882-935-0
- [28] *planning - Definition of planning in English by Oxford Dictionaries* [online]. 2018 [vid. 2018-05-08]. Dostupné z: <https://en.oxforddictionaries.com/definition/planning>

- [29] CHANG, Anthony C. Big data in medicine: The upcoming artificial intelligence. *Progress in Pediatric Cardiology* [online]. 2016, **43**(43), 91–94. ISSN 15581519. Dostupné z: doi:10.1016/j.ppedcard.2016.08.021
- [30] TRACTICA. *Artificial Intelligence Market Forecasts* [online]. Boulder: Tractica. 2017. Dostupné z: <https://www.tractica.com/research/artificial-intelligence-market-forecasts/>
- [31] *What doctor?* [online]. New York: PricewaterhouseCoopers. 2017. Dostupné z: <https://www.pwc.com/gx/en/industries/healthcare/publications/ai-robotics-new-health/ai-robotics-new-health.pdf>
- [32] RAJPURKAR, Pranav, Jeremy IRVIN, Kaylie ZHU, Brandon YANG, Hershel MEHTA, Tony DUAN, Daisy DING, Aarti BAGUL, Curtis LANGLLOTZ, Katie SHPANSKAYA, Matthew P. LUNGREN a Andrew Y. NG. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. *ArXiv* [online]. 2017. Dostupné z: doi:1711.05225
- [33] BAKKAR, Nadine, Tina KOVALIK, Ileana LORENZINI, Scott SPANGLER, Alix LACOSTE, Kyle SPONAUGLE, Philip FERRANTE, Elenee ARGENTINIS, Rita SATTLER a Robert BOWSER. Artificial intelligence in neurodegenerative disease research: use of IBM Watson to identify additional RNA-binding proteins altered in amyotrophic lateral sclerosis. *Acta Neuropathologica* [online]. 2018, **135**(2), 227–247. ISSN 14320533. Dostupné z: doi:10.1007/s00401-017-1785-8
- [34] BUČKOVÁ, Michaela, Tatjana DOSTÁLOVÁ, Alexandra POLÁŠKOVÁ, Magdaléna KAŠPAROVÁ a Milan DRAHOŠ. Decision Support System in Dentistry. *International Journal on Biomedicine and Helathcare*. 2017, **5**(1), 33–35.
- [35] PECEN, Ladislav, Marcel JIŘINA a Jakub NOVÁK. Diagnostic Software for Decision Support of Detection and Interpretation of Tumor Markers. *International Journal on Biomedicine and Helathcare*. 2015, **3**(1), 33–36.
- [36] OKOLI, Chitu a Suanne D. PAWLOWSKI. The Delphi method as a research tool: An example, design considerations and applications. *Information and Management* [online]. 2004, **42**(1), 15–29. ISSN 03787206. Dostupné z: doi:10.1016/j.im.2003.11.002
- [37] TREVELYAN, Esmé G. a Nicola ROBINSON. Delphi methodology in health research: How to do it? *European Journal of Integrative Medicine* [online]. 2015, **7**(4), 423–428. ISSN 18763839. Dostupné z: doi:10.1016/j.eujim.2015.07.002
- [38] VON DER GRACHT, Heiko A. Consensus measurement in Delphi studies: Review and implications for future quality assurance. *Technological Forecasting and Social Change* [online]. 2012, **79**(8), 1525–1536. ISSN 0040-1625. Dostupné z: doi:<https://doi.org/10.1016/j.techfore.2012.04.013>
- [39] LEONDES, Cornelius T. *Expert systems: the technology of knowledge management and decision making for the 21st century* [online]. B.m.: Academic Press, 2002. Expert Systems: The Technology of Knowledge Management and Decision Making for the 21st Century. ISBN 9780124438804. Dostupné z: <https://books.google.cz/books?id=CK5QAAAAMAAJ>
- [40] VAN LENTE, Harro, Charlotte SPITTERS a Alexander PEINE. Comparing technological hype cycles: Towards a theory. *Technological Forecasting and Social Change* [online]. 2013, **80**(8), 1615–1628. ISSN 00401625. Dostupné z: doi:10.1016/j.techfore.2012.12.004
- [41] MENDEN, Michael P., Francesco IORIO, Mathew GARNETT, Ultan MCDERMOTT, Cyril H. BENES, Pedro J. BALLESTER a Julio SAEZ-RODRIGUEZ. Machine Learning Prediction of Cancer Cell Sensitivity to Drugs

- Based on Genomic and Chemical Properties. *PLoS ONE* [online]. 2013, **8**(4). ISSN 19326203. Dostupné z: doi:10.1371/journal.pone.0061318
- [42] AHMED, Adnan, Munam Ali SHAH, Abdul WAHID, Saif UL ISLAM, Muhammad Kamran ABBASI a Muhammad Nabeel ASGHAR. Big Data Analytics Using Neural Networks for Earlier Cancer Detection. *Journal of Medical Imaging and Health Informatics* [online]. 2017, **7**(6), 1469–1474. ISSN 2156-7018. Dostupné z: doi:10.1166/jmihi.2017.2189
- [43] SOH, Kee Pang, Ewa SZCZUREK, Thomas SAKOPARNIG a Niko BEERENWINKEL. Predicting cancer type from tumour DNA signatures. *Genome Medicine* [online]. 2017, **9**(1). ISSN 1756994X. Dostupné z: doi:10.1186/s13073-017-0493-2
- [44] MONTEIRO, Eriksson, Carlos COSTA a José Luís OLIVEIRA. A De-Identification Pipeline for Ultrasound Medical Images in DICOM Format. *Journal of Medical Systems* [online]. 2017, **41**(5). ISSN 1573689X. Dostupné z: doi:10.1007/s10916-017-0736-1
- [45] GATOS, Ilias, Stavros TSANTIS, Stavros SPILIOPOULOS, Dimitris KARNABATIDIS, Ioannis THEOTOKAS, Pavlos ZOUMPOULIS, Thanasis LOUPAS, John D. HAZLE a George C. KAGADIS. A Machine-Learning Algorithm Toward Color Analysis for Chronic Liver Disease Classification, Employing Ultrasound Shear Wave Elastography. *Ultrasound in Medicine and Biology* [online]. 2017, **43**(9), 1797–1810. ISSN 1879291X. Dostupné z: doi:10.1016/j.ultrasmedbio.2017.05.002
- [46] AFRIDI, Muhammad Jamal, Arun ROSS, Xiaoming LIU, Margaret F. BENNEWITZ, Dorela D. SHUBONI a Erik M. SHAPIRO. Intelligent and automatic in vivo detection and quantification of transplanted cells in MRI. *Magnetic Resonance in Medicine* [online]. 2017, **78**(5), 1991–2002. ISSN 15222594. Dostupné z: doi:10.1002/mrm.26571
- [47] DI DECO, Javier, Ana M GONZÁLEZ, Julia DÍAZ, Virginia MATO, Daniel GARCÍA-FRANK, Juan ÁLVAREZ-LINERA, Ana FRANK a Juan A HERNÁNDEZ-TAMAMES. Machine learning and social network analysis applied to Alzheimer’s disease biomarkers. *Current topics in medicinal chemistry* [online]. 2013, **13**(5), 652–662. ISSN 1873-4294. Dostupné z: doi:10.2174/1568026611313050008
- [48] KOTSAVASILOGLOU, C, N KOSTIKIS, D HRISTU-VARSAKELIS a M ARNAOUTOGLU. Biomedical Signal Processing and Control Machine learning-based classification of simple drawing movements in Parkinson ’ s disease. *Biomedical Signal Processing and Control* [online]. 2017, **31**, 174–180. ISSN 1746-8094. Dostupné z: doi:10.1016/j.bspc.2016.08.003
- [49] DLUHOS, Petr, Daniel SCHWARZ a Tamas KASPAREK. Wavelet Features for Recognition of First Episode of Schizophrenia from MRI Brain Images. *Radioengineering*. 2014, **23**(1), 274–281. ISSN 1210-2512.
- [50] MASOOD, Anum, Bin SHENG, Ping LI, Xuhong HOU, Xiaoer WEI, Jing QIN a Dagan FENG. Computer-Assisted Decision Support System in Pulmonary Cancer detection and stage classification on CT images. *Journal of Biomedical Informatics* [online]. 2018, **79**(January), 117–128. ISSN 1532-0464. Dostupné z: doi:10.1016/j.jbi.2018.01.005
- [51] VALDES, Gilmer, Charles B. SIMONE, Josephine CHEN, Alexander LIN, Sue S. YOM, Adam J. PATTISON, Colin M. CARPENTER a Timothy D. SOLBERG. Clinical decision support of radiotherapy treatment planning: A data-driven machine learning strategy for patient-specific dosimetric decision making.

- Radiotherapy and Oncology* [online]. 2017, **125**(3), 392–397. ISSN 18790887. Dostupné z: doi:10.1016/j.radonc.2017.10.014
- [52] BEN-COHEN, Avi, Eyal KLANG, Idit DIAMANT, Noa ROZENDORN, Stephen P. RASKIN, Eli KONEN, Michal Marianne AMITAI a Hayit GREENSPAN. CT Image-based Decision Support System for Categorization of Liver Metastases Into Primary Cancer Sites: Initial Results. *Academic Radiology* [online]. 2017, **24**(12), 1501–1509. ISSN 18784046. Dostupné z: doi:10.1016/j.acra.2017.06.008
- [53] RIBAS, Vicent J, Anna WOJDEL, Enrique ROMERO, Pablo RAMOS a Josep BRUGADA. ECG assessment based on neural networks with pretraining. *Applied Soft Computing Journal* [online]. 2016, **49**, 399–406. ISSN 1568-4946. Dostupné z: doi:10.1016/j.asoc.2016.08.013
- [54] HASSAN, Nasruddin, Osama Rashed SAYED, Ahmed Mostafa KHALIL a Mohamed Abdel GHANY. Fuzzy Soft Expert System in Prediction of Coronary Artery Disease. *International Journal of Fuzzy Systems* [online]. 2017, **19**(5), 1546–1559. ISSN 21993211. Dostupné z: doi:10.1007/s40815-016-0255-0
- [55] MENDES, David, Irene Pimenta RODRIGUES, Carlos Fernandes BAETA a Carlos SOLANO-RODRIGUEZ. Ontology Driven Controlled Natural Language Clinical Decision Support System for the Cardiovascular Specialty. *Procedia Technology* [online]. 2014, **16**, 1493–1501. ISSN 22120173. Dostupné z: doi:10.1016/j.protcy.2014.10.170
- [56] SAOUD, Manel Saad, Abdelhak BOUBETRA a Safa ATTIA. A Multi-Agent Based Modeling and Simulation Data Management and Analysis System for the Hospital Emergency Department. *International Journal of Healthcare Information Systems and Informatics* [online]. 2017, **12**(3), 21–36. ISSN 1555-3396. Dostupné z: doi:10.4018/IJHISI.2017070102
- [57] DAS, Lala T., Erika L. ABRAMSON, Anne E. STONE, Janienne E. KONDRICH, Lisa M. KERN a Zachary M. GRINSPAN. Predicting frequent emergency department visits among children with asthma using EHR data. *Pediatric Pulmonology* [online]. 2017, **52**(7), 880–890. ISSN 10990496. Dostupné z: doi:10.1002/ppul.23735
- [58] SAOUD, Manel Saad, Abdelhak BOUBETRA a Safa ATTIA. A Simulation Knowledge Extraction-based Decision Support System for the Healthcare Emergency Department. *International Journal of Healthcare Information Systems and Informatics* [online]. 2016, **11**(2), 19–37. ISSN 1555-3396. Dostupné z: doi:10.4018/IJHISI.2016040102
- [59] MENTZER, Marc S. *The Innovator's Solution: Creating and Sustaining Successful Growth*. [online]. B.m.: Harvard Business School Press, 2004. ISBN 1578518520. Dostupné z: doi:10.5465/AME.2004.12689164
- [60] Ministerstvo připravilo nová pravidla pro rozhodování Přístrojové komise. *Ministerstvo zdravotnictví České republiky* [online]. 2018 [vid. 2018-05-15]. Dostupné z: http://www.mzcr.cz/dokumenty/ministerstvo-pripravilo-nova-pravidla-pro-rozhodovani-pristrojove-komise_15265_1.html
- [61] *The Hype Cycle for Emerging Technologies, 2017 | VIPdoc* [online]. [vid. 2018-05-10]. Dostupné z: <https://www.vipdoc.nl/the-hype-cycle-for-emerging-technologies-2017/>