



Zemědělská
fakulta
Faculty
of Agriculture

Jihočeská univerzita
v Českých Budějovicích
University of South Bohemia
in České Budějovice

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH ZEMĚDĚLSKÁ FAKULTA

Katedra zemědělské, dopravní a manipulační techniky

Diplomová práce

Umělá inteligence v dopravě a městech

Autor práce: Bc. Matouš Dědič

Vedoucí práce: Mgr. Havelka Zbyněk, Ph.D

České Budějovice
2021

Prohlášení

Prohlašuji, že jsem autorem této kvalifikační práce a že jsem ji vypracoval pouze s použitím pramenů a literatury uvedených v seznamu použitých zdrojů.

V Českých Budějovicích dne

.....

Bc. Matouš Dědič

Abstrakt

Příchod Průmyslové revoluce 4.0 ovlivňuje každého z nás. V rámci Průmyslové revoluce 4.0 a jejího vstupu do oblasti řízení dopravy a měst zastává velmi výraznou roli umělá inteligence, na kterou se zaměřuje tato práce. Práce je rešeršní a klade si za cíl vytvořit srozumitelný přehled současného stavu problematiky.

Kapitola první se zabývá pojmem umělé inteligence, jejími klady a zápory, historií a principy. Následující kapitoly se již věnují historii a využití UI pro řízení dopravního provozu, chytrých měst a technologie Smart grids.

Klíčová slova: umělá inteligence, doprava, chytré město, průmyslová revoluce 4.0

Abstract

The approach of Industrial Revolution 4.0 affects every human being. Artificial intelligence plays a significant role in Industrial Revolution 4.0 and its input into area of traffic and urban management. This is a research thesis which aims to create a clear overview of the current state of affairs.

First chapter analyses the concept of the artificial intelligence, its pros and cons, history and principles. The following chapters are focused on history and use of artificial intelligence for traffic management, smart cities and Smart grids technology.

Keywords: artificial intelligence, traffic, smart city, industrial revolution 4.0

Poděkování

Děkuji svému vedoucímu diplomové práce panu Mgr. Zbyňku Havelkovi Ph.D, za cenné rady a podnětné připomínky, které mi pomohly k vypracování této práce.

Obsah

Úvod	7
1 Cíle a metodika práce	10
2 Definice a historie umělé inteligence	11
2.1 Definice a vysvětlení pojmu	11
2.2 Historie umělé inteligence	12
2.3 Budoucnost umělé inteligence	12
2.3.1 Průmyslová revoluce 4.0 a její zhodnocení	13
2.4 Test umělé inteligence	15
2.4.1 Systém ELIZA	15
2.5 Expertní systémy	16
2.6 Neuronové sítě	16
2.6.1 Princip neuronových sítí	17
2.7 Řešení problémů	17
2.7.1 Systematická strategie	17
2.7.2 Neinformované metody prohledávání stavového prostoru	18
2.7.3 Informované metody prohledávání stavového prostoru	19
2.8 General problem solver	19
2.8.1 Činnost GPS systému	19
2.8.2 Příklad využití GPS	20
3 Řízení dopravního provozu	21
3.1 Nástup umělé inteligence v dopravě	21
3.2 Způsob modelování křižovatek	21
3.3 Analýza a predikce dynamiky silničního provozu pomocí umělé inteligence	24
3.3.1 Koopmanova metoda	24
3.4 Systémy v řízení dopravního provozu	25
3.4.1 Systém CPS	25
3.4.2 Řízení provozu pomocí systému DSRC	26
3.4.3 Řízení provozu metodou SCOOT	26
3.4.4 Systém DALI	28
3.4.5 Detekce vozidel pomocí akustického snímání	28
3.4.6 Magnetický senzorový systém	28
3.4.7 Inteligentní dopravní mobilní aplikace	30
3.5 Google Maps a umělá inteligence	31

4	Chytrá města	33
4.1	Použití umělé inteligence ve městech	33
4.1.1	Co je to chytré město?	33
4.2	Transformace měst na 4.0	34
4.2.1	Mindsphere – operační cloudový systém	35
4.2.2	Spinwire	35
4.2.3	Multiagentní systém pro dynamické umístění nabíjecích stanic elektrických vozidel	36
4.2.4	Využití dopravního značení ve městech pro potřeby autonomních vozidel	37
4.3	Využití DIPT v městském prostředí	38
4.4	Shromažďování dat pomocí sledování očí	38
4.4.1	Tepelná mapa	39
4.4.2	Časoprostorová krychle	40
4.4.3	Trajektorie pohledu	40
4.4.4	Příklady budoucího využití v praxi	41
4.5	Nejzelenější londýnská budova	41
4.6	Nejstarší inteligentní budova v ČR	42
4.7	Čistý vzduch v chytrých městech	43
4.8	Tramvaje v Bordeaux se spodním odběrem APS	43
4.9	Chytrý hybridní systém solárního osvětlení	44
5	Smart grids	45
5.1	Co je to Smart grid?	45
5.1.1	Chytré spotřebiče	46
5.2	Vývoj Smart grids v Česku	47
5.2.1	Koncept Smart grids	47
5.2.2	Legislativní podmínky	47
5.2.3	Prvky umělé inteligence v přenosové soustavě	48
5.2.4	Prvky umělé inteligence v distribuční soustavě	48
5.2.5	Dopad elektromobility a zavádění obnovitelných zdrojů do Smart grids	49
	Závěr	50
	Seznam použitých zdrojů	52
	Seznam obrázků	57
	Seznam tabulek	58

Úvod

Otázku, zda mohou stroje myslet, si pokládali významní filosofové již v 17. století. V té době se zabývali pouze existenční otázkou, ale k žádnému vývoji nedocházelo. Postupný vývoj byl započat až v polovině 20. století. V tu dobu vznikl program General Problem Solver, jehož autoři byli Newell a Simon. Tento program byl považován za první systém využívající umělou inteligenci. Jeden z převratných vynálezů byl Turingův test, který byl definován v padesátých letech 20. století Alanem Turingem. Test je podrobně popsán dále v práci. Díky tomuto testu se dá určit, zda testovaný systém je inteligentní či ne. Od této doby začalo vznikat mnoho převratných systémů, metod, programů a různých teorií o umělé inteligenci. V osmdesátých letech se do výzkumu umělé inteligence přidaly velké soukromé firmy: General Motors a Boeing. V těchto letech se začalo uvažovat o umělé inteligenci jako o nástroji, který by mohl být využíván i v průmyslu a způsobit určitou úsporu nákladů nebo zrychlení procesů. Později byla objevena fuzzy logika a neuronové sítě, které byly inspirovány fungováním mozku.

V současné době, kdy probíhá digitalizace téměř ve všech oblastech, jsme svědky tzv. čtvrté průmyslové revoluce. Do revoluce 4.0 se aktivně zapojuje i Evropská unie a proběhlo již mnoho investic do různých projektů a spousta dalších investic je v plánu. Investice by se měly týkat zejména internetu věcí, práce s velkým objemem dat a cloudových úložišť, robotiky, zavádění umělé inteligence a rozvojem 3D tisku. V ČR byl vypracován dokument s názvem Iniciativa Průmysl 4.0, který se zabývá i dopady na trh práce. Část společnosti má strach, že umělá inteligence nahradí některá pracovní místa. Měla by však být zaváděna tam, kde by byla možnost nahradit těžkou monotónní práci a nechat člověka pracovat na pozicích, kde je potřeba lidského uvažování. Aby však mohla být zaváděna na pracovní pozice, kde je náplní práce pouze monotónní činnost, musí se vyrovnat náklady na mzdy nákladům pro zavedení automatizace. V současné době tato rovnice vychází málokdy kladně. S rostoucím vývojem nových technologií by však mělo být zavádění automatizace a umělé inteligence snazší a také méně nákladné.

Práce se zabývá popisem základních prvků, bez kterých by umělá inteligence nemohla fungovat. Jednou z těchto věcí jsou neuronové sítě. Neuronová síť je výpočetní model, který se využívá v umělé inteligenci, skládá se z umělých (formálních) neuronů. Neurony jsou navzájem propojeny a předávají si signály, zároveň je pomocí přenosových funkcí transformují v určité výstupy. Neurony mají libovolný počet vstupů, ale pouze jeden výstup. V současné době existuje nepřehledné množství metod, které ke svému fungování využívají umělou inteligenci a tyto systémy slouží v nejrůznějších odvětvích.

Jedno z odvětví, kde se hojně využívá umělé inteligence zejména ke zvýšení bezpečnosti, je doprava. V dopravě se umělá inteligence využívá uvnitř automobilů, díky zvyšujícímu se podílu autonomity při řízení a dalších různých pomocných prvků. Umělá inteligence se také využívá i mimo automobily pro řízení dopravního provozu jako ta-

kového. Tyto oblasti by měly být vyvíjeny současně a disponovat schopností vzájemné komunikace. Zhruba před sto lety se objevily na silnicích semaforey. Byl to jeden z prvních náznaků, že bude potřeba v budoucnu pomocí techniky regulovat dopravu. Jelikož hustota provozu se neustále rapidně zvyšuje, je potřeba zavádět inteligentní systémy, které mohou zajistit bezpečnost a plynulost provozu.

V současné době existuje a dále je vyvíjena celá řada systémů, které pomáhají regulovat emise, dopravní zácpy nebo snižovat energetickou náročnost dopravy. Jeden ze systémů pro zvyšování efektivity provozu je například systém DSRC. Tento systém je oproti klasickým systémům řídicích semaforey na principu časovačů velmi pružný a dokáže reagovat na změny provozu v různých fázích dne. Systém funguje na principu sbírání dat ze signálů, které vysílají vozidla projíždějící městem. V případě, kdy systém zaznamená vozidlo blížící se ke křižovatce, je čas na efektivní zhodnocení celé situace tak, aby byla zajištěna co nejplynulejší jízda pro všechny účastníky provozu. Systémy si musejí vykreslovat křižovatky, například pomocí dlaždic a různé situace, které se v provozu dějí a vyhodnocovat různé možnosti, kam se může který objekt dále pohybovat. Detekování vozidel může probíhat různými způsoby např. pomocí akustického snímání nebo pomocí magnetických signálů.

S vývojem inteligentních technologií přicházejí také inteligentní dopravní aplikace do chytrých telefonů. Jedna z aplikací byla představena i v České republice, její název je C-Roads. Spolu s mobilní aplikací musí být řidič vybaven vozidlovou jednotkou. Při používání aplikace probíhá komunikace mezi jednotkami v ostatních vozidlech, ale také detekuje dopravní značky, semaforey, železniční přejezdy či vozidla IZS. V oblasti mobilních aplikací a vyvíjení nových systémů v oblasti umělé inteligence je velkým hráčem společnost Google. Například jejich funkce DeepMind již dokáže odhalit chřipkovou epidemii rychleji než americká vláda. Google do oblasti dopravy ve velké míře zasahuje svou aplikací Google maps. V dnešní době jsou to již nevyužívanější virtuální mapy na světě. V současné době tuto aplikaci využívá přes miliardu uživatelů. Velkou novinkou bylo zavedení služby Street View v roce 2007. Vize, že společnost Google nafotí celý svět, byla poměrně zanedlouho naplněna. Společnost využívá denně několik automobilů kvůli aktuálnosti fotek a pomocí umělé inteligence fotky třídí. Jejich algoritmus dokáže na 84,2 % rozpoznat název ulice a číslo popisné. Vlastnost rozeznávat nápisy i z méně čitelných fotografií tuto aplikaci posouvá daleko před konkurenci.

Umělá inteligence také nachází velké uplatnění v konceptech nazývaných jako Smart City. Chytré město by mělo být takové, které ve velké míře využívá digitálních technologií, bezuhlíkovou dopravu, má nízkou produkci odpadu a šetří lidem čas. Chytrá města také vytváří prostředí pro podnikání a dávají do rukou všem občanům a zaměstnavatelům velký objem dat, se kterým je potřeba efektivně pracovat. I ve městech lze použít termín transformace 4.0. V takovém městě by měly být například vlaky bez řidiče nebo budovy, které se aktivně propojují s energetickou sítí na rozhraní zahrnující mobilitu nebo inteligentní systémy. Budovy budou poskytovat důležité informace například pro zlepšení kvality ovzduší. Při fungování chytrého města je důležitý sběr velkého množství dat. Jednou z metod sběru dat je sledování očí. Díky této metodě lze zjistit přesné chování uživatele. Rychlost snímání pohybu může být až 500 Hz. Tato metoda sleduje nejsledovanější body očí nebo trajektorii pohledu očí.

Se Smart Cities souvisí také Smart Grids. Abychom mohli mít v chytrém městě elektřinu vyrobenou z obnovitelných zdrojů potřebujeme Smart Grids. Jelikož obnovitelné zdroje jsou nepredikovatelné, je potřeba zvládat špičkové odběry elektřiny a přebytečnou energii nějakým způsobem ukládat k pozdějšímu využití. Hlavním cílem chytrých sítí je,

aby všechny subjekty podílející se na výrobě elektřiny spolu komunikovaly, regulovaly svoje výkony a uskladňovaly nevyužitou elektřinu.

1 Cíle a metodika práce

Cílem práce je poskytnout ucelený pohled na současný stav problematiky využití umělé inteligence v oblasti řízení dopravy a chytrých měst. Vzhledem k tomu, že je problematika velmi rozsáhlá, byla pro potřeby této práce rozdělena do čtyř hlavních celků. První část si dává za cíl seznámit čtenáře se samotnou problematikou umělé inteligence, další části jsou již konkrétně zaměřeny na problematiku řízení dopravy ve městech, chytrých měst a s nimi související technologií Smart Grid.

Práce je rešeršního typu a tak je k dosažení cíle práce využito vědeckých databází Scopus, Web of Science apod. V těchto databázích byly vyhledány relevantní vědecké publikace vztahující se k tématu, které jsou následně seskupeny do logických celků práce. Informace z vědeckých publikací byly doplněny informacemi z relevantních internetových a knižních zdrojů.

2 Definice a historie umělé inteligence

2.1 Definice a vysvětlení pojmu

Nejuznávanější definicí je ta, kterou definoval v roce 1967 Marvin Minsky: „*Umělá inteligence je věda o vytváření strojů nebo systémů, které budou při řešení určitého úkolu užívat takového postupu, který – kdyby ho dělal člověk – bychom považovali za projev jeho inteligence*“ (Reeke Jr., 1991).

Dříve se umělá inteligence objevovala spíše u sci-fi knih a filmů, v dnešní době je však součástí každodenního života. Umělá inteligence se v současné době rozmáhá do nej-různějších odvětví v běžném životě, dopravě, podnikání i průmyslu. S umělou inteligencí se počítá i v programu udržitelného rozvoje, jenž stanovuje 17 cílů, kterými se bude OSN snažit dosáhnout v letech 2015 až 2030 (United Nations, 2021). Během jejího vytváření lidstvo získalo spoustu dat o inteligenci člověka a také byl strukturován lidský intelekt. Umělá inteligence má výhody oproti lidské inteligenci, např.: vyšší predikční schopnost, vyšší účinnost a lepší výsledky. Rozvoj umělé inteligence bude poskytovat některým městům a státům oproti ostatním finanční výhody a výhody všeobecného pokroku. Určitá část společnosti se obává, že umělá inteligence nahradí lidskou pracovní sílu. Tyto obavy mohou být opodstatněné, podle Stephena Hawkinga lidé svými pomalými biologickými systémy jen těžko mohou konkurovat strojům, jež jsou řízeny umělou inteligencí. Jiní vědci zase tvrdí, že možná jsou stroje schopny překonat schopnosti člověka, ale tyto změny by měly negativní dopad na lidstvo.

Společnost se rozděluje na dva tábory, jedni umělou inteligenci vítají, druzí ji odsuzují. Obecně je to tak, že lidé ve vyspělých zemích se mohou obávat ztráty zaměstnání, na druhou stranu v chudších zemích by umělá inteligence měla napomoci odvrátit chudobu. Nepochybně by mohla být silným prostředkem hospodářského růstu.

Umělou inteligenci lze v současné době rozdělit do dvou odvětví: úzká a obecná. Úzká zahrnuje všechny formy umělé inteligence jak ji dnes známe. Obecná inteligence zůstává stále teoretická. Podmnožinou obecné umělé inteligence je strojová inteligence na úrovni člověka, která je idealizována a je schopná fungovat na úrovni extrémně nadaného člověka ve všech intelektuálních úkolech. Tato část umělé inteligence nahání ve společnosti největší strach, jelikož by tyto roboti mohli nahradit lidský druh na planetě. Vzhledem k tomu, jak dnešní nová generace jednoduše přijímá nové technologie a umělou inteligenci, se předpokládá, že bude mít svojí roli i ve vzdělávání. Pokud se možnosti umělé inteligence využijí správně a efektivně, mohl by to být dobrý krok v globalizaci, zdravotnictví, dopravě, technickém pokroku, udržitelném rozvoji a v mnoha dalších odvětvích (Goralski a Tan, 2020).

2.2 Historie umělé inteligence

Roku 1955 Newell a Simon vyvinuli systém General Problem Solver (Ernst a Newell, 1969), který je považován za první, jež využívá umělou inteligenci. Program pracoval na stromovém principu. Ke každému problému, který měl analyzovat, našel větev, která odpovídala pravděpodobnému řešení. Tento program měl zásadní vliv pro další vývoj. O rok později John McCarthy, který je považován za otce umělé inteligence, zorganizoval velkou konferenci pro všechny, kteří se zajímají o strojovou inteligenci. Od doby této konference se začal používat termín umělá inteligence. Na konferenci byla otevřena cesta pro další objevování tohoto odvětví. O pár let později firma IBM vytvořila tým, jehož úkolem byl výzkum umělé inteligence. V roce 1958 John McCarthy vytvořil převratný nástroj. Byl to jazyk LISP (List Processing – zpracování seznamů) (McCarthy, 1958). Využívá se dodnes jako jazyk vývojářů umělé inteligence. V roce 1963 se do tohoto odvětví zapojila i vláda USA. Ministerstvo obrany vypsalo grant v hodnotě 2,2 mil. dolarů, aby si zajistilo technologickou výhodu proti Sovětskému svazu. Tento milník také velmi pomohl ve vývoji a financování rozvoje umělé inteligence. V dalších letech vzniklo velké množství programů, na konci šedesátých let vznikl například program STUDENT, který dokázal vyřešit různé algebraické výrazy. Vznikl také program SIR, který byl průkopníkem dnešních překladačů a rozuměl jednoduchým anglickým větám. V sedmdesátých letech byly rozvíjeny expertní systémy, ty předvídají pravděpodobnost řešení ve stanovených podmínkách. V osmdesátých letech se začaly více zlepšovat, zrychlovat, zvýšila se jejich účinnost a také po nich stoupla poptávka. V těchto letech začaly používat expertní systémy velké firmy jako: General Motors nebo Boeing. V pozdějších letech se umělá inteligence vyvíjela dále a dost zásadně, vznikly první kamery a počítače, které kontrolovaly kvalitu na výrobních linkách. Byla objevena fuzzy logika a neuronové sítě. Armáda chtěla vytvořit robota, který by mohl provádět bitevní úkony, ale nakonec ze strachu ztráty kontroly nad strojem financování zastavila. Nadále se začalo více ukazovat, že umělá inteligence by mohla být později využívána i v běžném životě (Zelinka, 2003).

2.3 Budoucnost umělé inteligence

Technologické inovace pomáhají v rozvoji průmyslu již více než 250 let. V minulosti byly významnými milníky vynálezy parní stroj, spalovací motor nebo elektřina. Umělá inteligence se staví na pozici stále rozvíjejícího se vynálezu dnešní doby. Systémy strojového učení jsou skvělí žáci a dokážou dosáhnout výborných výsledků v širokém spektru aktivit včetně diagnostikování nemocí. Zapojení těchto systémů do světové ekonomiky bude mít extrémně velký dopad. V minulosti už stroje dokázaly porazit nejlepší hráče pokeru (Gibney, 2017). I přesto je potřeba, aby se umělá inteligence nadále vyvíjela. Například: pokud umělá inteligence umí pomocí databáze ImageNet rozeznávat velké množství fotografií, avšak v případě, že je fotografie rozostřena, či vyfocena ze špatného úhlu, umělá inteligence selhává. Podobně jsou na tom systémy pro překlad cizích jazyků, kdy umělá inteligence některá slova vůbec nechápe. Aby se umělá inteligence postavila na stejnou úroveň té lidské, je zatím velmi vzdálené a stále je hodně věcí, které se budou zdokonalovat. V dohledné době bude mít zejména svoje místo tam, kde se pracuje s velkým množstvím dobře definovaných dat (formuláře, fotky, akcie). Umělá inteligence by do budoucna ne-

měla být vnímána jako náhrada lidských činností, měla by nám pouze sloužit k dosažení pokroku (Cejnarová, 2018a).

2.3.1 Průmyslová revoluce 4.0 a její zhodnocení

Základní myšlenka, která by při zavádění umělé inteligence do průmyslu a v průběhu tzv. revoluce 4.0, měla být dodržena je, že technika by měla sloužit člověku, a ne naopak. EU vydala prostřednictvím Evropské komise v roce 2016 zásadní dokumenty: Digitalizace evropského průmyslu (European comission, 2020a) zaměřená na oblast cloud computingu, priority pro normalizaci informačních technologií, akční plán pro e-Government a pracovní dokument útvaru EK o internetu věcí. Druhý dokument, který byl Evropskou komisí vydán v roce 2018 navrhuje vytvoření komplexního a integrovaného přístupu k umělé inteligenci. Tato sdělení by měla vytvořit celoevropskou iniciativu, která bude zaměřena zejména na tři body:

1. Zvýšení technologických a průmyslových kapacit a zavádění umělé inteligence v rámci celého subjektu hospodářství.
2. Zaměření se na socioekonomické otázky, které souvisí se zaváděním umělé inteligence.
3. Zajištění etického a právního rámce, který by stanovil pravidla pro umělou inteligenci.

Evropská unie má také v plánu celou řadu projektů a investic, které budou zaměřeny na vybudování celosvětové špičkové infrastruktury superpočítačů v Evropě, zřízení konfederace laboratoří pro výzkum umělé inteligence v Evropě a vlajkové lodě kvantových technologií.

Po ekonomické stránce ICT oblasti tvoří v EU asi 4 % HDP. V oblasti ICT pracuje více jak 6 mil. lidí. Přidaná hodnota vyrobeného zboží, kterým jsou buď digitální, nebo softwarové produkty, tvoří téměř 10 % celkové přidané hodnoty průmyslové činnosti. Jedna třetina celkové průmyslové výroby v Evropě využívá digitální technologie. V příštích pěti letech by se výnos EU v oblasti digitalizace výrobků měl zvýšit o 110 mld. eur. Nejrozsáhlejší segment digitální změny je v konvergenci řady technologií - internetu věcí, dat velkého objemu a cloudů, robotiky, zavádění umělé inteligence a 3D tisk. Nové technologie pomocí pokročilých senzorů a velkému objemu dat šetří spotřebu energie a surovin. V Evropské unii je chybějící pracovní síla, kterou bude nutné nahradit. V této oblasti se klade důraz na rozsáhlé zvyšování kvalifikace pracovní síly na všech úrovních a nutnost spolupráce veřejného a soukromého sektoru. Velkým úkolem je také připravit pracovníky na digitální transformaci a vybavit je dovednostmi, které budou u moderních technologií potřeba. Průmyslová revoluce 4.0 také rozhodně změní trh práce a jeho povahu. Charakter budoucích pracovních míst bude mít vyšší nárok na digitální, podnikatelské a inženýrské dovednosti. V ČR se problematika vyjadřuje jako Iniciativa Průmysl 4.0 (MPO, 2016). Pro řešení jednotlivých úkolů byl vypracován dokument s názvem Národní iniciativa Průmysl 4.0, který zahrnuje kapitoly jako např.: Dopad na trh práce, Dopad na vzdělávací soustavu, Nezbytné úpravy právního rámce a regulačního prostředí, Efektivita využívání zdrojů atd.

Proměna pracovního trhu

Dopad digitalizace v rámci jednotlivých sektorů českého hospodářství vyhodnocuje index ohrožení digitalizací. Z průzkumu vyplývá, že sektory, které mají vyšší míru digitalizace, budou pravděpodobně více připraveni přizpůsobit se důsledkům změn, které s sebou nese 4. průmyslová revoluce. Přestože již dnes jsou některá pracovní místa nahraditelná, zůstávají stále na pracovním trhu, jelikož náklady na mzdy jsou nižší než výdaje, které by si žádala automatizace. Na trhu práce zcela nepochybně zůstanou profese, které nelze jakkoliv automatizovat z důvodu sociálních, organizačních, fyzických či intelektuálních požadavků. Nejvyšší index ohrožení digitalizací se týká úředníků pro zpracovávání číselných údajů, administrativních pracovníků, pokladníků, prodavačů, nástrojařů, sekretářů, obsluhy různých zařízení, strojvedoucích atd. Mezi oblastí, na které bude mít digitalizace pozitivní dopad, patří např.: ICT, průmyslová výroba, těžba, stavebnictví, výzkum, vývoj, či marketing. Níže je uvedeno několik příkladů přínosů revoluce 4.0 (Hanzlíková, 2020; Hermann et al., 2016).

Pozitivní přínosy revoluce 4.0

- Zvýšení úrovně globálních příjmů a zlepšení kvality života.
- Zvýšení globální produktivity úspěšným zavedením nových technologií.
- Velká příležitost pro investory (již dnes jsou prokazatelná vysoká zhodnocení).
- Zásadní změna celého systému od vývoje výrobku přes výrobu a prodej. Očekává se zvýšení pružnosti a reakce na poptávku.
- Dlouhodobý přínos v efektivitě a produktivitě prostřednictvím technologické inovace.
- Zvýšení rychlosti rozhodovacích procesů v oblasti ekonomiky a podnikání.
- Posun lidského potenciálu k propracovanějšímu způsobu využití techniky pro zvýšení prosperity lidí při dodržení komplexního přístupu k řešení nové problematiky.

Negativní přínosy revoluce 4.0

- Představa populace o způsobech, jak může společnost zajistit, aby její myšlenky dokázaly držet krok s rychle se rozvíjejícími technologiemi.
- Nedořešené otázky související se zdaněním robotických pracovních sil.
- Zvyšující se digitalizace bude nahrávat získávání interních informací pomocí hackerských útoků.
- Odtržení mladé generace od praxe a nastolení práce pouze pomocí výpočetní techniky.
- Přesunem získaných dovedností na moderní technologie člověk ztrácí schopnost samostatné reakce na různé situace.

- Budoucí trh si bude žádat vzdělané a kvalifikované lidi, nejistá otázka těch, kteří budou intelektuálně slabší.
- Úroveň spolehlivosti nových systémů moderních technologií.

2.4 Test umělé inteligence

V padesátých letech 20. století Alan Turing – britský matematik vynalezl test na umělou inteligenci (Turing, 1950). Otázka tohoto testu zní, zda testovaný systém vykazuje známky inteligentního chování či nikoliv. Test je založen na principu imitační hry. Hru hrají tři hráči: hráč X dostává informace od dvou hráčů A a B v podobě psaného textu. Hráči jsou rozdílného pohlaví, jeden z hráčů je muž a druhý žena. Úkolem hráče X je přiřazení, který hráč je muž a který žena. Muž má snahu překazit výhru hráče X a žena má opačnou snahu, tzn. aby hráč X vyhrál. Dle Turingova testu je systém inteligentní, pokud dokáže úspěšně hrát dle strategie muže. Závažným kritickým argumentem je, že sice test měří schopnost simulace myšlení, ale nevypovídá nic o vlastní inteligenci počítače. Tudíž by se tedy měla měřit i míra inteligence způsobu řešení úlohy, nikoli pouze výsledek. Pokud má nějaký program úspěšně absolvovat Turingův test, musí jeho programové vybavení odrážet realitu lidského myšlení. Aby program měl úspěšný výsledek, musí tedy být vybaven poznatky o lidském myšlení, které dokáže použít podobně jako člověk. V dnešní době se Turingův test používá zejména v oblasti bezpečnosti. Test má odhalit, zda testovaný objekt není robot. Opisování čísel do formuláře pro test CAPCHA je dnes už běžnou praxí. Sofistikovanější testy už používají rozeznávání obrázků, kde má subjekt vyhodnotit, na kterém obrázku je hledaný objekt, např. automobil (Brodic a Amelio, 2020; Nath, 2020).

2.4.1 Systém ELIZA

Turingův test prověřoval systém ELIZA, který je dostupný na internetu. Tento systém se snaží imitovat komunikaci s psychiatrem. Dle Turingova testu, pokud člověk komunikuje s tímto programem, může uvěřit, že komunikuje s jiným člověkem. Eliza má v databázi seznam klíčových slov, s kterým porovnává slova a věty (Mařík, 1991).

Algoritmus systému Eliza

1. Vstup od uživatele;
2. hodnocení slov ve větě;
3. mezi slovy ve větě alespoň jedno klíčové slovo? ne? pokračování bodem č. 5;
4. vybrat nejdůležitější z klíčových slov;
5. zda není použita reakce na nejdůležitější slovo, pokračování bodem 8;
6. použití reakce na uživatele;
7. pokračování 1. bodem;
8. použití reakce na minulé slovo, pokud ne, pokračování bodem 11;

9. použití reakce ze zásobníku;
10. pokračování bodem 1;
11. použití náhradního východiska;
12. pokračování bodem 1.

2.5 Expertní systémy

Expertní systémy jsou počítačové programy, které napodobují rozhodovací proces experta při řešení složitých úloh a využívající vhodně zakódovaných, explicitně vyjádřených znalostí, převzatých od experta, s cílem dosáhnout podobné rozhodovací úkony jako počítačový expert. V minulosti se například v MS Office používala chytrá sponka. Byla to funkce, která radila, co by měl člověk dělat jako další krok v programu. Sponka nebyla nějak zvlášť inteligentní. Na tomto příkladu se dá ukázat jednoduchý model expertního systému. Je to program, který má konečnou množinu různých situací a reakcí na ně. V historii se expertní systémy používaly například pro stanovení lékařské diagnózy (Luger, 2011).

Výhody expertních systémů

- Schopnost řešit složité problémy;
- dostupnost expertíz a snížené náklady na jejich řešení;
- trvalost a opakovatelnost expertízy;
- trénovací nástroj pro začátečníky;
- uchování znalostí odborníků.

Nevýhody expertních systémů

- Nebezpečí selhání ve změněných podmínkách;
- neschopnost poznat meze své použitelnosti.

2.6 Neuronové sítě

Neuronové sítě jsou struktury, které jsou inspirovány biologickými vzory. Jejich hlavní úloha je simulace a implementace některé funkce lidského mozku. Jedná se zejména o funkce adaptace a učení.

Mezi největší výhody neuronových sítí patří paralelizmus při vlastních výpočtech. Neuronové sítě se používají na úlohy směřované do oblasti klasifikace, aproximace a predikce. Svůj prapůvod mají v biologické oblasti. Neuronová síť je složena z mnoha jednoduchých procesorů – perceptronů.

Při prvních počítačových modelacích se začala tato cesta ukazovat jako ta správná k umělé inteligenci. Model mohl vypadat třeba takto: malé množství neuronů bylo propojeno s virtuálními synapsami a k některým byla přidána tlačítka, k jiným výstupy (např.

žárovky). Postupně se neuronům předkládal učební materiál, kde byly různé vstupní stavy a odpovědi na ně. Učením se signály někde posílily a jinde ztlumily. Síť se poté dokázala naučit reagovat i na vstup, který nikdy neviděla v učebním materiálu (Luger, 2011).

2.6.1 Princip neuronových sítí

Do neuronu vstupuje n -spojů (axonů), ve formě jiných neuronů nebo jako podněty z okolí, i -tým spojem vstupuje informace ve formě reálného čísla x_i . Jedná se o vstupy, které mohou být například: rychlost, barva, tlak a teplota. Vstupy charakterizují objekt, kterého se výzkum týká. Každý spoj, který se zde nachází, je vybaven reálným číslem w_i , který nese informace o důležitosti konkrétního spoje. Každý neuron je také vybaven prahem. Vážený součet udává celkový podnět neuronu tzv. potenciál neuronu. Na potenciál reaguje neuron odezvou na svém výstupu. Výstup má velikost Z a předepsanou nelineární přenosovou funkci S . Tvar přenosové funkce může být různý. U neuronových sítí lze použít jakoukoliv rostoucí diferencovatelnou funkci. Sítě, které obsahují mnoho neuronů, lze rozdělit dle mnoha faktorů. Prvním faktorem je struktura sítě. Druhý faktor je způsob práce sítě. Dle prvního faktoru jsou sítě rekurentní, které mají cyklický graf, tzn. výstupy se vracejí jako vstupy zpět do sítě. Ostatní sítě jsou vícevrstvé, které mají neurony rozdělené do vrstev. Výstupy neuronů předešlé vrstvy slouží jako vstupy neuronů do další vrstvy. Spodní vrstva sítě je vstupní, naopak horní vrstva je výstupní (Basheer a Hajmeer, 2000; Mařík, 1991).

2.7 Řešení problémů

Inteligentní systém by si měl umět vytvořit vnitřní model světa a pracovat s ním. Při řešení problémů máme dán počáteční a cílový model prostředí. Za pomoci inteligentního systému je potřeba realizovat takovou posloupnost akcí, kdy při jejich aplikaci dojde od počátečního k cílovému stavu. Každý řešený model má svůj určitý stav prostředí, který mu odpovídá. Tento stav se nazývá stavový vektor a množina těchto vektorů se nazývá stavový prostor řešení. Cílových stavů může být v dané úloze několik a mohou být vyjádřeny podmínkami, které musí splňovat. Při řešení problémů se v počátku začne celé řešení formulovat na jeden konkrétní cílový stav.

Pro úspěšné hledání prostorů stavů musí být splněny dle Russell a Norvig (2014) tyto předpoklady:


- dobře rozeznatelná struktura symbolů;
- operátory, které umožňují transformaci jedné struktury na druhou pro úplné prohledání celého prostoru;
- efektivní řídicí strategie, dle kterých se vykonávají jednotlivé transformace.

2.7.1 Systematická strategie

Systematická řídicí strategie musí splňovat dvě základní podmínky:

- nevynechat žádný z objektů;
- žádný objekt nevybrat dvakrát.

Příklad systematické řídicí strategie: Na čtvercové hrací desce s možnými devíti pozicemi je rozmístěno osm číselných kamenů viz obrázek 2.1 (Russell a Norvig, 2014). Jedna pozice je tedy neobsazena. Rozmístění kamenů na začátku hry může být různé a považujeme tento stav za počáteční. Účel hry je rozmístění kamenů do cílového stavu. Cílový stav je jediný a vypadá tak, že čísla jdou postupně od 1 do 8. Každý stav úlohy je definován polohou kamenů. Každý posun kamenů je přechod mezi stavy, tudíž změna stavového vektoru. Podle toho, jaká je úroveň řešení problémů v prohledávání stavového prostoru, rozlišujeme algoritmy informované a neinformované (Russell a Norvig, 2014).



Obrázek 2.1: Systematická strategie

Algoritmus prohledávání šířky

1. Zápis počátečního stavu do seznamu OPEN, seznam CLOSED je prázdný. Zda-li je počáteční stav a cílový shodný, ukončit hledání.
2. Je-li seznam OPEN prázdný, řešení neexistuje, ukončí se hledání.
3. Označit stav v seznamu OPEN symbolem i , ze seznamu OPEN se vymaže a zapíše se do seznamu CLOSED.
4. Expandovat stav i . Zda-li tento stav nemá následovníky nebo byli všichni expandováni, pokračování krokem č. 2.
5. Zápis všech následovníků stavu i , kteří nejsou v seznamu CLOSED na konec seznamu OPEN.
6. Pokud některý z následovníků stavu i je cílovým stavem, řešení je nalezeno a ukončí se prohledávání, jinak pokračování krokem č. 2.

2.7.2 Neinformované metody prohledávání stavového prostoru

Neinformované metody prohledávání stavového prostoru jsou charakteristické svým řešením pořadí, ve kterém jsou expandovány hrany grafu na prohledávání do hloubky a šířky. Při prohledávání do šířky se expanduje uzel s minimální hloubkou, největší prioritu mají vrcholy, které jsou nejbližší k počátku vrcholu grafu. Vrcholy grafu se prohlíží na úrovních stejné hloubky. Při prohledávání do hloubky se expandují vrcholy grafu takovým způsobem, že nejdříve se vybere vrchol s největší hloubkou tak dlouho dokud to jde a poté

se mechanismus vrátí o jeden krok zpět a následně pokračuje do hloubky (Russell a Norvig, 2014).

2.7.3 Informované metody prohledávání stavového prostoru

Informované metody prohledávání často používají k výběru nejvhodnějšího vrcholu různé typy řešení. K rozhodnutí, který uzel grafu bude expandován se používají různé hodnotící funkce. Platí, že čím kvalitnější jsou počáteční znalosti o problému, tím lépe je použita funkce k formulaci hodnotící funkce a tím efektivnější bude prohledávání (Russell a Norvig, 2014).

2.8 General problem solver

General Problem Solver (GPS) je jedna z kvalitativních heuristik. Heuristika byla navržena v roce 1959 jako model lidského konání při řešení problémů. Metoda funguje na principu analýzy prostředků a cílů. Následuje koncentrace na určení rozdílů mezi aktuálním a cílovým stavem prostředí. Pokud existuje diference, systém vyhledá její redukci. Pokud se nalezený operátor nedá aplikovat na aktuální stav, systém se snaží dostat do stavu, kdy aplikace bude možná. Po aplikaci se může naskytnout stav, který není cílový. Proto je nutné dostat se od aktuálního stavu k cílovému. GPS funguje na prostoru stavů. Diference je vlastnost, která je rozdílem dvou stavů. Pro řešení je potřeba sestavit tabulku diferencí a operátorů – systém si utřídí, jaký operátor se použije na danou diferenci.

Tři základní procedury

1. TRANSFORM – sestavuje a řeší podúlohu, která převádí současný stav na cílový
2. REDUCE – navrhuje pravidlo, které buď odstraní nebo alespoň zmenší diferenci mezi současným a cílovým stavem
3. APPLY – aplikuje vybrané pravidlo na daný stav

(Russell a Norvig, 2014)

2.8.1 Činnost GPS systému

Vybereme maximální možnou diferenci mezi stavy a dle tabulky diferencí a operátorů je vybrán příslušný operátor. Ten buď je nebo není aplikován. Když není aplikován, musí se formulovat podproblém, na který je možné operátor aplikovat. Další maximální možná diference je mezi dvěma po sobě jdoucími stavy a celý postup je zopakován. Nevýhodou systému je, že uživatel musí nadefinovat diference, následně udělat uspořádání podle velikostí a nastavit pravidla za jakých se budou diference používat (Russell a Norvig, 2014).

2.8.2 Příklad využití GPS

Příkladem využití může být jednoduchá mechanická hračka. Jedná se o auto, které jezdí po stole. Při řešení problému musíme nejprve definovat stavy: POVRCH A HRANA. Dále se definují diference: D1 (POVRCH, HRANA), D2 (POVRCH, POVRCH) viz obrázek 2.2 (Russell a Norvig, 2014).

Akce/Diference	D1	D2
POHYB-VPŘED		x
OTOCENI	x	

Obrázek 2.2: Příklad definice GPS

Pokud nastane diference POVRCH, HRANA hračka se nachází na hraně stolu a musí provést otočení. Pokud je diference POVRCH, POVRCH hračka jede dále dle příkazu POHYB-VPŘED (Russell a Norvig, 2014).

3 Řízení dopravního provozu

3.1 Nástup umělé inteligence v dopravě


Když se před zhruba sto lety objevily na silnicích semaforey, nebyla hustota provozu tak velká jako v současné době. Silnice jsou nebezpečné a dopravní nehody ročně zabíjí spousty lidí. I proto je snaha zavádět do provozu inteligentní řešení, která by provoz činila jednak plynulejším, ale i bezpečnějším. V současné době je trendem zavádět umělou inteligenci jednak do řízení dopravního provozu, ale také do samotných autonomních vozidel. Umělá inteligence se musí zavádět do současných silničních sítí, a ty mají své limity, proto je také trendem co nejefektivněji využívat prostor silniční infrastruktury. Nové technologie by nám měly pomoci jezdit úsporněji. Pokud si představíme typickou situaci, kdy na semaforu padne zelená a první automobil vyjede, ve druhém automobilu řidič píše zprávu a nezareaguje na zelenou barvu, třetí automobil už kvůli němu musí brzdit. Takových neefektivních situací je v provozu spousta. Ve výsledku pak projede křižovatkou mnohem méně automobilů, než by teoreticky mohlo. Kdyby se například podařil rozjezd z křižovatky sladit tak, aby probíhala komunikace mezi semaforem a automobilem, byla by efektivita provozu na vyšší úrovni. Všechny stroje se musí umět mezi sebou domluvit a k tomu by měl sloužit sdílený jazyk, který je základem zavádění umělé inteligence (Cejnarová, 2018b).

3.2 Způsob modelování křižovatek

Správa křižovatek je jedním z nejnáročnějších problémů v dopravním systému. S vývojem inteligentních systémů v dopravě a automobilismu musí probíhat vývoj i v řízení křižovatek. Je snaha, aby se provázala komunikace mezi řidiči, infrastrukturou a střediskem řízení dopravního provozu. Průsečíky trajektorií vozidel jsou jedním z největších problémů v rámci udržení bezpečnosti a plynulosti provozu. Ačkoliv je křižovatka poměrně malá část v celém silničním systému, jedná se poměrně často o místo vzniku dopravních nehod. Zavedení semaforů v řízení provozu pomohlo zlepšit dopravní stav na křižovatkách, v současnosti je však snaha zavádět systémy koordinovaného adaptivního provozu, které fungují na základě odhadu. Při vývoji jsou zaváděny senzory do vozidel, aby systém mohl snímat polohy a trajektorie vozidel. U autonomních vozidel se vyvíjí systémy, které umožňují projet křižovatkou bez zásahu řidiče.


Způsob, jakým vnímají inteligentní systémy křižovatky, je takový, že křižovatky jsou zobrazovány pomocí dlaždic viz obrázek 3.1 (Chen a Englund, 2016). Čím více má křižovatka dlaždic, tím větší je možnost, aby více vozidel mohlo projet křižovatkou a neseťkaly se jejich trajektorie. To významně přispívá i k plynulosti provozu. Na obrázku a) je vyob-

razená čtyřcestná křižovatka s jedním přímým provozem z každého směru a potenciální vznik průsečíku by mohl vzniknout na 20ti dlaždicích. Na obrázku b) je čtyřcestná křižovatka s kruhovým objezdem, která má 24 dlaždic. Na obrázku c) je čtyřcestná křižovatka s možností jízdy doleva, doprava i přímo. Tato křižovatka má 64 dlaždic, tudíž je nejnáročnější na řízení provozu. Pokud máme v modelech křižovatek co nejmenší dlaždice, můžeme lépe vytvářet modely provozu, ale zavádí se zde složitější algoritmy.



Obrázek 3.1: Příklady modelování křižovatek

Po vykreslení křižovatek pomocí dlaždic si musí systém vymodelovat možné trajektorie jízdy vozidel křižovatkou viz obrázek 3.2 (Chen a Englund, 2016). Na čtyřcestné křižovatce, obr. c) jsou znázorněny správné a špatné trajektorie. Obrázek ukazuje, že systém hodnotí tuto křižovátku tak, že pokud pojede vozidlo trajektorií 1, není zároveň možná trajektorie 5, ale například trajektorie 2 a 4 možná je (Chen a Englund, 2016).



Obrázek 3.2: Příklady modelování křižovatek s různými trajektoriemi

Předpoklady pro správnou funkci inteligentních systémů

1. Křižovatka zahrnuje účastníky silničního provozu.
2. Při řízení provozu se dodržuje průniková geometrie a pravidla silničního provozu.
3. Vozidla, která jsou řízena, jsou vybavena zařízeními pro výměnu informací.
4. Komunikace mezi vozidly je bez přenosových zpoždění a funguje ideálně.
5. Vozidla jsou schopna přesně reagovat na řízení systémem.
6. Automobily jsou na vysoké úrovni v rámci automatizace.
7. Vozidla nedělají žádné nepředpokládané úkony.

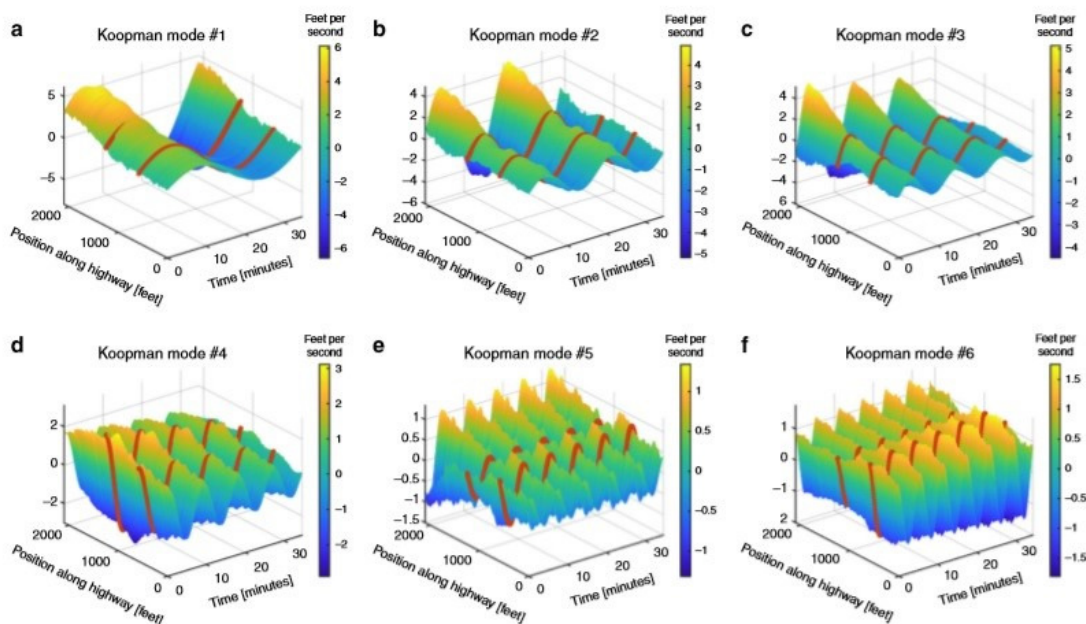
3.3 Analýza a predikce dynamiky silničního provozu pomocí umělé inteligence

Jelikož je do dopravního systému zapojena spousta nepředvídatelných faktorů, jako je např.: interakce člověka a počasí. Lze očekávat, že predikce silničního provozu je velmi komplikovaná a jedná se o nelineární dynamický systém. Je proto obtížné vyvinout nějaký matematický systém či systém umělé inteligence, který by dokázal popisovat časový vývoj dopravních systémů. Přetížení silniční dopravy stálo v přímých a nepřímých ztrátách USA 124 miliard dolarů. Tato finanční zátěž je mnohem vyšší než v evropských zemích a očekává se, že pokud neproběhne vývoj inteligentních dopravních systémů, budou se náklady neustále zvyšovat. Analýza byla v dřívějších dobách předpovídána pomocí matematických modelů – tyto modely však nedokázaly dynamicky reagovat na změny. Postupem času došlo ke zlepšení v dostupnosti dat, moderních možnostech zpracování a vývoje strojového učení. První třídou datově řízených algoritmů byly především parametrické modely, které dokáží přesně odhadnout parametry modelu. V poslední době spíše roste zájem o neparametrické modely, které fungují tak, že informace získávají z historických údajů. Většina publikované literatury v tomto oboru se zaměřuje na konkrétní systém. Málo se však uvádí problémy se zobecněním matematických modelů a problémy s implementací v reálném provozu. Moderní metody závisí na přesných parametrech a ke svojí funkci potřebují velké množství dat, které je obtížné a finančně náročné nasbírat. Je velmi náročné vytvořit systém, který by byl univerzální a fungoval napříč různými dálnicemi.

První pokusy o naprogramování inteligentního systému byly prováděny na základě zkoumání dopravy v USA, Velké Británii a Německu. Toto mezinárodní srovnání bylo z hlediska dynamiky provozu zajímavé tím, že se jedná o různé infrastruktury, kombinaci tříd vozidel, pravidel provozu a odlišné chování řidičů. Při zkoumání dopravních infrastruktur v jednotlivých státech se projevil značný rozdíl v chování provozu. Z tohoto výzkumu vyplývá, že systémy nejsou nepřesné, ale příliš závislé na konkrétních parametrech. Napříč vývojem dopravních systémů je jich proto mnoho vyvinuto takových, které se nedokáží globálně implementovat. Pravděpodobně nejsložitější situace, kterou je potřeba predikovat, je provoz na vícepruhové dálnici. Situaci ještě více ztěžuje velmi rozdílná dynamika provozu v závislosti na dni v týdnu, víkendu či svátku. Na dálnicích bývá na omezeném prostoru mnoho senzorů, které snímají jeden pruh a jsou dimenzovány pro konkrétní lokalitu. Při změně lokality musí procházet rozsáhlým přeškolením (Avila a Mezic, 2020).

3.3.1 Koopmanova metoda

Koopmanovi operátory je skupina nekonečných lineárních operátorů, které popisují dynamiku pozorovaného systému v čase. Měření pomocí tohoto operátoru lze použít k interpretaci základní dynamiky komplexního systému prostřednictvím spektrálních vlastností. Koopmanova metoda dokáže popsat dynamicky důležité časoprostorové vzorce v datech a vyhodnotit, jak se tyto veličiny vyvíjejí (opakují, rostou nebo se rozkládají) viz obrázek 3.3 (Avila a Mezic, 2020). Tato metoda využívá sledování jednotlivých vozidel, nikoli však rychlost nebo hustotu toku vozidel. Výsledkem Koopmanovi metody jsou grafy jejich sloupce odpovídají času, řádky náleží poloze podél dálnice a záznamy obsahují rychlost, hustotu nebo tok v místě a čase.



Obrázek 3.3: Koopmanova metoda

Koopmanova metoda velmi dobře zvládá i analýzu vícepruhých silnic, jelikož se jedná o metodu, která lze velmi dobře zobecnit a přizpůsobit jakékoliv situaci. Data o více jízdnicích pruzích jsou snímána tak, že se vytváří obraz pro jednotlivé pruhy a je přidána extra prostorová souřadnice, která určuje pruh (Avila a Mezic, 2020).

3.4 Systémy v řízení dopravního provozu

3.4.1 Systém CPS

Zkratka CPS znamená cyber-physical-system. Počet automobilů stále roste a hustota provozu se zvyšuje zejména ve městech, kde provoz způsobuje největší komplikace. Extrémní počet automobilů s sebou nese spoustu problémů od emisí, úmrtnosti při dopravních nehodách a v některých městech, která nejsou dimenzována na takový nápor, vznikají dopravní kolapsy. Roku 2006 Německá akademie technických věd představila systém CPS. V tomto systému se integrují fyzická zařízení a informace do jedné sítě, senzory vysílají signály a komunikační weby přijímají informace o fyzických stavech prostředí. Tento systém se vyznačuje přítomností výpočetní jednotky v každé fyzické složce, vysokou adaptivitou, vysokým stupněm automatizace a spolehlivým provozem při vysoké stabilitě. CPS hraje velmi důležitou roli v budování systému ITS (Intelligent Transport Systems). Jedná se zejména o řízení autonomních bezpilotních vozidel v městské infrastruktuře. Pro autonomní vozidla v současnosti není problém téměř přímočarý pohyb po dálnici, avšak v okamžiku, kdy se vozidla ve městě pohybují různými rychlostmi a kříží se jejich trajektorie, nastávají komplikace. Systém by mohl také zvýšit účinnost využívání silniční sítě, přerozdělit tok vozidel, minimalizovat dopravní zácpy. Všechny tyto aspekty vedou ke snížení emisí. Existují dvě strategie, pomocí kterých lze řídit dopravu. Systém CPS využívá centralizovanou strategii. Znamená to, že všechny objekty v dopravním provozu

jsou spojeny do jednoho systému. CPS systém ví, jakou cestou se budou vozidla pohybovat a vyvaruje se střetnutí jejich trajektorií pomocí optimalizace trasy jednotlivých automobilů. Vozidla si vyměňují informace v reálném čase a tím se zajišťuje plynulý provoz. Systém CPS uvažuje, že řízení pomocí centralizované strategie by bylo mnohem efektivnější, než současné řízení pomocí semaforů (Chuprov et al., 2019).

3.4.2 Řízení provozu pomocí systému DSRC

Ve velkých městech se stále zvyšuje hustota provozu a někdy může být doba jízdy z jednoho konce města na druhý delší než 2 hodiny. Semaforey jsou v městském provozu již nedílnou součástí. Jejich role je významná a pomocí nich se dají řešit situace na velkých křižovatkách. Existuje celá řada metod řízení semaforu od kamer po smyčkové detektory. Většina semaforů je však řízena neefektivně pomocí časovačů. I přesto, že se zdá tento způsob jako spravedlivý, má nízkou efektivitu z toho důvodu, že v průběhu dne je provoz nerovnoměrný a mění se jeho charakter. Proto by systém řízení měl být pružný a měl by reagovat na změny provozu. Název inovativního systému je DSRC (komunikace pomocí signálu na krátkou vzdálenost). Tento systém využívá přítomnost signálů ze zařízení, která jsou ve vozidlech. V případě, kdy vozidlo, které má toto zařízení vysílající signál, se blíží ke křižovatce, semafor tato vozidla zaznamenává a snaží se efektivně vyhodnotit situaci tak, aby křižovatkou mohlo co nejdříve projet co nejvíce automobilů najednou. Díky tomu se může výrazně snížit čekací doba na každé křižovatce. Čas, který lidé stráví v městském provozu v dopravní špičce při dojíždění do práce se může tímto podstatně snížit. Při průzkumu se ukázalo, že se časy snížily o více než 30 %. To vede také k úspoře vyprodukované uhlíkové stopy. Výhodou tohoto systému jsou nízké náklady. Instalaci by si mohla dovolit i menší města. Zavedení této technologie pravděpodobně nebude rychlé, jelikož se musí zařízení vysílající signál namontovat do vozidla. Tato technologie má také výhodu v tom, že by nemusely být velké zásahy do současných systémů, pouze by se DSRC radiostanice připojila na současné fungující semaforey. I z tohoto důvodu je tento systém několikanásobně levnější než jiné systémy využívající umělou inteligenci (Federal Communications Commission, 2019; Tonguz a Zhang, 2020).


3.4.3 Řízení provozu metodou SCOOT

Spousta metod funguje na základě toho, že se hledá co největší poměr zelených vln na co nejvyšším počtu křižovatek, které jsou řízené chytrými systémy. Hlavním cílem metody SCOOT je přiblížit se situaci co nejmenších front před křižovatkami. Metoda také omezuje počet zastávek, každá zastávka znamená finanční i energetické znevýhodnění. Klíčové principy, na kterých funguje metoda SCOOT:

1. měření provozu v reálném čase;
2. průběžné aktualizace online modelů front;
3. optimalizace nastavení konkrétních semaforů na jednotlivých křižovatkách.

Provozní údaje pro řízení křižovatky se sbírají každou sekundu pomocí indukčních senzorů umístěných těsně před křižovatkou. Po zařazení automobilů do fronty systém SCOOT vyhodnotí charakter provozu a reguluje provoz křižovatky. Po vyhodnocení se zvolí, v jakém režimu bude systém pracovat a dále ještě dochází k jemnému doladění cyklů se

zavedením časového zrychlení nebo zpoždění cyklu až o 4 sekundy. Obvykle se tak optimalizuje chod systému až 10 000 krát za hodinu. Systém SCOOT byl testován pět měsíců v Glasgow, Worcesteru a Londýně. Po testech dopravní úřady vyhodnotily, že nově zavedený systém oproti standardnímu řízení křižovatek vykazuje průměrnou úsporu času 12 %. V mnoha situacích se ale ukázalo, že úspora byla vyšší, až 20 %. Z průzkumu bylo patrné, že tento systém bude nejvýhodnější využívat tam, kde bude silný a složitý provoz, který se rychle a nepředvídatelně mění. Součástí systému je i databáze která uchovává informace o tom, jak se v minulosti provoz vyvíjel a jak vypadají jednotlivé časové cykly v závislosti na hustotě provozu viz obrázek 3.4 (Robertson a Bretherton, 1991). Vývojáři se snaží, aby byla do systému zařazena i funkce, která by detekovala potřebu uvolnit křižovatky pro případ projetí vozidel záchranných složek.



Obrázek 3.4: Diagram metody SCOOT

Podle diagramu na obrázku 2.4 se hledají nejlepší způsoby koordinace. Na ose X je čas a na ose Y je prostor. Obvykle se programují nejméně čtyři časové plány, které odpovídají ranním, poledním, odpoledním a nočním podmínkám. Zvláštní plány mohou být naprogramovány pro případ různých kulturních akcí a festivalů (Robertson a Bretherton, 1991).

3.4.4 Systém DALI

Systém DALI slouží pro vysoce dynamické dopravní podmínky. Navrhovaný systém byl určen k nasazení do měst s minimálními změnami infrastruktury. Model je založen na používání aktuálních parametrů a časů. Zařízení, která jsou instalována na křižovatkách, komunikují prostřednictvím přímých signálů bez dohledového systému. Agenti mají naprogramované znalosti v dopravní síti. Dostávají informace o provozu a podle toho vyhodnocují výsledky a upravují chování řídicích systémů. Systém funguje na principu toho, že sleduje jednotlivá vozidla a vyhodnocuje pravděpodobnost, jak by se mohla jednotlivá vozidla pohybovat, jaká je hustota provozu a jaké jsou možnosti řízení na jednotlivých křižovatkách. Systém dokáže přímo simulovat dopravní síť z Open Street Map a využívá pokročilé algoritmy pro chybějící informace, například v případě neznámé cesty (Torabi et al., 2018, 2020).

3.4.5 Detekce vozidel pomocí akustického snímání

Detekování vozidel je jedním ze stěžejních úkolů, který musí zvládat každý systém, který se dá považovat za řízený pomocí umělé inteligence. Tento systém využívá akustické snímání a používá se pro odhad rychlosti vozidla v reálném čase. Celé podstata je principiálně podobná Reyleighovu rozptylovému světlu. Technologie využívá snímací vlákno ve formě akustických senzorů. Z informací lze vyčíst i kategorizace vozidel a odhad počtu. Provede se extrakce okolních prvků a systém získá informace o počtu vozidel a jejich okamžité rychlosti. Při dvouletém testování se ukázalo, že přesnost detekce vozidla je vyšší než 80 %. Chybovost při odhadování rychlosti je menší než 5 %. Přesnost při klasifikaci vozidla je vyšší než 70 %. Tato metoda se zatím nepoužívá a je ve fázi výzkumu (Liu a Ma, 2020).


3.4.6 Magnetický senzorový systém

Magnetický senzorový systém má dvě konfigurace. První z nich vyžaduje zakopání detekčního zařízení pod silnici a tudíž je nákladnější. Při druhé konfiguraci se zařízení montuje na okraj silnice a instalace je méně technicky a finančně náročná. Hlavní rozdíl mezi konfiguracemi je ten, že když se magnetické senzory zakopou pod vozovku, mají silnější signál. Systém funguje na principu změn magnetického pole na Zemi. Extrakce předmětů, které potřebuje systém vytěsnit ze svého zaznamenávání, funguje na základě jednoduchého principu, jelikož neferomagnetické objekty systém nezaznamená, díky tomu nemusí být extrakce prováděna elektronicky. Typ vozidla lze určit pomocí fluktuace magnetického pole. To znamená, že systém zná nějakou střední hodnotu a typ vozidla určuje pomocí detekce kolísání této hodnoty.

Výhody

1. Díky principu magnetických změn není detekce ovlivněna změnami klimatu.
2. Jednoduchá extrakce nežádoucích objektů a detekce vozidel.

Senzory jsou většinou nastaveny pro snímání každého směru vozovky zvlášť. Ve městech však nastává komplikace, jelikož kvůli úzké silnici a větší blízkosti protijedoucích vozidel se může stát, že systém zaznamená vozidlo jedoucí v opačném pruhu. Magnetické senzory jsou nastaveny na výšku 20 cm od povrchu silnice viz obrázek 3.5 (Wang a Zheng, 2018).



Obrázek 3.5: Systém měření na povrchu vozovky

Osa X je podél nebo proti směru pruhu, osa Y je kolmá ke směru pruhu a osa Z je kolmo k povrchu vozovky viz obrázek 3.6 (Wang a Zheng, 2018). Senzor v ose X zaznamenává buď vozidla ve směru jízdy nebo v protisměru. Při detekování vozidel senzor měří magnetické pole a přenáší data přes komunikační uzel do sběrnice dat (sink node) a poté se data přes sériový port přenáší do počítače. Obrázek znázorňuje, jak zjednodušeně vypadá systém měření na povrchu vozovky, který byl v takovéto podobě používán při experimentálním měření v Číně. Test proběhl na dvoupruhové vozovce, kde je riziko zaznamenávání falešných signálů. Rychlost vozidel se zde pohybovala od 32 do 67 $\text{km} \cdot \text{h}^{-1}$. Jak znázorňuje obrázek, zařízení bylo umístěno hned vedle jízdniho pruhu. Do standardní sestavy zařízení byla přidána videokamera, aby bylo možné ověřit výsledky vizuální kontrolou dle videozáznamu. Výsledky ukázaly, že za stanovený časový úsek jedné hodiny projelo 81 vozidel a systém jich zaznamenal 79. To odpovídá úspěšnosti 97,5 %. Systém detekoval

95 vozidel v sousedním pruhu. Reálně ale tímto pruhem projelo pouze 39 vozidel. Z toho vyplývá, že systém funguje poměrně spolehlivě pouze na měření jednoho směru jízdy, jelikož při měření obou směrů na vzdálenějším pruhu zaznamenává nadměrnou detekci. V tomto ohledu je úspěšnost pouze 41,1 %. Tento systém je ve fázi výzkumu (Wang a Zheng, 2018).




Fig. 2. Sensor node configuration diagram.

Obrázek 3.6: Princip magnetického sensorového systému

3.4.7 Inteligentní dopravní mobilní aplikace

Nová mobilní dopravní aplikace byla představena v rámci projektu C-Roads. Jedná se o aplikaci a vozidlovou jednotku, která umožňuje komunikaci mezi vozidlem a okolní infrastrukturou. Všeobecným cílem je zvýšení bezpečnosti na pozemních komunikacích. Aplikace by měla být k dispozici v rámci celé EU, včetně České republiky. Pomocí vozové jednotky dokáže komunikovat s aplikacemi v dalších vozidlech, ale také s dopravními značkami, železničními přejezdy, vozidly záchranného systému nebo semaforey. Mobilní aplikace řidiče upozorní na každé blížící se nebezpečí na dopravní trase. Principiálně funguje tak, že využívá tzv. hybridní komunikaci, která zahrnuje jednak vysokorychlostní mobilní síť, ale i Wi-fi pro automobily. Proměnlivá dopravní značení, servisní automobily či vozidla IZS vysílají informace do centrálních dopravních systémů a pokud aplikace vyhodnotí, že by se řidič mohl s touto situací setkat, dá mu signál. Výhodou je, že informace, které jsou vysílány do vozidla, nejsou od uživatelů aplikací, které často mohou být protichůdné. Systém využívá ověřené informace, které jsou manuálně zadávány, validovány a tříděny tak, aby se k řidiči dostali pouze informace, které jsou pro něj důležité.

Systém pracuje s pokročilými algoritmy, aby informace v aplikaci mohly případně řidiči i zachránit život (Vítek, 2020).

3.5 Google Maps a umělá inteligence

Google není jen vyhledávač, ale technologický gigant, který určuje směr a vyvíjí nové technologie. Podíl společnosti v oblasti dopravy má jejich aplikace Google Maps (Herwig, 2020). Strojové učení je v Silicon Valley téma č.1, kterou se vývojáři zabývají. Google například dokáže předpovědět chřipkovou epidemii rychleji než americká vláda. Vize společnosti je zavádění strojového učení do všech odvětví, kterými se zabývá. Vyvinul již spoustu aplikací, které mají podíl na současné úrovni využívání umělé inteligence, která se uplatňuje například i v Google maps.

– **DeepMind** Tato funkce je velmi ambiciózní a dokáže odhalit právě třeba chřipkovou epidemii nebo zvýšenou větrnou aktivitu. V běžné praxi, když se předpovídá šíření nákazy, funguje to tak, že pokud nemocný člověk navštíví lékaře, který zadá informace o nemoci do databáze a ve chvíli, kdy množství nakažených přesáhne určitou mez, je vyhlášena epidemie. Tento proces je však poměrně zdlouhavý a může trvat i několik dní, než se projeví epidemie.

Google zjišťuje chřipkovou epidemii pomocí umělé inteligence. Celý systém funguje tak, že sleduje klíčová slova v emailech a v internetových konverzacích. Pokud si lidé v jeden den častokrát píšou o potížích s nemocí, systém vyhodnotí, že se blíží epidemie.

Díky technologii Deepmind také vznikl program AlphaGo a AlphaZero. Alphago v roce 2016 porazil šampiona ve složité deskové hře Go (Silver et al., 2016), (Silver et al., 2017). AlphaZero porazil všechny ostatní programy v hraní šachů.

– **Google translate** Dříve překladač při zadání překládané fráze začal vyhledávat souhlasící vzory v databázích dokumentů. Mezi databázemi byla například i databáze Evropského parlamentu nebo OSN. Po nalezení klíčových frází začal systém vyhodnocovat nejlepší možný překlad. Podle způsobu překládání byla tato technologie pojmenována SMT – Statistical Machine Translation (Statistický strojový překlad). Překládání však bylo poměrně nepřesné, obecně byly překlady na velmi špatné úrovni.

Kolem roku 2016 přišla ve společnosti Google myšlenka zavedení strojového učení místo statistických algoritmů. V listopadu roku 2016 byl překladač přeprogramován na technologii Google Neural Machine Translation (GNMT - Neurální strojový překlad). Největší rozdíl je v tom, že dříve překladač překládal každé slovo a v současné době překládá celé věty, tudíž překládané texty dávají smysl. Překladač již pomocí strojového učení dokáže rozpoznat kontext věty a výsledky generuje jako celek. Překlad z češtiny v současnosti nejlépe pracuje s angličtinou. Probíhá vývoj, aby se přesnost zlepšovala i u dalších jazyků. V roce 2019 probíhaly testy ve Spojených státech napříč multikulturním obyvatelstvem. Výsledky dopadly velmi dobře. Z celkem 647 vět bylo 594 zcela správně přeloženo do španělštiny. V překladu do čínštiny bylo správně 522 překládaných vět. Google má vizi, že v budoucích letech se jejich úspěšnost bude blížit 100% míře (Turovsky, 2016).

– **Podíl českého vědce na vylepšení Google translate** Tomáš Mikolov je český vědec, který již spolupracoval s firmou Microsoft, Facebook a Google. Podílel se na vylepšení překladače Google Translate. Tomáš Mikolov se zejména zabývá obecnou umělou inteligencí (Slouka, 2019). Jedná se o systémy, které se dokáží samy učit a přizpůsobovat se novým podmínkám. Český vědec způsobil převrat ve zpracování jazyka počítačem, jelikož se podílel na vynalezení způsobu, pomocí kterého se slova převedou na čísla a počítač může sestavovat rovnice se slovy a může se s nimi přímo počítat (Mikolov et al., 2013a), (Mikolov et al., 2013b).

Tomáš Mikolov přišel na to, že jakékoliv slovo se pomocí jím vytvořeného matematického modelu dá transformovat na matematický vektor. Po převedení slov na čísla lze provádět matematické operace s částmi slov nebo s celými slovy. Jeden z prvních matematických příkladů, kterým ohromil vědce ve společnosti Microsoft, byl tento jednoduchý příklad: král - muž + žena = královna. Na tomto jednoduchém příkladu Tomáš Mikolov ukázal, že stačí od slova odečíst jeho vlastnost (faktor) a přičíst vlastnost jinou, čímž vznikne nový tvar slova.

Při zavedení nových technik práce s jazykem do překladače se eliminoval překlad nesmyslných vět. Díky tomu, že se začala reprezentovat slova jako unikátní řetězce znaků, přestala existovat možnost používat podobná slova nebo stejná slova s jinou koncovkou, která měla zásadní vliv na smysl celé věty. Díky modelaci slov pomocí vektorů vznikají mnohem plynulejší texty a překlad je několikanásobně rychlejší (Kytková, 2020; Stach, 2020).

– **Google Maps** Google Maps jsou nejznámější a nejvyužívanější virtuální mapy na světě. Byly spuštěny již v únoru roku 2005 a v současné době službu využívá více než jedna miliarda uživatelů. Samotné mapy nejsou nic převratného, ale v roce 2007 přišel Google s velkou novinkou a tou byla služba Street View (Frassi, 2020). V tu dobu se společnost rozhodla, že nafotí celý svět. Konkurence tuto vizi nebrala vážně, než se tak stalo. V dnešní době si můžeme již prohlédnout velké množství adres. Google kvůli aktuálnosti dat má několik automobilů, které snímají ulice a jsou každý den v provozu.

Společnost již pořídila více než 80 miliard unikátních fotografií. Kvůli třídění obrovského množství dat vznikl speciální tým Ground Truth, jehož cílem je automatizace získávání dat z pořízených snímků. Systém využívá strojového učení, které pomocí algoritmu dokáže s přesností 84,2 % rozpoznat název jednotlivých ulic, čísel popisných nebo i nápisy z výloh u obchodů. Systém dokáže písmena přečíst z čitelných fotografií, ale i z rozmazaných a nekompletních fotografií viz obrázek 3.7 (Myšák, 2019). Tato vlastnost a úspěšnost čtení je daleko před konkurenčními systémy.



Obrázek 3.7: Příklady fotografií pro čtení Google

V budoucnu by databáze mohla obsahovat fotografie všech ulic na světě a v plánu je zavedení funkce, kdy by aplikace dokázala vyhledat cílovou lokalitu na základě vlastní fotografie. Google v tomto odvětví nemá konkurenci a drží monopol (Myšák, 2019).

4 Chytrá města

4.1 Použití umělé inteligence ve městech

4.1.1 Co je to chytré město?

Chytré město je takové, když se do měst ve stávajícím stavu dodají chytré technologie a chytré aplikace, které napomáhají například: zachraňovat životy, bránit zločinu, řídit dopravu, šetřit čas a snižovat množství odpadu. Může působit pozitivně i pro vytváření dobrého prostředí pro podnikání. Chytrá města využívají zejména data a digitální technologie. Komplexní data, která se sbírají v reálném čase, umožňují sledovat události průběžně, od začátku do konce, pochopit, jak se mění poptávka a reagovat rychleji, levněji a efektivněji. Chytrá řešení mění zejména ekonomiku a řízení městské infrastruktury. Snižují náklady na sběr informací, vzorků o chování obyvatelstva. Chytrá města dávají zaměstnavatelům a všem občanům do rukou velký objem dat, s jejichž pomocí mohou efektivně optimalizovat stávající systémy. Komplexní obraz chytrého města tvoří tři základní faktory:

1. technologická základna – chytré telefony, senzory, vysokorychlostní komunikační síť, datové portály;
2. specifické aplikace – převedení surových dat do výstrah, akcí a řízení strojů;
3. veřejnost – veškeré aplikace a systémy budou fungovat pouze tehdy, pokud je veřejnost přijme a na jejich základě změní své chování a přemýšlení.

Pomocí výzkumu ve třech vzorových městech bylo zjištěno, že umělá inteligence ve městě zlepšuje hodnoty hned v několika oblastech:

1. snížení úmrtí v důsledku dopravních nehod o 8 až 10 %;
2. zkrácení reakční doby v případě mimořádných událostí o 20 až 35 %;
3. zredukování průměrné doby na dojíždění do zaměstnání či za jinými účely o 15 až 20 %;
4. snížení emisní stopy automobilů o 10 až 15 %.

Ve světovém měřítku se ukazuje, že bohatší městské oblasti se obecně rychleji transformují. Nejlepší transformaci zaznamenává Japonsko, kde mladá populace velice dobře přijímá nové digitální technologie.

Očekává se, že 60 % investic by mohlo přicházet od soukromých subjektů. Více než polovina počátečních investic ze strany veřejného sektoru by mohla přinést kladný

zisk buď v přímých úsporách, nebo v příležitosti k vytvoření dalšího zisku. Chytrá města mohou vyvolat nutnost transformovat některá průmyslová odvětví. Firmy, které vstoupí na trh chytrých měst, budou muset mít vyšší nároky na moderní technologie, implementování tvůrčího modelu financování a více se zaměřovat na občanskou angažovanost. Firmy by měly vyvíjet takové systémy, které rychle a pružně reagují na přání občanů (McKinsey Global Institute, 2018).

4.2 Transformace měst na 4.0

Současná města se potýkají s celou řadou úkolů, které je stále obtížnější řešit. Musí se zaměřovat na to, aby obyvatelstvo mělo dostatečné množství zdrojů (energie, čistá voda a čistý vzduch). Další faktory, které musí současná města omezovat, pramení z dopravy. Těmito faktory jsou nadměrný hluk, zvýšené emise a zvýšená nehodovost z důvodu přeplnění provozu. Tyto problémy se snaží řešit zaváděním umělé inteligence. V současné době se již staví nové budovy s využitím inteligentního softwaru BIM (Building Information Management). BIM je moderní inteligentní a informační model budovy pro správu projektů založených na modelu. Vlaky bez řidiče mají vyšší kapacitu. Energetické sítě se transformují do chytrých sítí, které zahrnují zvyšující se trend elektromobility v městské dopravě (smart grids). Propojení nejrůznějších městských infrastruktur vyvolá další vlnu zvýšení efektivity provozu města. Město 4.0 zahrnuje budovy, které se aktivně propojují s energetickou sítí na rozhraní zahrnující mobilitu nebo inteligentních systémů, které budou poskytovat užitečné informace například pro zlepšení kvality ovzduší (Schonig, 2019).

V praxi digitalizace znamená, že například projektanti vytvoří digitálního dvojníka reálného subjektu. Oba dvojníky vzájemně propojí za účelem vylepšení konstrukce, inženýringu, automatizace procesů, end-to-end reportování a analýzy. Trend dnešních technologií je simulace a prediktivní údržba. Tyto trendy se stávají stále snadnějšími a začleňují se do každodenních operací. V automobilovém průmyslu simulace vypadá například takto: dříve vývojáři vyrobili prototyp automobilu, havarovali s ním a zjistili slabá místa, upravili konstrukci a opět testovali upravenou konstrukci. Takto šel proces několika prototypů až ke spokojenosti konstruktérů. Při zavedení simulace se nejen tento proces velmi zrychluje, ale i zlevňuje a zjednodušuje.

Jeden z velmi zajímavých projektů jsou Helsinky 3D+, kdy se finské hlavní město rozhodlo, že vytvoří trojrozměrný obraz města pomocí technologií, které slouží k zachycování reality od softwarové společnosti Bentley Systems (City of Helsinki, 2019). Tento trojrozměrný obraz dokáže vytvářet koordinace, vyhodnocování možností, modelování a vytváření vizualizací. Cílem projektu je zlepšit interní služby a procesy. Získaná data pomocí systému budou využívána pro další rozvoj chytrého města. Při zavedení systému by měl městský model sloužit jako otevřená data k podpoře komerčního a akademického výzkumu i vývoje. Díky datům bude moci město řídit svou zelenou agendu tak, aby byla více zaměřena na udržitelný rozvoj a zdravé životní prostředí.

K tomu, aby velké množství dat z trojrozměrných obrazů fungovalo správně, musí spolu vzájemně propojené součásti dobře komunikovat. Trojrozměrná síť se propojí s jednotlivými částmi infrastruktury prostřednictvím cloudového operačního systému Siemens Mindsphere. Ze spodní vrstvy městské infrastruktury jako je energie, voda, doprava, bezpečnost, budovy a zdravotní péče, přicházejí data, která jsou odváděna do společného datového systému. Tam jsou prováděna analytická, preventivní a normativní opatření. Systém

Mindsphere dokáže zpracovat obrovské množství dat. Jakmile budou tato data k dispozici, otevřené rozhraní pro programování aplikací umožní společnostem a městským správám, aby přišly s tím, jak s daty naložit a jakým způsobem je využít pro potřeby občanů, městské dopravy apod. (McKinsey Global Institute, 2018).

4.2.1 Mindsphere – operační cloudový systém

Technologie pro internet věcí jsou považovány za ty, které nejvíce ovlivní celou naši společnost. Mindsphere je otevřený operační systém a cloudový server pro průmyslový internet věcí od firmy Siemens (Siemens, 2020). Slouží k propojování různých zařízení ke cloudu a sbírání dat. Zařízeními, která sekundárně cloud využívají, jsou všechny stroje používající se v chytrých továrnách, v řízení dopravní infrastruktury a v mnoha dalších odvětvích. Mohou to být i technologické celky nacházející se v energetice či v chemickém průmyslu nebo také pouze jednoduchý počítač, či senzor, který má schopnost sbírat data. Všechna tato zařízení potřebují data někde ukládat a k tomu slouží systém Mindsphere. Systém ale neslouží pouze jako úložiště, Mindsphere umožňuje s daty dále nakládat pomocí pokročilých analytických funkcí. Tyto aplikace vytváří přímo vývojář systému, společnost Siemens a nebo třetí strany, které mohou používat aplikace od vlastních vývojářů. Další možností je, že si aplikace vyvinou sami zákazníci.

Mindsphere tvoří tři základní vrstvy (McKinsey Global Institute, 2018):

Spodní vrstva slouží k připojení zařízení, ze kterých se sbírají data. Pro tuto úroveň bude k dispozici celá řada nástrojů, ať již softwarových či hardwarových. Připojení funguje na velmi jednoduchém principu, kdy není potřeba, aby si zákazník kupoval speciální hardware. Uživatel si pouze aktivuje funkci, která mu otevře šifrované připojení do cloudu.

Střední vrstva operačního systému tvoří samotné cloudové úložiště. V této oblasti Siemens spolupracuje s firmami jako SAP nebo Amazon Web Services, které poskytují vlastní cloudové služby. Zatím je systém provozován pouze na veřejných cloudech. V budoucnu by měl být k dispozici i cloud pro soukromé sektory.

Nejvyšší vrstva v tomto systému je vrstva aplikační, na jejímž vývoji se podílí i třetí strany. Vývojáři pracují na velkém množství aplikací v řadě odvětví. Aplikace, které vytvoří Siemens, budou zpřístupněny zákazníkům na Mindsphere Store. Jedná se o internetový obchod s kompletní nabídkou různých aplikací.

4.2.2 Spinwire

I v České republice se pomalu zavádějí chytrá řešení. Spinwire je systém, který je využíván například na veřejném parkovišti v Třebíči a v Písku. Parkoviště v Třebíči není nová výstavba, nýbrž se jedná o zrekonstruované parkoviště s chytrými řešeními. Spinwire je inovativní řešení s minimálními náklady na provoz a údržbu. Systém také sbírá data, která jsou otevřená. Spinwire je diskrétní, jelikož nevyužívá záznam obrazu, zvuku ani polohy telekomunikačních zařízení. Díky jeho instalaci pod zem nijak nenarušuje původní vzhled parkoviště. Je ekologický, jelikož řešení připojení k síti neprodukuje žádné použité baterie

ani náklady na jejich výměnu. Provozní náklady jsou opravdu nízké, příkon jedné kabelové pasivní detekční jednotky je 1 W.

Používání funguje jednoduše, přes aplikaci Spinpark.cz se můžou řidiči podívat, kolik míst k parkování je momentálně k dispozici. Také se zde nachází nabíjení pro elektromobily. K parkovišti řidiče navádějí proměnné dopravní značky, které ukazují aktuální počet volných parkovacích míst (Slavík, 2019).

4.2.3 Multiagentní systém pro dynamické umístění nabíjecích stanic elektrických vozidel

V současné době města preferují městskou dopravu s co nejnižší emisní stopou. Co se týče městských vozidel, jeví se jako ideálním řešením do města a příměstských oblastí elektromobil. Ve městech by na elektrickou energii mohla být poháněna nejen osobní vozidla, ale třeba i autobusy, taxi nebo vozidla pošty. Je navrhován multiagentní systém, který pomocí více agentů získává informace pro pozdější konfiguraci a lokalizaci dobíjecích stanic pro elektromobily. Všichni agenti jsou plně flexibilní a nabízejí služby, které lze opakovaně používat v různých městech.

Popis práce jednotlivých agentů

1. Městský agent – získávání informací o množství obyvatel v různých čtvrtích nebo blocích sledovaného města.
2. Dopravní agent – sbírání dat o provozu ve městě, díky sbíraným informacím je schopen tento agent odpovědět na otázku, jaká je právě hustota provozu v určité části města.
3. PoI agent – úkolem tohoto agenta je detekovat a klasifikovat místa, kde by mohl být zájem o dobíjecí stanici. Zároveň provádí tzv. klastrovací proces – eliminuje zajímavá místa, která jsou příliš blízko u sebe.
4. Agent popularity místa – úkolem tohoto agenta je určit popularitu bodu zájmu na základě počtu lidí, kteří jej navštíví a kolik času tito lidé na místě stráví. Ke sbírání těchto dat používá systém třetí stranu a tou je služba od firmy Google, která detekuje počet návštěvníků a čas strávený na místě.
5. Agent sociálních sítí – tento agent načítá data ze sociálních sítí, které mají informaci o lokaci, ze které jsou vysílány. Funguje podobně jako agent popularity místa, avšak tento agent používá k analýze sociální sítě.
6. Agent zpracování dat – tento modul je zodpovědný za shromáždění všech informací od předchozích agentů. Nеспециализује se na určitý typ informací, nýbrž provádí seskupení všech informací a dává je dalšímu agentovi.
7. Agent pro optimalizaci umístění – provádí optimalizaci algoritmu dle předchozích nasbíraných dat a hledá nejvhodnější možnosti.

Systém také využívá centralizovanou databázi, kde se provádí veškeré zpracování výsledků, které jsou dále zobrazovány v uživatelském rozhraní.

System provádí tři základní kroky. Prvním krokem je extrakce zájmových bodů města a jejich charakterizace s ohledem na různé zdroje informací. Druhý krok je aplikace algoritmu, který pracuje podle aktuálních podmínek. Závěrečnou fází je vizualizace výsledků.

Závěrečnou informací, která je systémem vyprodukována, je rozmístění dobíjecích stanic ve městě. System bere v potaz i další rozvoj města dle obecného plánu rozvoje. Obvykle algoritmus preferuje zejména veřejná parkoviště jak garážová, tak venkovní. U těchto míst obvykle nebývá problematické potřebné připojení k síti. V těchto lokalitách má umístění dobíjecí stanice mnoho výhod, např.: zvýšení atraktivity parkoviště, zvýšená návštěvnost. Ve městě Valencia je v současné době 24 dobíjecích stanic. Do roku 2050 chce město Valencia eliminovat konvenční pohonné hmoty ve městě a vybudovat plně funkční infrastrukturu dobíjecích stanic pro elektromobily. Proto byla provedena analýza jejich rozmístění (viz tabulka 4.1) (Jordan et al., 2018).

Tabulka 4.1: Oblasti pro potenciální umístění nabíjecí stanice a jejich charakteristika

Oblast	Nabíjecí režim	Časové vytížení	Strávený čas	Dostupnost
Nákupní centrum	Rychlonabíjení, pomalé nabíjení	Pracovní dny 19:00–22:00 a víkendy	1,2 h	Veřejné
Práce	Pomalé nabíjení	24 h	9 h	Veřejné i soukromé
Parkoviště	Pomalé nabíjení	24 h	2 h	Veřejné
Veřejná komunikace	Rychlonabíjení, pomalé nabíjení	24 h	1-12 h	Veřejné
Místní komunikace	Pomalé nabíjení	8:00–20:00	12 h	Soukromé
Soukromá garáž	Pomalé nabíjení	24 h	12 h	Soukromé
Čerpací stanice	Rychlonabíjení, výměna baterií	24 h	10 min.	Veřejné
Parkoviště firemních automobilů	Rychlonabíjení, pomalé nabíjení, výměna baterií	24 h	15 min.–12 h	Soukromé

4.2.4 Využití dopravního značení ve městech pro potřeby autonomních vozidel

Autonomní vozidla budou do budoucna nedílnou součástí života ve městech, jelikož velmi zvyšují komfort a bezpečnost dopravy. Autonomní vozidla se rozdělují dle úrovně automatizace.

Úrovně autonomity vozidel

0. Bez automatizace;
1. asistenční systémy;
2. částečná automatizace;
3. podmíněná automatizace;
4. vysoká automatizace;
5. plná automatizace.

Inteligentní automobilové systémy využívají radar, GPS, senzory vidění a dále ze získaných dat vyhodnocují navigační cesty a překážky. Jednou z technik počítačového vidění je Lane Assistant System (LAS). Videosenzor je umístěn z druhé strany zpětného zrcátka před čelním sklem. Aby systém fungoval správně, musí být splněna podmínka kvalitního dopravního značení. Systém nemusí fungovat správně, pokud jsou pruhy vybledlé nebo nesprávně značené. V zimních měsících, kdy je vozovka pokrytá sněhem, je také problém se snímáním pruhů. Obvykle se pro vidění pruhů využívaly různé algoritmy, které znaly plné nebo přerušované pruhy a podle toho vyhodnocovaly situaci. Existují i snímací techniky pomocí 3D modelů.

Ve výzkumu došlo k významnému posunu díky rozvoji strojového vidění pro silniční vozidla. Tato metoda procházela výzkumem a vývojem v posledním desetiletí. Vyvinutý automatický detektor by měl být schopen zvládat rovné i zakřivené pruhy, všechna značení pruhů (jednoduché, dvojité, přerušované). Měl by dokázat bezproblémově rozeznat pruhy i při zhoršených podmínkách (louže, skvrny či nízká viditelnost) (Matowicki, 2016).

4.3 Využití DIPT v městském prostředí

Digitální inovační a transformační proces zahrnuje analýzu a cíle digitalizace, zjišťuje a vyhodnocuje potřeby obyvatel ve městech pomocí vizuální analytiky. Existuje velké množství možností aplikace vizuálních analytických metod. Úkolem inteligentních technologií v chytrých městech je analyzovat obrovské množství dat. Statistické metody jsou omezeny na korelaci mezi shromážděnými daty. Tradiční metody jako například vizualizace, jsou také omezeny, jelikož nedokáží sledovat velký počet osob. Vizuální analytika je jedním z alternativních řešení pro analýzu velkého množství dat. Tato metoda zahrnuje analytické zdůvodnění, vizualizaci a interakci mezi počítači a lidmi.

4.4 Shromažďování dat pomocí sledování očí

V dnešní době se využívá sledování očí v různých aplikacích, které potřebují zjistit přesné chování uživatele. Metoda se využívá např. při marketingu nebo při zkoumání interakce člověk–počítač. Podle aplikace se zaznamenává specifický typ dat. Dostupné nástroje mohou zaznamenávat data rychlostí až 500 Hz (rychlost je počet detekovaných bodů za sekundu).

Typy dat pro metodu sledování očí

1. Kmit oka — rychlý pohyb oka, který vykazuje dobu fixace na jeden konkrétní bod (trvá až 80 ms).
2. Sledování — součet doby fixace v konkrétní oblasti.
3. Stimul — jedná se o oblast studia. Vizualní obsah, kde bude sledován pohyb očí. Může se jednat o 2D nebo 3D vizualizaci.
4. Zájmové oblasti — sledování chování vůči konkrétním oblastem, které mají pro sledované lidi velký význam.

Před analýzou očí by měl být proveden soubor kroků, které jsou nezbytné pro zkoumání. Prvním bodem je časová reference, která charakterizuje časovou osu, na které se bude výzkum provádět. Druhý bod je prostorová reference. Jedná se o stanovení prostoru, ve kterém bude výzkum prováděn. Jako poslední je potřeba vytvořit časoprostorovou referenci, ve které se vyhodnocuje např. počet návštěv a uživatelů, průměrný čas strávený na místě atd.

Vizualizační analýza využívá k zaznamenávání dat tři metody: tepelná mapa, časoprostorová krychle a pohledová linie.

4.4.1 Tepelná mapa

Tepelná mapa neboli mapa pozornosti poskytuje přehled agregace pohledu, aby se odhalilo, na který objekt oči ubírají největší pozornost. Pomáhá tak identifikovat hlavní oblasti zájmu. Mapa pozornosti barevně rozlišuje hlavní oblasti zájmu (viz obrázek 4.1).


Červené oblasti vykazují vysoký počet hledisek, z toho vyplývá, že se jedná o důležitou oblast zájmu. Naproti tomu zelené plochy ukazují body, které mají nízký počet pohledových bodů.



Obrázek 4.1: Tepelná mapa ve městě New York

4.4.2 Časoprostorová krychle

Metoda je alternativním přístupem pro časoprostorová data, rozšiřuje 2D prostorovou doménu do třetí dimenze přidáním třetí (časové) osy viz obrázek 4.2 (Wichmann a Sandkuhl, 2020). Zelená čára představuje časovou osu a body jsou promítnuty na boční stěny.



Obrázek 4.2: Výsledný obraz časoprostorové krychle

4.4.3 Trajektorie pohledu

Tato metoda sleduje, na jaké body se pohled zaměřuje a jakou dobu se na těchto fixačních bodech zdržuje. Výstupem této metody jsou kruhy, které označují fixační body viz obrázek 4.3 (Wichmann a Sandkuhl, 2020). Velikost těchto bodů určuje dobu fixace. Další informací je trajektorie pohledu, kterou vykreslují spojnice bodů, jenž mají posloupné číslice.



Obrázek 4.3: Trajektorie pohledu – internetová stránka

4.4.4 Příklady budoucího využití v praxi

Obchodní studie

Údaje o sledování očí při nakupování v supermarketu dokáží pomoci v pochopení nákupního chování jednotlivých osob. Analýzu pohybu očí lze vytvořit pomocí některé z výše popsanych metod. Sledování očí v obchodě může být prováděno buď pomocí vysoce výkonných kamer, nebo pomocí brýlí, které jsou zákazníkům poskytovány u vchodu do supermarketu. Pomocí těchto metod dokáže obchodník vyhodnotit, jak se zákazníci rozhodují v reálném čase, jak funguje navádění v obchodě, jak se zákazníci zaměřují na reklamní poutače atd.

Studie při řízení automobilu

Sledování očí by mělo přispět ke zvýšení bezpečnosti v silničním provozu. Jelikož počet automobilů na silnicích celosvětově narůstá, je potřeba volit chytré metody pro přispění k bezpečnosti. V budoucnu by mohly mít automobily zabudovaný integrovaný systém, který by sledoval oči řidiče a zároveň spolupracoval s bezpečnostními systémy. To přispěje k analýze dopravní situace a umožnění automobilu reagovat v reálném čase (Wichmann a Sandkuhl, 2020).

4.5 Nejzelenější londýnská budova

Příkladem jedné z chytrých staveb, které by mohly v budoucnu vznikat v chytrých městech je Crystal, kterou otevřeli v Královských viktoriánských docích. Je jednou z nejvíce nízkenergetických budov na světě. Toto výstavní a konferenční centrum je na vysoké úrovni co se týče inteligentních a ekologických řešení (McKinsey Global Institute, 2018).

Přehled chytrých řešení

1. Udržitelná architektura — vítěz platinového ocenění v metodice LEED a titul výjimečné stavby v metodice BREEAM za přísně udržitelný design a stavební normy.
2. Monitorovací a řídicí systémy — parametry budovy (energie, voda, údržba atd.) jsou trvale kontrolovány pomocí měřidel a čidel.
3. Přeměna solární energie — 1580 m² fotovoltaických panelů na střeše generuje 256 MWh/rok a ty pokrývají 20 % spotřeby energie.
4. Úprava černé odpadní vody – veškerá odpadní voda se využívá ke splachování a zavlažování zeleně.
5. Sběr dešťové vody – 87 % pitné vody v Crystalu pochází z dešťové vody, která se uchovává v podzemí a upravuje pomocí filtrace a dezinfekce UV zařízením.
6. Podzemní tepelná čerpadla – přivádějí z podzemí teplo nebo chlad a starají se o správnou teplotu v budově.
7. Užitečná zeleň – zelené plochy kompenzují efekt městských tepelných ostrovů a zabraňují povodním.

8. Inteligentní energetický management – energetický monitoring umožněný existencí chytré sítě, vzdálené zásobování zelenou energií, nabíjecí stanice pro elektromobily.
9. Výhody zasklení – 64 neprůhledně zaizolovaných skel maximalizuje využití denního světla a minimalizuje přehřívání od slunce viz obrázek 4.4 (McKinsey Global Institute, 2018).



Obrázek 4.4: *Budova Crystal*

4.6 Nejstarší inteligentní budova v ČR

Nejstarší inteligentní budova v České republice stojí v České Lípě, jedná se o kulturní dům. Byl vyprojektován v letech 1975–1981 a postaven v letech 1984–1990. Je již v provozu 29 let a tím se jedná o nejdéle provozovanou inteligentní budovu na území Československa. Vzduchotechnický systém hlavních prostor domu je provozně spojen se solární fasádou. Solární fasáda má plochu 800 m². Pod budovou je zemní tepelný výměník o ploše cca 1600 m². Základní architektonické a stavebně-technické uspořádání budovy vychází z jejího začlenění do kontextu zahrady augustiniánského kláštera. Budova je začleněna do svahu a zahrada plynule přechází na střechu kulturního domu. Je vystavěna jako plochý kompaktní objekt.

Tepelně-technická koncepce budovy byla ve své době zcela unikátní. Jelikož je stavba zasazena do svahu, tak využívá na tehdejší dobu nadstandardní izolaci. Budova má provětrávanou jižní fasádu s funkcí vzduchového kolektoru tepla. Tento kolektor je dále spojen se vzduchotechnickým systémem a zemním výměníkem tepla a chladu. V této budově je také použit na tu dobu velmi nadčasový systém větrání s pomocí rekuperace. V současně době již byly provedeny některé úpravy. Systémy s manuálním řízením byly předělány na řízení pomocí umělé inteligence. Od roku 2004 majitel, město Česká Lípa uvažuje o budoucím využití objektu a s tím související celkovou rekonstrukcí. Pro projekt rekonstrukce byli osloveni architekti původního objektu. Byly předloženy čtyři návrhy rekonstrukce. Cílem by měla být modernizace interiéru a exteriéru při zachování původní tepelně-technické a stavební koncepce (Suchomel, 2020).

4.7 Čistý vzduch v chytrých městech

Bohužel v dnešní době se světové metropole potýkají s problémem, že čím vyšší je technická úroveň měst, tím větší problém nastává se znečištěným ovzduším. Umělá inteligence má své místo i v regulaci emisí ve městech. Systém City Air Management (Siemens Advanta, 2019) je založen na umělých neuronových sítích, které jsou určeny k monitorování a přesnému předpovídání znečištění ovzduší ve velkých městech několik dní dopředu. Jeho úkolem je poskytnout městům a jejich obyvatelům informace potřebné k minimalizaci produkce emisí, ještě dřív než k produkování dojde. Systém monitoruje a předpovídá úroveň znečištění ovzduší v následujících 3–5 dnech s přesností až 90 %. Současně nabízí městu soubor krátkodobých opatření. Města si mohou vybrat ze 17 krátkodobých opatření, které eliminují produkci emisí. Poté už je na městu, jaká opatření stanoví a zda udrží emisní limity na přípustné úrovni. Předpovědi jsou založeny na principu sofistikovaných algoritmů, které spolupracují s umělou neuronovou sítí. Prognóza se provádí ze třech stanovisek, jsou to: historická data znečištění ovzduší neboli opakující se události (víkendy, svátky veletrhy, sportovní akce), aktuální předpověď počasí a charakteristika dopravní situace. Systém sleduje 7 nejdůležitějších složek, které jsou obsaženy v emisích. Díky získávání informací v reálném čase a zavádění zejména krátkodobých, ale i středně a dlouhodobých opatření je předpoklad, že se poměrně spolehlivě dá regulovat míra znečištění ovzduší.

Samotná prognóza ale nemůže zlepšit ovzduší. Proto je systém propojen s technologií CyPT (City Performance Tool). Jedná se o simulační nástroj, který se používá již ve 40 městech po celém světě. CyPT měří dopad strategických plánů měst a srovnává tradiční metody s nejmodernějšími technologiemi. Města si mohou vybrat ze seznamu. Pokud vyhodnotí, že by se mohla blížit situace s velkou koncentrací smogu, mohou zavést krátkodobé bezpečnostní opatření, například: bezplatnou veřejnou dopravu, uzavření parkovacích míst nebo ulic. Při střednědobých až dlouhodobých bezpečnostních opatřeních se mohou zavádět poplatky za produkci exhalací, uzavření parkovišť nebo zatraktivnění místních veřejných dopravních systémů (Cejnarová, 2018b).

4.8 Tramvaje v Bordeaux se spodním odběrem APS

Spodní odběr je výhodný zejména k jeho šetrnosti k historickým částem města, které se zde nacházejí. Systém spodního odběru APS byl ve městě Bordeaux vybudován v roce 2003. Od té doby se tramvajová trasa modernizovala a rozšiřovala. V roce 2020 se počet tramvajů na této trase zaokrouhlil na 130.

Spodní napájecí systém tvoří izolované segmenty a napájecí kolejnice, které jsou umístěné mezi pojezdovými kolejnicemi na libovolném povrchu. Tyto segmenty mohou být instalovány na trávníku, dlažbě, betonu či jiném povrchu. Napájecí kolejnice jsou dlouhé 8 m a mezi sebou mají izolovaný úsek dlouhý 3 m. Trakční energii o napětí 750 V DC, která je segmenty produkována, odebírá tramvajová souprava pomocí dvou botkových sběračů, které jsou umístěny ve střední části soupravy.

Při jízdě se díky kódovanému signálu přenášenému pomocí smyčky v kolejišti zapne pouze ten napájecí segment, nad kterým právě v daném okamžiku projíždí tramvaj. Díky tomu, že napájení probíhá pouze když je nad napájecím segmentem tramvaj, je zajištěna naprostá bezpečnost pro chodce a ostatní účastníky provozu.

Ve výkonovém porovnání konvenčního vrchního a spodního odběru je výkon srovnatelný, tudíž i u systému APS lze zajistit jízdu rychlostí až $60 \text{ km} \cdot \text{h}^{-1}$. V případě, že energie dodávaná z kolejnic selže, každá souprava má na střeše umístěnou trakční baterii.

Chytrá tramvajová síť v Bordeaux má čtyři linky a celkovou délku 77 km. Na linkách jezdí 118 sedmičlánkových tramvají o délce 44 m a 12 pětičlánkových o délce 33 m. Převážná kapacita je 218–300 cestujících. Ročně přepraví více než 100 milionů cestujících. Tramvaje jsou významným městotvorným prvkem propojujícím historické centrum s příměstskými oblastmi viz obrázek 4.5 (Fritschi et al., 2020). Dnes se tyto tramvaje využívají také v Dubaji, Sydney a Riu de Janeiro (Fritschi et al., 2020).



Obrázek 4.5: Tramvaj se spodním odběrem elektrické energie (Bordeaux)

4.9 Chytrý hybridní systém solárního osvětlení

Svítilna veřejného osvětlení vybavená fotovoltaikou se používají zejména u ostrovních systémů připojení. Tento systém je sice ekologický, avšak jeho ekonomičnost není dobrá, obzvláště pokud je používán v oblastech s proměnlivou délkou slunečního svitu během dne a roku. V takovém případě je výhodné připojení kombinované, solární s možností využití veřejné sítě. Firma Signify prezentovala takovéto osvětlení jako novinku roku 2020. U běžných ostrovních systémů během dne nabíjí baterie sluneční paprsky a uloženou energii využívá v noci veřejné osvětlení. Pro zajištění funkce osvětlení i ve dnech, kdy je zataženo se dimenzují baterie typicky na pětidenní spotřebu energie. U hybridního systému stačí baterie, která je dimenzována na jednodenní provoz. Pokud tedy není dostatek slunečního svitu u hybridního systému, osvětlení přejde na napájení z veřejné sítě. Největší výhodou je, že díky možnosti napájení se výrazně šetří náklady na menší solární panel a baterii. Tyto hybridní systémy se mohou používat například i v severních zemích nebo v oblastech s velkým počtem oblačných dnů v roce. Tato veřejná osvětlení mají svítivost 5–24 tis. lm a světelný tok až 170 lm/W . Díky těmto parametrům se dají svítla využívat jak pro pěší stezky, tak i hlavní městské komunikace (Chitale, 2020).

5 Smart grids

5.1 Co je to Smart grid?

Z jakého důvodu je potřeba zavádět Smart grid? Toto téma jde ruku v ruce se zapojováním do soustavy obnovitelných zdrojů elektřiny. Pokud se budou ve vysoké míře zapojovat do soustavy nepredikovatelné zdroje, jako solární nebo větrné elektrárny, bude potřeba zvládat špičkové odběry a přebytečnou energii nějakým způsobem ukládat. Energetika jde cestou decentralizace a digitalizace, flexibility a autonomních ostrovních systémů, u kterých je možnost nezávislého fungování. Autonomní provozy budou využívány a vyvíjeny tam, kde by kogenerační jednotka vyřešila dodávku tepla a elektřiny. Bude také potřeba zavést nové nástroje pro řízení distribuční soustavy.

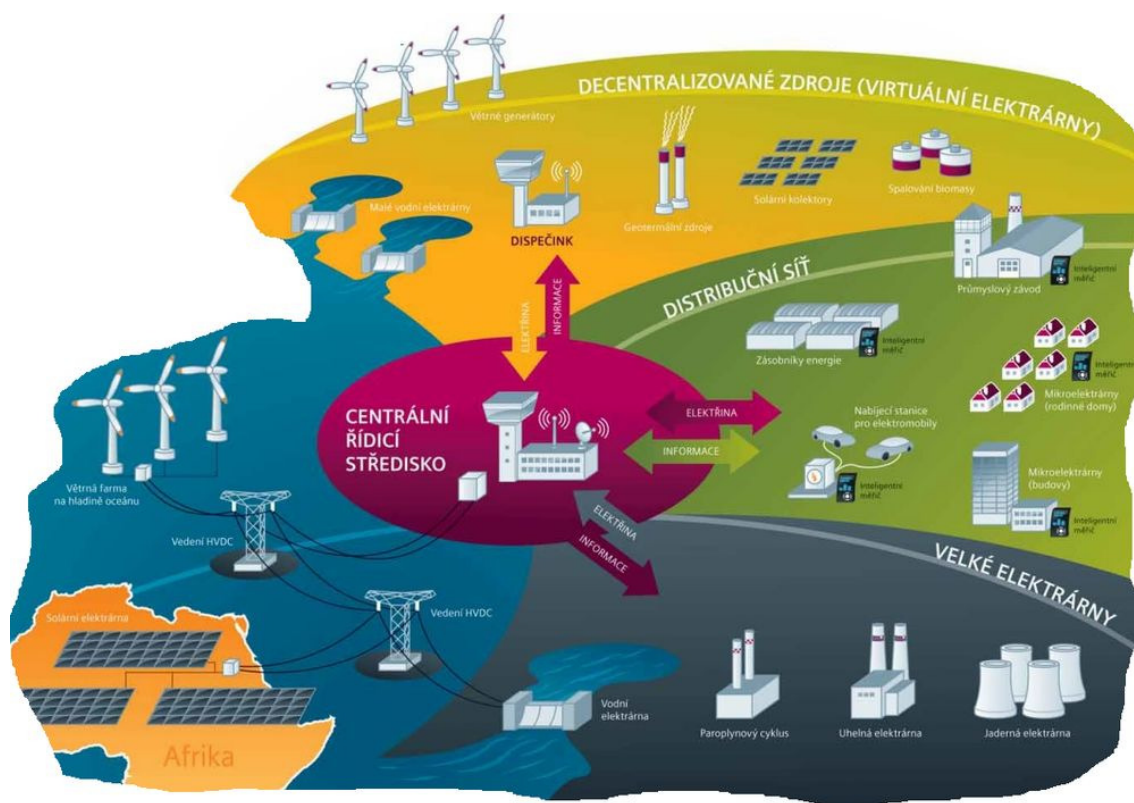
Decentralizované zdroje musí oproti konvenčním zdrojům provádět zejména sběr dat a zabývat se jejich zpracováním a dalším využitím. Hlavním cílem Smart grid je, aby všechny objekty, které se podílí na výrobě elektřiny, spolu komunikovaly, regulovaly svoje výkony, uskladňovaly nevyužitou elektrickou energii a dodávaly vlastní vyprodukovanou energii do rozvodné sítě. Smart grid by měl umožnit nasazení digitálních komponent a technologií do sítě. Pomocí Smart grid by měla být umožněna komunikace mezi koncovým odběrným místem a řídicím datovým centrem, které bude na straně správce distribuční soustavy. Díky zavedení této komunikace bude možné užívání chytrých aplikací a technických řešení. Ty jsou zkvalitněním služeb pro koncové odběratele, šetří energii a především chrání životní prostředí díky dobrému fungování obnovitelných zdrojů ve výrobě elektřiny a řízenou spotřebou.

Výhody Smart grids

1. Okamžitý přehled distributora o stavu distribuční sítě a odběrných místech – pružná reakce na přetížení spotřeby nebo výroby.
2. Sběr přesných dat o průběhu spotřeby energie – časté odečítání naměřených hodnot.
3. Chytrá měřidla dokáží zjistit pokusy o nedovolené manipulaci a zajistit preventivní opatření proti krádežím a ztrátám.
4. Konečný zákazník má přístup k datům a podle nich může uzpůsobit svou spotřebu – dochází k šetření energie i nákladů.
5. Hodnoty jsou odečítány na dálku – odpadá nutnost dojíždění pracovníků na odběrná místa.
6. Díky dálkovému řízení měřidel je umožněno např.: dálkové odpojení, omezení maximálního výkonu či změny tarifů .

5.1.1 Chytré spotřebiče

V rozvoji Smart grids hrajou důležitou roli i chytré spotřebiče. Chytrá síť přináší zákazníkům mnoho možností energetických tarifů a také možnost odebírat elektřinu v době, kdy je levná. Chytré spotřebiče budou fungovat tak, že budou spotřebiče přímo ze sítě vědět, jaká je v reálném čase cena elektřiny. Podle toho budou zákazníkovi nabízet, kdy bude spotřebič v provozu. Na spotřebiči (např. pračce) by si uživatel nastavil, aby se spustila v době, kdy je cena elektřiny nejpříznivější. Chytrá síť by měla být kompatibilní i s nabíjením elektromobilů, kdy by domácí wall box začal nabíjet až při nízkém tarifu elektřiny. Elektromobily by mohly v době stání v garáži fungovat i jako tzv. záložní zdroj, kdy by se v době výpadku nebo v čase, když je elektřina drahá, mohla energie čerpat z akumulátoru elektromobilu, který byl nabit levným tarifem. Díky inteligentním technologiím by mohla spotřeba v domácnostech klesnout o 10 až 15 %.



Obrázek 5.1: Schéma výrobní a distribuční sítě zahrnující Smart grid

Obrázek 5.1 (Plchút, 2015) znázorňuje Smart grid pojetí produkce a spotřeby elektřiny. Smart grid počítá s nepředvídatelnou výrobou elektřiny a kontrolovatelnou spotřebou. Průmyslové objekty by se měli proměnit v aktivní účastníky na trhu s elektrickou energií. Koncept by měl být uzpůsoben tak, že by se distribuční sítě dokázaly samy regulovat pomocí umělé inteligence, která by měla k dispozici veškerá data a dokázala by predikovat spotřebu elektřiny (Plchút, 2015).

5.2 Vývoj Smart grids v Česku

Evropská energetika se v posledních letech významně transformuje. Trend je ve spojování decentralizovaných, zejména obnovitelných zdrojů. Zdroje se spojují pomocí moderních informačních a komunikačních technologií. Celý energetický sektor se transformuje díky zavádění nových možností, aplikací, produktů a subjektů. Ruku v ruce se Smart city vzniká i tzv. koncept Smart Grids, neboli chytré sítě, které se budou implementovat nejen v Evropě, ale i v České republice.

Mezi hlavní cíle Smart Grids do roku 2030 patří zejména dekarbonizace neboli snížení emisí, dále decentralizace, digitalizace, zvýšení podílu obnovitelných zdrojů v energetickém mixu a zvýšení energetické účinnosti. Trend ve spojování decentralizovaných zdrojů (zejména obnovitelných) s chytrými technologiemi, které při své práci využívají moderní informační a komunikační technologie, mění energetický sektor ve více soběstačný a chytrější (Kučerková a Makešová, 2020).

5.2.1 Koncept Smart grids

Smart grids jsou sítě, které dokáží monitorovat samy sebe a jejich činnost zahrnuje kombinování konvenčních zdrojů energie s alternativními. Zahrnují inteligentní řídicí systém, který monitoruje aktuální provoz sítě. Data, která snímá inteligentní řídicí systém jsou vyhodnocována v reálném čase a podle nich se upravuje aktuální situace provozu sítě. Chytré sítě mají schopnost tzv. self healingu. Síť monitoruje svůj technický stav a při kolísání dodávky či odběru se za pomoci implementovaných inteligentních prvků dokáže uvést do rovnováhy. Na zajištění se bude podílet i strana spotřeby, která může díky inteligentním technologiím poskytovat potřebnou flexibilitu. Smart grids dokáží zároveň komunikovat se zákazníkem v reálném čase a optimalizovat jeho spotřebu vzhledem k aktuální ceně elektřiny a zátěži životního prostředí, což umožňuje lepší začlenění obnovitelných zdrojů elektřiny do energetického mixu. V současném modelu trhu s elektřinou je zřetelné, že spotřebitel je pouze pasivním členem tohoto řetězce. Koncept chce aktivně zapojit spotřebitele do tohoto řetězce za účelem práce s daty, efektivnějšího využití energetické soustavy a dosažení vyšší účinnosti (Kučerková a Makešová, 2020).

5.2.2 Legislativní podmínky

Nutnost implementace konceptu Smart grids v ČR vznikla v kontextu na dlouhodobé evropské cíle a nové legislativní podmínky ze strany Evropské unie. V posledních letech vzniklo mnoho evropských strategických dokumentů, kterými se musí řídit i Česká republika, např.: Europe 2020 Strategy – Strategie pro inteligentní a udržitelný růst podporující začlenění.

Evropské legislativní dokumenty podporující SG

1. Europe 2020 Strategy – Strategie pro inteligentní a udržitelný růst podporující začlenění (European commission, 2020b);
2. Toward a Sustainable – udržitelná Evropa do roku 2030 (European commission, 2019);

3. Roadmap 2050 – Snížení emisí skleníkových plynů na nulové procento do roku 2050 (European comission, 2012).

Legislativní dokumenty se zaměřují na flexibilitu mezi zákazníkem a trhem s elektřinou, shromažďování dat a podmínkami pro přístup k těmto datům, bezpečnost dat a kybernetickou bezpečnost systému. Dokumenty také řeší otázku decentralizované výroby a akumulaci elektrické energie, dále pak její uplatnění při řízení distribučních sítí. Velmi důležitým bodem, kterým se také zabývají, je ustanovení o podmínkách zavedení chytrého měření v členských státech EU. V České republice energetiku upravují tři zákony, bohužel v současnosti žádný ze zákonů nezahrnuje vývoj změny probíhající v sektoru energetiky.

V České republice vznikl v roce 2015 Národní akční plán pro chytré sítě, který vychází z globálních požadavků Státní energetické koncepce. V Národním akčním plánu je popsáno, kam by měl směřovat vývoj elektrizační soustavy v České republice a jakým způsobem se budou implementovat prvky umělé inteligence do oblasti energetiky (Kučerková a Makešová, 2020).

5.2.3 Prvky umělé inteligence v přenosové soustavě

Pro sledování a predikci stability přenosové soustavy se využívá inteligentní systém WAMS (Wide Area Monitoring System). Systém slouží k plošnému monitorování přenosové soustavy. V principu se jedná o měření fázových úhlů napětí v důležitých uzlech přenosové soustavy. Měření probíhá zejména na vývodech linkových vedení z rozvodu VVN a na přeshraničních linkách. Na základě naměřených dat lze predikovat případnou poruchu nebo nežádoucí stav soustavy. Tyto stavy mohou vést v důsledku až k rozdělení přenosové soustavy na ostrovní provozy. V současné době je vybavena tímto systémem většina přenosových soustav v Evropě. Systém si předává data na základě bilaterálních dohod. Z provedené analýzy lze zjistit problém, který může nastat až stovky kilometrů od zdroje. Jedná se o jeden z prvních kroků využití umělé inteligence v přenosové síti. V plánech do budoucna v souvislosti s narůstajícím podílem obnovitelných zdrojů by se měl vytvořit centrální evropský dispečink, který by udržoval optimální nasazení podpůrných služeb a regulační energie. Centrálnímu řízení by byly podřízeny jednotlivé lokální dispečinky (Kučerková a Makešová, 2020).

5.2.4 Prvky umělé inteligence v distribuční soustavě

V distribuční soustavě se již od sedmdesátých let využívá systém HDO (hromadné dálkové ovládání). Tento systém slouží k ovládání spotřebičů na dálku. HDO je funkční systém, ale disponuje řadou nedostatků. Nové inteligentní systémy eliminují tyto nedostatky. Smart grids nebo Smart metering by mohla být do budoucna náhrada za HDO. Inteligentní systémy se zavádějí z důvodu vyšší přesnosti harmonogramu spotřeby a následné řízení spotřeby pomocí spínání odběrných míst. Nynější systém řízení přes HDO neumožňuje detailní sledování dat o počtu spínaných spotřebičů a jejich příkonu. Současným trendem je ovládat celé odběrné místo najednou nebo dokonce provádět řízení až na úrovni konkrétních spotřebičů. V plánech do budoucna je nasazení inteligentního měřicího systému AMM (Advanced Metering Managment). Tato technologie umožní lepší reagování zákazníka na cenové signály obchodníků a v konečném signálu to bude znamenat úsporu nákladů na silovou elektřinu. Největší překážkou zavádění inteligentních systémů do distribuční soustavy je bariéra sběru dat, ukládání a následné nakládání s daty, která měřidla

produkují v reálném čase. Pro sběr dat a zavedení umělé inteligence je potřeba upravit současnou legislativu (Kučerková a Makešová, 2020).

5.2.5 Dopad elektromobility a zavádění obnovitelných zdrojů do Smart grids

Do roku 2050 se předpokládá, že se celková spotřeba elektrické energie kvůli využívání elektromobilů zhruba zdvojnásobí. Obnovitelné zdroje by měly do budoucna pokrýt dvě třetiny výroby elektrické energie. Cílem je také snížit produkci skleníkových plynů z dopravy o 80–95 % do roku 2050. Velký podíl OZE ve výrobě elektrické energie a v rozvoji elektromobility v dopravě by vedlo k dekarbonizovanému přepravnímu systému, který splňuje cíle evropské unie. Dle předpokladů do roku 2030 nebude mít podstatný vliv zavádění elektromobility na elektrickou síť. Dramatické zvýšení spotřeby elektrické energie by mělo nastat do roku 2050 – podíl spotřeby elektrických vozidel na celkovou spotřebu energie je až 80 %. V současné době ve světě výrobu elektrické energie tvoří energetický mix zdrojů – ropa (34 %), zemní plyn (24 %), vodní energie (7 %), jaderná energie (4 %), ostatní obnovitelné zdroje (4 %) (Sree Lakshmi et al., 2020).

Závěr

První poznatky o umělé inteligenci se objevily již v roce 1941, v tu dobu však na tuto technologii nebylo pohlíženo jako na umělou inteligenci a nikdo netušil, že o několik desítek let později bude tato technologie vyvíjena jako prostředek pro zjednodušení života lidstva. Roku 1967 Marvin Minsky vyslovil nejuznávanější definici, která platí dodnes. Jedním z prvních funkčních systémů umělé inteligence byl The Logistic Theorist, který pracoval na stromovém principu a ke každému zadanému problému hledal větev, která bude řešením. Vznik tohoto programu byl velkým milníkem pro další rozvoj umělé inteligence. Později začala na vývoji pracovat firma IBM a v roce 1963 se do vývoje zapojila i vláda USA. Dále vznikaly různé matematické programy, které uměly řešit algebraické výrazy nebo překladače. V sedmdesátých letech vznikly expertní systémy, které byly postupně zaváděny do systémů umělé inteligence. Díky expertním systémům získala umělá inteligence dnes již klíčovou vlastnost, a to předvídání pravděpodobnosti řešení. V osmdesátých letech se zapojily do vývoje velké průmyslové společnosti a jejich snaha byla uváděna směrem k odstranění lidské práce na výrobních a kontrolních linkách, kde se jedná převážně o stejnorodou monotónní práci. V pozdějších letech se začalo více ukazovat, že by umělá inteligence mohla najít využití i v běžném životě. V současnosti se využívá v dopravě, podnikání, zdravotnictví, průmyslu, statistice a dalších. OSN stanovila 17 cílů, kterých se bude snažit dosáhnout v letech 2015 až 2030. Dokumentů o umělé inteligenci už vzniklo mnoho, jak na úrovni EU, tak ČR. V ČR se dokument nazývá iniciativa Průmysl 4.0. V tomto dokumentu jsou zahrnuty kapitoly o dopadech na vzdělávací soustavu, trh práce či efektivní využívání zdrojů. Určitá část společnosti se obává negativního dopadu na trh práce vlivem nahrazení lidské pracovní síly. Podle teorie vědce a teoretického fyzika Stephena Hawkinga nejsou schopny stroje, které jsou řízeny umělou inteligencí, konkurovat biologickým schopnostem člověka. Z obecného hlediska je to tak, že lidé ve vyspělých zemích se mohou obávat ztrát zaměstnání a v chudších zemích by měla umělá inteligence napomoci k odvrácení chudoby.

Kvůli neustálému nárůstu počtu automobilů na silnicích a trendu zrychlování dopravy již nestačí konvenční způsoby řízení dopravy. Například u semaforů již nevyhovuje, aby funkce byla řízena pouze pomocí časovače, avšak měly by být zahrnuty důležitější aspekty, jako například hustota provozu. Chytré řízení dopravního provozu se týká i řízení dopravy ve městech. V chytrých městech se však s umělou inteligencí počítá ve větší míře, než pouze v dopravě. Chytré město potřebuje nějakým způsobem ukládat data a dále s nimi pracovat. K tomu slouží například systém Mindsphere. Chytrá města by měla být i nízkoemisní, tzn. co největší podíl elektrických vozidel v městském provozu. V chytrých městech se počítá s velkou mírou využití obnovitelných zdrojů. Aby bylo možné je zapojovat do sítě, je potřeba využít tzv. smart grids. Cílem je, aby všechny subjekty, které se podílejí na fungování chytré sítě, spolu komunikovaly, regulovaly svoje výkony,

uskladňovaly nevyužitou energii a dodávaly vlastní vyprodukovanou energii do rozvodné sítě.

V současné době je umělá inteligence vyvíjena a implementována do čím dál více oborů. Postupným trendem je digitalizace, sběr dat a rychlé vyhodnocování. V roce 2020, kdy propukla koronavirová krize, si velká část populace vyzkoušela práci na dálku, která je také jedním z trendů průmyslové revoluce 4.0. Při této krizi se pořádaly vzdálené meetingy a telekonference. Ukázalo se, že takovýto způsob práce, kdy nemusí být pracovník přímo fyzicky přítomen, je využitelný v dnešní době. Je možné, že kdybychom měli vyspělejší a celosvětově komplexnější technologie umělé inteligence v oblasti zdravotnictví, mohl by být celý průběh zjišťování a vyhodnocování informací o novém viru účinnější a rychlejší. Mohlo by se také za pomoci vyhodnocení velkého množství dat zhodnotit, která opatření mají smysl zavádět i v dalších zemích a která naopak ne.

Otázka zní, zda u dnešních systémů můžeme již opravdu mluvit o umělé inteligenci. Systémy opravdu fungují inteligentně. Avšak je nutné podotknout, že systémy, které jsou naprogramovány na jeden konkrétní typ dat a operací, se samy nedokáží přetransformovat na jiný typ. Tím, že se nedokáží přetransformovat jako lidský mozek, mají k inteligentnímu myšlení srovnatelnému s lidským mozkem ještě velmi daleko. Na umělou inteligenci, jakou ji známe dnes, by se dalo pohlížet pouze jako na mimořádně efektivní nástroj, který dokáže zpracovávat a vyhodnocovat velké množství dat za pomoci algoritmů a neuronových sítí. Umělá inteligence ve firmách nepochybně ušetří velký objem mechanické a stejnorodé práce. V současnosti využívá umělou inteligenci 4 % velkých firem a 46 % firem plánuje v dohledné době tyto technologie zavádět. Umělá inteligence je a bude nepochybně dobrým pomocníkem, jak už pro průmysl či běžný život. Je žádoucí neustále tuto technologickou oblast vyvíjet a zavádět ji tam, kde je opravdu potřeba.

Seznam použitých zdrojů

- Avila, A. a Mezic, I. (2020). Data-driven analysis and forecasting of highway traffic dynamics. *Nature Communications*, 11(1):1–6.
- Basheer, I. a Hajmeer, M. (2000). Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1):3–31.
- Brodic, D. a Amelio, A. (2020). *Artificial Intelligence and Turing Test*, Smart Innovation, pp. 1–5. Springer Science and Business Media Deutschland GmbH, Technical Faculty in Bor, University of Belgrade, Bor, Serbia. ISSN: 21903018.
- Cejnarová, A. (2018a). *Visions*, Umělá inteligence - budoucnost, pp. 5–12. Siemens, s.r.o., Praha 13. ISSN: 1804-364X.
- Cejnarová, A. (2018b). *Visions*, Chytrá města, pp. 28–29. Siemens, s.r.o., Praha 13. ISSN: 1804-364X.
- Chen, L. a Englund, C. (2016). Cooperative Intersection Management: A Survey. *IEEE Transactions on Intelligent Transportation Systems*, 17(2):1–3.
- Chitale, H. (2020). Signify expands solar lighting potential to northern countries using new hybrid charging technology. [online]. [cit. 2020-4-13], Dostupné z: <https://www.signify.com/global/our-company/news/press-releases/2020/20200227-signify-expands-solar-lighting-potential-to-northern-countries-using-new-hybrid-charging-technology>.
- Chuprov, S., Viksnin, I., a Kim, I. (2019). Urban intersection management with connected infrastructure objects and autonomous vehicles. *IEEE International Conference on Connected Vehicles and Expo, ICCVE 2019 - Proceedings*, pp. 1–6.
- City of Helsinki (2019). Helsinki's 3D city models. [online]. [cit. 2020-7-18], Dostupné z: <https://www.hel.fi/helsinki/en/administration/information/general/3d/>.
- Ernst, G. a Newell, A. (1969). GPS : a case study in generality and problem solving. *New York (N.Y.) : Academic press*, pp. 1–297.
- European comission (2012). Energy roadmap 2050. [online]. [cit. 2020-7-18], Dostupné z: https://ec.europa.eu/energy/sites/ener/files/documents/_energy_roadmap_2050_en_0.pdf.
- European comission (2019). Towards a sustainable Europe by 2030. [online]. [cit. 2020-7-18], Dostupné z: https://ec.europa.eu/info/publications/towards-sustainable-europe-2030_en.

- European comission (2020a). Communication from the commission to the european parliament, the council, the european economic and social committee and the committee of the regions. [online]. [cit. 2020-7-18], Dostupné z: <https://ec.europa.eu/transparency/regdoc/rep/1/2016/EN/1-2016-180-EN-F1-1.PDF>.
- European comission (2020b). A European strategy for smart, sustainable and inclusive growth. [online]. [cit. 2020-7-18], Dostupné z: <https://ec.europa.eu/eu2020/pdf/COMPLET>
- Federal Communications Commission (2019). Dedicated Short Range Communications (DSRC) Service. [online]. [cit. 2020-7-18], Dostupné z: <https://www.fcc.gov/wireless/bureau-divisions/mobility-division/dedicated-short-range-communications-dsrc-service>.
- Frassi, V. (2020). Take a virtual travel day with Street View. [online]. [cit. 2020-7-18], Dostupné z: <https://blog.google/products/maps/virtual-travel-day-with-street-view/>.
- Fritschi, T., Collet, C., a Miller, S. (2020). Alstom delivers the 130th Citadis tram to Bordeaux Métropole. [online]. [cit. 2020-4-9], Dostupné z: <https://www.alstom.com/press-releases-news/2020/2/alstom-delivers-130th-citadis-tram-bordeaux-metropole>.
- Gibney, E. (2017). How rival bots battled their way to poker supremacy. *Nature*, (543):160–161.
- Goralski, M. a Tan, T. (2020). Artificial intelligence and sustainable development. *International Journal of Management Education*, 18(1):1–9.
- Hanzlíková, I. H. (2020). *Energie 21*, Moderní technologie 4. průmyslová revoluce, pp. 34–37. Profi Press s.r.o., Praha 2. ISSN: 1803-0394.
- Hermann, M., Pentek, T., a Otto, B. (2016). Design principles for industrie 4.0 scenarios. *Proceedings of the Annual Hawaii International Conference on System Sciences*, 47(5670):3928–3937.
- Herwig, C. (2020). Maps that bring us closer, even when we're apart. [online]. [cit. 2020-7-18], Dostupné z: <https://blog.google/products/maps/my-maps-bring-us-closer/>.
- Jordan, J., Palanca, J., del Val E., Julian, V., a Botti, V. (2018). A multi-agent system for the dynamic emplacement of electric vehicle charging stations. *Applied Sciences (Switzerland)*, 8(2):1–6.
- Kučerková, B. a Makešová, M. (2020). *Energie 21*, Smart Grids v Česku, pp. 24–27. Profi press s.r.o, Praha 2. ISSN: 1803-0394.
- Kytková, B. (2020). Základní výzkum je trochu jako ruleta. *Věda a výzkum*, 8(4):1–6.
- Liu, H. a Ma, J. (2020). Vehicle Detection and Classification Using Distributed Fiber Optic Acoustic Sensing. *IEEE Transactions on Vehicular Technology*, 69(2):1–3.
- Luger, G. (2011). *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. Pearson Education, New Mexico. ISBN: 0133001733.

- Mařík, V. (1991). *Umělá inteligence (1)*. Academia 2000, Praha. ISBN: 978-80-200-0496-3.
- Matowicki, M. (2016). Analysis of possibility to utilize road marking for the needs of autonomous vehicles. 27(4):1–5.
- McCarthy, J. (1958). Recursive Functions of Symbolic Expressions Their Computation by Machine, Part I. *Massachusetts Institute of Technology*, pp. 1–12.
- McKinsey Global Institute (2018). Smart cities: Digital solutions for a more livable future. [online]. [cit. 2020-9-11], Dostupné z: <https://www.mckinsey.com/business-functions/>.
- Mikolov, T., Chen, K., Corrado, G., a Dean, J. (2013a). Efficient estimation of word representations in vector space. In *1st International Conference on Learning Representations, ICLR 2013 - Workshop Track Proceedings*.
- Mikolov, T., Yih, W. ., a Zweig, G. (2013b). Linguistic regularities in continuous space-word representations. In *NAACL HLT 2013 - 2013 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Proceedings of the Main Conference*, pp. 746–751.
- MPO (2016). Inicativa průmysl 4.0. pp. 1–233. [online]. [cit. 2020-20-02], Dostupné z: <https://www.mpo.cz/assets/dokumenty/53723/64358/658713/priloha001.pdf>.
- Myšák, P. (2019). Seriál: Google vsází všechny karty na strojové učení. [online]. [cit. 2020-7-18], Dostupné z: <https://www.nextvision.cz/blog/google-vsazi-vsechny-karty-na-strojove-uceni-ii/>.
- Nath, R. (2020). Alan Turing’s Concept of Mind. *Journal of Indian Council of Philosophical Research*, 37(1):31–50.
- Plechůt, M. (2015). Co je Smart Grid? [online]. [cit. 2020-7-18], Dostupné z: <https://elektro.tzb-info.cz/12544-co-je-smart-grid>.
- Reeke Jr., G. (1991). The society of mind. Marvin Minsky. *Artificial Intelligence*, 48(3):341–348.
- Robertson, D. a Bretherton, R. (1991). Optimizing Networks of Traffic Signals in Real Time—The SCOOT Method. *IEEE Transactions on Vehicular Technology*, 40(1):11–15.
- Russell, S. a Norvig, P. (2014). *Artificial Intelligence: A Modern Approach*. Pearson Education Limited, UK. ISBN: 978-12-920-2420-2.
- Schonig, J. (2019). Vítejte ve městě 4.0. [online]. [cit. 2020-7-18], Dostupné z: <https://www.visionmag.cz/vitejte-ve-meste-4-0>.
- Siemens (2020). Connecting the things that run the world. [online]. [cit. 2020-7-18], Dostupné z: <https://siemens.mindsphere.io/en>.
- Siemens Advanta (2019). CITY AIR MANAGEMENT. [online]. [cit. 2020-7-18], Dostupné z: <https://www.siemens-advanta.com/cases/city-air-management>.

- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., a Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587):484–489.
- Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., a Guez. (2017). Mastering the game of Go without human knowledge. *DeepMind*, 550(7676):354–359.
- Slavík, J. (2019). *Rekonstrukce veřejného parkoviště*, Inovativní řešení, 9 p. Smart city v Praze, Říčany.
- Slouka, D. (2019). AI vs MI: Co je umělá inteligence a co strojové učení. [online]. [cit. 2020-7-18], Dostupné z: <https://aiworld.cz/umela-inteligence/ai-vs-ml-co-je-umela-inteligence-a-co-strojove-uceni-288>.
- Sree Lakshmi, G., Rubanenko, O., a Hunko, I. (2020). Renewable Energy Generation and Impacts on E-Mobility. *Journal of Physics: Conference series*, 1457(1):1–14.
- Stach, D. (2020). Tomáš Mikolov. [online]. [cit. 2020-7-18], Dostupné z: <https://www.ceskatelevize.cz/porady/10441294653-hyde-park-civilizace/220411058090215-tomas-mikolov>.
- Suchomel, J. (2020). *Energie 21*, Nejstarší inteligentní budova stojí v České Lípě, pp. 30–31. Profi Press s.r.o., Praha 2. ISSN: 1803-0394.
- Tonguz, O. a Zhang, R. (2020). Harnessing Vehicular Broadcast Communications: DSRC-Actuated Traffic Control. *IEEE Transactions on Intelligent Transportation Systems*, 21(2):1–4.
- Torabi, B., Wenkstern, R., a Saylor, R. (2018). A Collaborative Agent-Based Traffic Signal System for Highly Dynamic Traffic Conditions. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC, 2018 - November(7)*:1–6.
- Torabi, B., Wenkstern, R. Z., a Saylor, R. (2020). A collaborative agent-based traffic signal system for highly dynamic traffic conditions. *Autonomous Agents and Multi-Agent Systems*, 34(1).
- Turing, A. M. (1950). I.—COMPUTING MACHINERY AND INTELLIGENCE. *Mind*, 59(236):433–460.
- Turovsky, B. (2016). Ten years of Google Translate. [online]. [cit. 2020-5-10], Dostupné z: <https://blog.google/products/translate/ten-years-of-google-translate/>.
- United Nations (2021). Sustainable development goals. [online]. [cit. 2020-7-18], Dostupné z: <https://www.un.org/sustainabledevelopment/sustainable-development-goals/>.
- Vítek, J. (2020). Autonomní řízení vyžaduje komunikaci. [online]. [cit. 2020-4-14], Dostupné z: <https://www.i-city.bid/>.

- Wang, Q. a Zheng, J. (2018). Roadside Magnetic Sensor System for Vehicle Detection in Urban Environments. *IEEE Transactions on Intelligent Transportation Systems*, 19(5):1–4.
- Wichmann, J. a Sandkuhl, K. (2020). Toward a smart town: Digital innovation and transformation process in a public sector environment. *Smart Innovation, Systems and Technologies*, 189(1):1–10.
- Zelinka, I. (2003). *Umělá inteligence*. BEN, Praha. ISBN: 80-7300-068-7.

Seznam obrázků

2.1	Systematická strategie	18
2.2	Příklad definice GPS	20
3.1	Příklady modelování křižovatek	22
3.2	Příklady modelování křižovatek s různými trajektoriemi	23
3.3	Koopmanova metoda	25
3.4	Diagram metody SCOOT	27
3.5	Systém měření na povrchu vozovky	29
3.6	Princip magnetického sensorového systému	30
3.7	Příklady fotografií pro čtení Google	32
4.1	Tepelná mapa ve městě New York	39
4.2	Výsledný obraz časoprostorové krychle	40
4.3	Trajektorie pohledu – internetová stránka	40
4.4	Budova Crystal	42
4.5	Tramvaj se spodním odběrem elektrické energie (Bordeaux)	44
5.1	Schéma výrobní a distribuční sítě zahrnující Smart grid	46

Seznam tabulek

4.1	Oblasti pro potenciální umístění nabíjecí stanice a jejich charakteristika	37
-----	--	----