Operačný program
Efektívna verejná správa

Európska únia
Európsky sociálny fond

Výstup č. 4

Návody pre jednotlivé oblasti inovácie

Zmluva o dielo č. 333/2018 Príručka pre využívanie dát k optimalizácii procesov a transformácii organizácií verejnej správy

Projekt:

Zlepšenie využívania údajov vo verejnej správe

ITMS kód projektu:

314011S979

Tento projekt je podporený z Európskeho sociálneho fondu.

Obsah

1 Manažérske zhrnutie 4

2 Úvod 7

3 Prehľad inovácií postavených na dátach 13

3.1 Nové trendy 13

3.2 Konkrétne firmy a riešenia 14

4 Metódy, techniky a nástroje pre lepšie využitie údajov 18

5 Odporúčania pre inštitúcie verejnej správy 21

5.1 Posudzovanie vplyvov regulácií pomocou veľkých dát 22

5.1.1 Úvod 22
5.1.2 Vízia 23
5.1.3 Transformácia 24
5.1.4 Požiadavky na dáta a analytické nástroje 26
5.1.5 Najlepšia prax 28
5.1.6 Obmedzenia a problémy 28

5.2 Lepší dozor a dohľad nad regulovaním prostredím 29

5.2.1 Úvod 29
5.2.2 Vízia 30
5.2.3 Transformácia 31
5.2.4 Požiadavky na dáta a analytické nástroje 34
5.2.5 Najlepšia prax 35
5.2.6 Obmedzenia a problémy 36

5.3 Inovácie procesov 36

5.3.1 Úvod 37
5.3.2 Vízia 37
5.3.3 Transformácia 38
5.3.4 Požiadavky na dáta a analytické nástroje 39
5.3.5 Najlepšia prax 40
5.3.6 Obmedzenia a problémy 41

5.4 Lepšie riadenie zdrojov a plánovanie činností 42

5.4.1 Úvod do problematiky prediktívnej polície 42
5.4.2 Vízia prediktívnej polície 44
5.4.3 Transformácia fungovania 46
5.4.4 Požiadavky na dáta 50
5.4.5 Najlepšia prax 52
5.4.6 Obmedzenia a nevýhody 53

5.5 Zvýšenie kvality služieb 53

5.5.1 Úvod 53
5.5.2 Vízia 56
5.5.3 Transformácia 56
5.5.4 Požiadavky na dáta a analytické nástroje 57
5.5.5 Najlepšia prax 58
5.5.6 Obmedzenia a problémy 59

5.6 Využitie umelej Inteligencie pre manažment ľudských zdrojov 60
5.6.1 Úvod 60
5.6.2 Vízia 61
5.6.3 Transformácia 61
5.6.4 Požiadavky na dáta a analytické nástroje 62
5.6.5 Najlepšia prax 62
5.6.6 Obmedzenia a problémy 63
5.7 Využitie technológie blockchain pre transformáciu evidencie 63
5.7.1 Úvod 63
5.7.2 Vízia 64
5.7.3 Transformácia 64
5.7.4 Požiadavky na dáta a analytické nástroje 66
5.7.5 Najlepšia prax 67
5.7.6 Obmedzenia a problémy 67
6 Použitá literatúra 69

1 Manažérske zhrnutie

"Umelá inteligencia je budúcnosť, nie iba pre Rusko, ale pre celé ľudstvo. Ktokoľvek sa stane v tejto sfére lídrom bude vládcom sveta." Tieto vety vyriekol v roku 2017 Vladimír Putin. Ukazujú, ako dôležitá je táto téma pre vlády a to nie len v geopolitickom význame. Táto príručka sa venuje jednému spôsobu, ako môžu štáty podporiť rozvoj umelej inteligencie a to vytvorením dopytu po riešeniach. Ak začnú využívať nové algoritmy samotné štátu, umožnia inovatívnym spoločnostiam vyskúšať takéto riešenia v praxi a získať tak významnú konkurenčnú výhodu. Zároveň sa inštitúcie verejnej správy zmenia, keďže budú fungovať efektívnejšie a flexibilnejšie. Pokúsime sa preto vysvetliť možnosti, aké majú inštitúcie verejnej správy, ak chcú realizovať dátovú transformáciu. Aby malo nasadenie technológie význam, je potrebné zmeniť fungovanie a úlohy v rámci zlepšovaných funkcií, čo bude vyžadovať aj zmenu pracovných pozícií a celkových procesov. Je potrebné si uvedomiť, že nové technológie umelej inteligencie výrazne znižujú náklady na predikciu, a použitie ich má zmysel všade, kde je potrebné predvídať budúci vývoj dôležitých veličín a rozhodovať sa na základe takýchto vstupov. Naším prístupom je preto hľadať a povzbudzovať riešenia. Široká škála verejných inštitúcií vo svete už začala používať technológie, ktorý využívajú strojové učenie a ďalšie metódy umelej inteligencie na lepšie rozhodovanie. Príklady zahŕňajú úsilie správ sociálneho zabezpečenia na zlepšenie kvality rozhodovania pri posudzovaní žiadostí o dávky, úsilie environmentálnych agentúr pri modelovaní toxicity chemických zlúčenín a finančných správ pri predpovedanie daňových únikov a identifikáciu cieľov daňových kontrol.

Základné témy a oblasti digitálnej transformácie

V našej príručke rozoberáme sedem oblastí možnej aplikácie nových technológií:

- Lepší návrh politík a regulácií,
- Lepší dozor a dohľad nad regulovaním prostredím,
- Inovácie procesov,
- Lepšie riadenie zdrojov a plánovanie činností,
- Zvýšenie kvality služieb,
- Lepší manažment zdrojov,
- Distribuovaná evidencia.

Pre každú z týchto oblastí vysvetľujeme základné pojmy a koncepty, definujeme víziu aplikácie nových technológii v praxi, navrhujeme postup transformácie, definujeme požiadavky na dáta, popisujeme súčasnú najlepšiu prax a analyzujeme tiež možné obmedzenia a nevýhody. Poskytujeme tak komplexný pohľad na možnosti transformácie v daných oblastiach.

Všeobecný postup digitálnej transformácie

Každá organizácia musí vykonať vlastnú dátovú transformáciu. Pri plánovaní transformácie musí brať do úvahy svoje kapacitné a finančné obmedzenia, ako i náročnosť celkovej úlohy. Odporúčame evolučný prístup, pričom vo všeobecnosti je potrebné postupovať podľa nasledovných krokov.

- **Krok 1. Dekonštruujte vaše pracovné postupy:** vykonajte dôslednú dekompozícii na jednotlivé úlohy a zamyslite sa, ako je možné jednotlivé úlohy posunúť. Je dôležité, aby ste sa venovali reálnemu spôsobu výkonu úloh (nie len formálnej pracovnej náplni). Pri každej úloha sa zamyslite,

do akej kategórie patrí: či je repetetívna alebo variabilná, interaktívna alebo nezávislá, fyzická alebo kognitívna. Definujte tiež rozhodovacie body a mieru možnej automatizácie. Potrebujete poznať dátové potreby pre optimálne rozhodovanie. Ďalej sa sústreďte na posun a redefiníciu hraníc vašej organizácie: ktoré úkony je možné vykonávať automaticky, ktoré je možné outsourcovať (napríklad cez platformu pre expertnú prácu) a ktoré sa dajú posunúť na inú organizáciu? Pri dekompozícii procesov a rozdelení úloh a funkcií postupujte podľa princípov RACI - "*responsible", "accountable", "consulted" a "informed".*

- **Krok 2. Posúďte hodnotu za peniaze:** preskúmajte, aký efekt dokážete dosiahnuť inováciu pre jednotlivé úkony v rámci pracovných postupov. Porovnajte výsledné benefity s nákladmi a vypočítajte hodnotu za peniaze. Práve hodnota za peniaze je najlepší spôsob pre stanovenie priorít jednotlivých etáp digitálnej transformácie.
- **Krok 3: Vyberte riešenie pre inováciu:** na základe hodnoty za peniaze a technologických možností vyberte optimálne riešenie automatizácie a navrhnite cestovnú mapu pre digitálnu transformáciu. Cestovná mapa môže pozostávať s viacerých projektov, ktoré budú postupne meniť vašu organizačnú štruktúru, technologické prostredie a spôsoby práce.
- **Krok 4: Implementujte inovácie:** a zaveďte inovácie do praxe. Vyžaduje si to programové riadenie projektov, ako i podporu experimentovania a posilnenie schopností chápať a využívať dáta. Výsledkom bude nový typ verejnej organizácie, orientovanej na vytváranie hodnoty z dátových tokov a ich využití pre lepšie rozhodovanie.

Kde sa môžeme ako inštitúcia posunúť v jednotlivých témach?

Inteligentné posudzovanie vplyvov umožní optimalizovať reguláciu

Nové technológie, akými sú sémantická analýza legislatívy, umelá inteligencia a dátová veda, umožnia systematicky vylepšovať regulačný rámec obsahujúci obrovský počet regulácií. Okrem inovácie regulačných postupov je preto v posudzovanie vybraných vplyvov potrebné podporiť aj komplexným IT riešením, ktoré bude schopné spracovať veľké množstvo relevantných údajov tak, aby v reálnom čase umožnilo sledovať vplyvy regulácií a hlavným aktérom v rozhodovacom procese prinieslo dostatočné nástroje pre posúdenie vypočítaných vplyvov a vzájomnú spoluprácu na zlepšovaní regulovaného prostredia.

Vďaka využitiu dát môžeme sledovať regulačnú zhodu

Inovácie v oblasti kontroly regulovaného prostredia že sme schopní znížiť administratívnu záťaž spojenú s preukazovaním súladu s reguláciami. V prípade, že je potrebné získavať informácie o prípadoch a chovaní na trhu je ideálne zbierať dáta automatizovaným spôsobom, cez API na ktoré by sa pripájali informačné systémy subjektov pôsobiacich v regulovanej oblasti. Napríklad takýmto spôsobom je možné jednoducho získavať údaje o preprave cez API od platforiem, ktoré poskytujú služby pre prepájanie vodičov a cestujúcich (ako Uber alebo Bold); od platforiem, ktoré sprostredkovávajú ubytovanie (AirBnB) alebo napríklad od utilitných spoločností.

Úradníci budúcnosti budú spolupracovať s algoritmami

Úradníci sú vybavení nástrojmi (algoritmami umelej inteligencie), ktoré im pomáhajú efektívne riešiť zadané prípady. Výsledky činnosti sú neustále monitorované, aby rozhodnutia boli v súlade zo zákonom, obdobné a vykonané čo najrýchlejšie. V prípade, že od rozhodnutia závisí nejaké udalosti v budúcnosti,

úradník získa aktualizovanú predstavu o pravdepodobnosti takýchto udalostí (napríklad pravdepodobnosť úspechu respektíve neúspechu posudzovaného projektu).

Prediktívna polícia dokáže poslať policajtov tam, kde sú potrební

Prediktívne policajné metódy sa vzťahujú na uplatňovanie matematických, analytických a dôkazných intervenčných techník na predvídanie, predchádzanie a zníženie kriminálnej činnosti. Ak budú úspešne implementované, môžu pomôcť znížiť kriminalitu, zmierniť riziko pre policajtov, informovať o účinnom prideľovaní zdrojov a znížiť zaujatosť a ľudské chyby pri zatýkaní. Je nevyhnutné pochopiť nuansy prediktívnych policajných metód v praxi, aby sa zabezpečila verejná bezpečnosť a aby bolo možné rutinne kontrolovať policajnú činnosť.

Virtuálni asistenti vám pomôžu zvládnuť životné situácie

Občania a podnikatelia často potrebujú pomoc orientovať sa vo svojich životných situáciach: v nárokoch, ktoré si môžu od štátu uplatňovať a v povinnostiach, ktoré musia riešiť, ako i v možnostiach podpory. Ak sa už rozhodnú niečo riešiť, často to potrebujú vybaviť automaticky a ihneď, alebo naopak pochopiť jednotlivé alternatívne spôsoby riešenia svojej životnej situácie. Ideálnou technológiou, ktorú môže verejná správa nasadiť pre tento typ problémov sú inteligentní asistenti, ktorí dokážu interakovať s klientami štátu, sprostredkovávať informácie a zabezpečovať riadny beh transakcií. Už dnes sú k dispozícii technologické funkcie, ako napríklad dynamický dialóg, umožnia automatizácii zvládnuť pokročilé konverzačné schopnosti. Virtuálni asistenti môžu byť proaktívni a budú schopní predpovedať možné výsledky na základe údajov.

Lepší manažment ľudských zdrojov vďaka umelej inteligencii

Ďalšou oblasťou, kde môže umelá inteligencie pomôcť inštitúciám verejnej správy je manažment ľudských zdrojov, ktoré môže mať verejná správa k dispozícii. V prvom rade sa dá zlepšiť nábor. Umelá inteligencia bude vedieť porovnať a vyhodnotiť stovky profilov za jednotku času, s prihliadnutím k najrôznejším parametrom hľadania a vyhodnocovania. Ak jeden zo systémov zlyhá, strojovým učením sa zvolí iný postup. Umelá inteligencia môže pomôcť aj so vzdelávaním a školeniami, vďaka personalizácií a sledovaniu pokroku každého zamestnanca. Zamestnanec môže mať prístup k svojim osobným údajom, napríklad k adrese, núdzovým kontaktom, podrobnostiam organizácie, dovolenkovým dňom, stavu schválenia žiadostí o dovolenku a autorizovaným údajom o ľudských zdrojoch.

Inovácia inštitúcií vďaka technológiám pre vrstvy dôvery

Decentralizované riešenia, ktoré môžu vzniknúť vďaka technológii decentralizovanej hlavnej knihy alebo aj blockchain majú potenciál disruptovať inštitúcie, ako ich poznáme, vďaka vytváraniu vrstvy dôvery medzi účastníkmi transakcií. Na zabezpečenie dôveryhodnosti transakcií už nebude potrebná dôveryhodná tretia strana, čo v mnohých prípadoch býva práve verejná inštitúcia. Znamená to, že dokážeme budovať štíhlejší intencionálny rámec, ktorý dokáže fungovať automaticky.

2 Úvod

Ako umelá inteligencia mení vzdelávanie

Bezprecedentný nárast množstva dát a príchod takzvaných veľkých dát menia náš svet zásadným spôsobom. Veľké dáta už mnohým organizáciám pomáhajú využívať zmysluplné inovácie, agilne transformovať procesy a tým zlepšovať ich celkové výsledky. **Dátová revolúcia sa ukázala ako impulz pre zmenu systému práce v mnohých odvetviach, vrátane vzdelávania**. Niektoré univerzity na svete už napríklad prijímajú technológie, ktoré dokážu prispôsobovať obsah učiva špecifickým schopnostiam študentov a vylučujú učiteľov z prednáškovej činnosti.

Počítač namiesto prednášajúceho

V princípe ide o novodobý typ takzvanej adaptívnej personalizovanej výučby poháňanej dátami. **Adaptívne vzdelávanie na báze dát sa vo všeobecnosti vzťahuje na učenie prostredníctvom počítača, ktorý neustále vyhodnocuje spôsoby uvažovania a myslenia študenta a automaticky prispôsobuje vyučovací materiál návykom konkrétneho študenta**. Takáto výučba funguje v praxi nasledovne: študenti namiesto počúvania prednášajúceho a zapisovania si poznámok používajú softvérový panel, ktorý im umožňuje prechádzať medzi videami, textom, kvízmi a precvičovať si úlohy vlastným tempom. V procese takejto výučby sú odpovede na úlohy spolu s množinami údajov o spôsoboch, akým študenti k týmto odpovediam dospeli rozosielané na vzdialené servery. Prediktívne algoritmy vyvinuté tímom dátových vedcov porovnávajú svoje štatistiky s dátami zhromaždenými od desiatok tisícov ďalších študentov, hľadajú spoločné znaky toho, čo sa každý študent naučil ľahko, ktoré časti učiva mu naopak robili problémy, čo by sa mal naučiť ďalej a ako presne by si konkrétne učivo mal osvojiť, aby ho neskôr nezabudol.

Medzi hlavné prínosy personalizovaného vyučovania postaveného na dátach patria:

- Rýchla diagnostika silných a slabých stránok každého študenta.
- Prispôsobenie tempa a obsahu vyučovania individuálnym potrebám a možnostiam každého študenta.
- Agilné vyučovanie, ktoré študentovi umožňuje vlastný časový manažment bez nutnosti navštevovania prednáškových miestností.
- Algoritmy schopné robiť všetky druhy prognózovania určia, v ktorú hodinu dňa je študent schopný sa naučiť a zapamätať si konkrétny vyučovací materiál.
- Jednoduchšie sledovanie výkonov študentov a ich progresu pre učiteľa.
- Jednoduchšie známkovanie a hodnotenie študentov pre učiteľa.
- Relatívne nízka cena – platí sa „iba“ za softwér.

Zástancovia verzus oponenti a budúcnosť nového prístupu

Zástancovia adaptívneho vzdelávania na báze dátovej analytiky tvrdia, že toto technologické riešenie poskytuje každému študentovi na mieru vytvorené individuálne inštrukcie za prijateľnú cenu využívania analytického softwéru. Ide tiež o efektívny spôsob, ako sa vyrovnať s rastúcim počtom študentov, znižujúcim sa rozpočtom mnohých univerzít a prísnejšími požiadavkami na výsledky študentov. Na druhej strane kritici tohto prístupu sú presvedčení, že takýto typ vyučovania môže zmeniť školy na akési

továrne. Takúto formu digitalizácie vnímajú ako ďalší spôsob pre obohacovanie IT spoločnosti, ktoré pretláčajú svoje produkty v mene „reformy“ do všetkých oblastí, kde je to možné. Oponenti tvrdia, že všetky prínosy diagnostiky a prispôsobovania učiva zvládajú už stovky rokov učitelia a sú presvedčení, že namiesto delegovania týchto úloh na počítače by štáty mali radšej investovať prostriedky na školenia a motivačné ohodnotenie kvalitných učiteľov.

Stručne zhodnotené, pravdu do istej miery majú oba tábory a riešenie bude potrebné nájsť v spoločnom konsenze. **Vyučovanie sa jednoznačne bude musieť prispôsobiť požiadavkám digitálnej doby a všetkým príležitostiam, ktoré technológie a dátová analytika ponúkajú pre skvalitnenie výučby; súčasne sa však technologické nadšenie nemôže preceňovať a je nepravdepodobné, aby počítač mohol raz úplne nahradiť funkciu, ktorú zosobňuje vysoko vzdelaný a skúsený človek stojaci pred katedrou so všetkými vedomosťami, zručnosťami a – predovšetkým – s ľudským prístupom, ktorý študentom môže ponúknuť**.

Dokáže umelá inteligencia zmeniť prácu úradníkov?

Pri úvahe o dopade zavádzania nových technológií na pracovnú činnosť v rámci inštitúcii verejnej správy je potrebné najprv pochopiť, ktoré schopnosti ľudí budú v budúcnosti nahradené, ktoré môžu byť vylepšené a v ktorých oblastiach budú ľudia naďalej výrazne lepší.

Tabuľka 1: Prehľad schopností a výhod[1]

Aktivity v ktorých sú výrazne lepší ľudia		Vedenie (Leadership)
		Empatia
		Tvorenie
		Úsudok
Hybridné aktivity	Ľudia doplnia a podporia algoritmy - nové riešenia sa budú vyžadovať nové pracovné náplne	Trénovanie algoritmov
		Vysvetľovanie chovania algoritmov
		Údržba algoritmov
	Ľudia získajú vďaka AI superschopnosti	Zosilnenie ľudských schopností
		Interakcia
		Prepojenie práce ľudí s prácou strojov
Aktivity v ktorých sú výrazne lepšie algoritmy		Predikcia
		Adaptácia
		Realizácia transakcií

[1] Zdroj: Paul R. Daugherty; H. James Wilson (2018): *Human + Machine: Reimagining Work in the Age of AI*

	Iterácia

Typy úloh a možnosti automatizácie

Ak sa zaoberáme touto otázkou, v prvom kroku je potrebné pochopiť, aké typy úloh pracovníci (a špeciálne úradníci) vykonávajú. Každý z typov úloh podporuje rôzne možnosti automatizácie.

Tabuľka 2: Typy úloh pracovníkov[2]

Rozdelenie	Typ úlohy	Popis
Repetetívna alebo Variabilná	Repetetívna	Práca je predikovateľná, rutinná, a určená na základe jasných pravidiel. Veľká časť úradníckych postupov, najmä v správnom konaní a pri vybavovaní žiadostí je repetetívna. Repetetívna práca je výrazne vhodná na automatizáciu, najmä podľa postupov RPA (Robot Process Automation).
	Variabilná	Prácu nie je možné dopredu predikovať a je potrebné adaptívne prispôsobovanie cieľov a metód vzhľadom na meniace sa okolnosti. Budúcnosť práce úradníkov vnímame ako čím ďalej viac variabilnú. Za príklad variabilnej práce je možné považovať konzultantov, ktorí sa musia vedieť prispôsobiť potrebám rôznych klientov a navrhovať riešenia pre ich špecifické problémy. Dá sa predpokladať, že pokrok v kognitívnom strojovom učení umožní automatizovať niektoré analytické úlohy, ako i učiť sa z predchádzajúcich projektov.
Interaktívna alebo Nezávislá	Interaktívna	Interaktívna práca spočíva na komunikácií a spolupráci s inými ľuďmi (spolupracovníkmi, zákazníkmi) a medziľudský kontakt hrá významnú úlohu. Príkladom sú pracovníci klientskych centier respektíve call centier. Títo pracovníci musia vedieť pochopiť emócie a psychický stav klienta a ponúknuť mu čo najvyššiu mieru zážitku. V súčasnosti je možné automatizovať aj tento typ úloh, ako napríklad rozpoznanie emócie, alebo vybavenie klienta cez chatbota.
	Nezávislá	Nezávislá práca nevyžaduje potrebu spolupráce a komunikácie s ostatnými. Príkladom nezávislej práce je tvorba expertných posudkov, spracovanie analytických reportov na základe preddefinovaných šablón alebo účtovníctvo. Takáto práca sa dá vykonávať nezávisle, pri spracovávaní údajov z definovaných zdrojov. Veľkú časť nezávislej práce je možné automatizovať pomocou dostupných techník: napríklad RPA môže byť použitá

[2] Zdroj: Ravin Jesuthasan, John W. Boudreau (2018): *Reinventing Jobs: A 4-Step Approach for Applying Automation to Work*

Rozdelenie	Typ úlohy	Popis
		Fna zber údajov, strojové učenie môže byť použité na analytické úlohy a spracovanie určitých typov zostáv.
Fyzická alebo Kognitívna	Fyzická	Ide o manuálnu prácu, ktorá vyžaduje fyzický pohyb a silu. Napríklad časť úloh colníkov, policajtov alebo hasičov je možné považovať za fyzickú prácu. Nové technológie, ako sociálna a kolaboratívna robotika, použitie mobilných technológií alebo využitie senzorov môžu výrazne zefektívniť manuálnu prácu. Manuálna práca môže byť tiež lepšie organizovaná vďaka využitiu nástrojov ako je prediktívna polícia.
	Kognitívna	Kognitívna práca je postavená na myslení: spracovanie informácií, rozhodovanie alebo použitie úsudku na určenie hodnoty alternatív. Umelá inteligencia má potenciál automatizovať práve kognitívne činnosti a tým výrazne zmeniť obsah pracovnej náplne úradníka.

Spôsoby automatizácie

Pri uvažovaní o transformácií práce je možné použiť 2 prístupy: dekonštrukcia práce a rekonfigurácie práce. V prípade **rekonfigurácie pracovných úloh** je dôraz kladený na optimalizáciu procesov a lepšiu spoluprácu jednotlivých organizačných jednotiek. Najlepší výsledok je možné dosiahnuť vďaka lepšej výmene informácií a manažmentu toku údajov. **Dekonštrukcia pracovných postupov** sa venuje ich rozloženiu na jadrové úlohy a následné preusporiadanie so zámerom zvýšenia efektivity a inovácií. Automatizácia je kľúčovým faktorom pri dekonštrukcii pracovných postupov.

Automatizácia dokáže súčasné pracovné úlohy:

1. Nahradiť.
2. Vylepšiť.
3. Vytvoriť nový typ úlohy.

Za základné prístupy k automatizácií pracovných postupov je možné považovať:

- **Robot Process Automation (RPA):** RPA je najjednoduchší spôsob automatizácie. Jeho podstata znamená v automatizovaní procesov na základe dopredu definovaných pravidiel (napríklad expertných systémov). Ide napríklad o výmenu dát medzi informačnými systémami a ich triedenie. RPA je možné implementovať klasickými nástrojmi informačných systémov. RPA je vhodná pre repetetívne úlohy (ak chceme rovnaké výsledky pre rovnaké vstupy), ako je napríklad registrácia vo verejných databázach, prevody pozemkov, platby za vládne služby, vyplácanie dávok, zmena trvalého pobytu, registrácia obchodnej spoločnosti. Ďalšou skupinou úloh, ktoré sa dajú vyriešiť cez RPA, sú redundantné kroky v biznis procesoch. V procesoch verejnej správy môžeme nájsť veľké množstvo redundantných krokov, najmä v rôznych úrovniach schvaľovania, alebo pri výmene informácií medzi organizáciami. Treťou skupinou úloh, veľmi významnou pre budúcu modernizáciu verejnej správy sú aplikácie pre manažment rizika. Sledovanie, či sa v danej oblasti dodržujú pravidlá môže byť vykonávané automaticky, napríklad audity projektov, verejných obstarávaní, audity vynakladanie verejných prostriedkov a podobne.

- **Automatizácia kognitívnych procesov:** znamená riešenia, ktoré dokážu automatizovať ľudské myslenie. Riešenia, postavené na strojovom učení vyniká v rozpoznávaní vzorov a v predikcii. Vďaka týmto schopnostiam je možné riešiť aplikácie ako rozpoznávanie obrazov, strojové spracovanie reči a podobne. V mnohých ohľadoch dokáže systém sám identifikovať pravidlá a učiť sa na základe vstupných dát a dosahovaných výsledkov. Vďaka automatizácií kognitívnych procesov je možné skúmať dopady regulácií, automatizovane vytvárať podklady pre rozhodovanie sudcov v súdnych konaniach, identifikovať podvody alebo diagnostikovať v lekárstve. Napríklad práca inšpektora môže byť nahradená vzdialenými supervízormi. Ďalšou možnosťou ako využiť automatizáciu kognitívnych procesov je návrh nových verejných služieb, napríklad personalizované balíčky podpory ľuďom v núdzi. Technológia sa dá využiť tiež na hľadanie nových poznatkov v dátach, napríklad pri hodnotení vplyvov regulácií.
- **Kolaboratívna robotika:** ide o riešenia, použiteľné na manuálne alebo interaktívne pracovné úlohy, kde je potrebná spolupráca alebo interakcia s ľuďmi. Do tejto oblasti patrí napríklad obsluha požiadaviek občanov prostredníctvom chatbotov, alebo používanie dronov pri kontrole používania dotácií alebo pri asistencii v dopravných nehodách.

Vo verejnej správe by sme mali navrhovať dôveryhodnú umelú inteligenciu zameranú na človeka

Je všeobecným faktom, že umelá inteligencia sa do dnešných dní vyvíjala bez potrebnej regulácie, čo vedie k zásadným problémom v etickom využívaní tejto prelomovej technológie. Neregulované zavádzanie AI a digitálnych technológií predovšetkým v Spojených štátoch amerických umožnilo technologickým gigantom akými sú Google či Facebook neeticky zhromažďovať obrovské množstvo súkromných informácií. Veľká časť týchto dát bola a naďalej je široko zdieľaná s vládami, ako aj so súkromnými spoločnosťami, a to často bez riadnych povolení. Vláda USA nielenže nie je schopná regulovať rozvoj digitálnych technológií a umelej inteligencie, ale nedodržiava ani základné etické princípy pri využívaní týchto technológií (ako dokazujú odhalenia Edwarda Snowdena o špionážach NSA namierených na európskych politikov).

Za týchto okolností sa Európska únia rozhodla ísť príkladom a začala pracovať na radikálnej regulácií vývoja digitálnych a iných vyspelých technológií, pričom opatrenie GDPR bolo prvým nevyhnutným krokom na tejto ceste. Ďalším nadväzujúcim logickým krokom je vytvorenie rámca pre etickú AI, ktorý bude chrániť jednotlivcov a ich osobné údaje, bude vytvárať viac investícií a príležitostí pre európske start-upy, ako aj prispievať k celospoločenskému dobru. V nadväznosti na to Expertná skupina na vysokej úrovni pre umelú inteligenciu Európskej komisie (AI-HLEG) vydala dňa 18. decembra 2018 dokument Etické usmernenia pre dôveryhodnú umelú inteligenciu, ktorý volá po novom prístupe k umelej inteligencii, ktorý bude založený na nasledujúcich 7 kľúčových požiadavkách pre etický proces vývoja, zavádzania a používania AI:

- 1. Ľudský faktor a dohľad,
- 2. Technická odolnosť a bezpečnosť,
- 3. Správa súkromia a údajov,
- 4. Transparentnosť,
- 5. Rozmanitosť, nediskriminácia a spravodlivosť,
- 6. Environmentálny a spoločenský blahobyt,
- 7. Zodpovednosť.

AI-HLEG ďalej vydala dňa 26. júna 2019 dokument Politické a investičné odporúčania pre dôveryhodnú AI, ktorý volá po zintenzívnení výskumu a investícií do budovania etickej AI v EÚ. Vízia Komisie je konkrétne založená na troch pilieroch:

- Zvýšenie verejných a súkromných investícií do AI,
- Príprava na sociálno-ekonomické zmeny,
- Zabezpečenie vhodného etického a právneho rámca na ochranu a posilnenie európskych hodnôt.

Dokument celkovo obsahuje 33 odporúčaní, medzi ktoré napríklad patria: automatizácia rizikových pracovných miest, v rámci ktorých sú ohrozené ľudské životy; vytvorenie dostupných digitálnych verejných služieb pre jednotlivcov a podniky na všetkých úrovniach verejnej správy, prístupných pri plnom rešpektovaní individuálnych práv a súkromia (ako vzorový príklad tu figuruje estónska verejná správa); posilnenie mechanizmov výskumu, vzdelávania a financovania v rámci EÚ; zákaz alebo obmedzenie neoprávneného osobného, fyzického alebo mentálneho sledovania alebo identifikácie na báze AI; či navrhnutie medzinárodného moratória na vývoj automatizovaných smrtiacich zbraní.

Všetky tieto odporúčania a princípy, ktoré navrhuje AI-HLEG, by v praxi vytvorili príležitosť pre start-upy pri budovaní verejných systémov na zber údajov, ako aj na ochranu a správu vecí verejných a podporovali by investície do konceptov založených na AI na riešenie sociálnych potrieb v dôsledku naliehavých spoločenských výziev, akým je napríklad zmena klímy. Európska startupová komunita, univerzity a inkubátory by sa mali aktívne zapájať do aktivít AI-HLEG a podporovať implementáciu týchto odporúčaní a tým zaručiť, že vyvíjajúce sa normy nestratia verejný dosah a ani zreteľ na to podstatné – na človeka.

3 Prehľad inovácií postavených na dátach

V nasledujúcej kapitole sa venujeme spracovaniu prehľadu prípadov použitia inovácií postavených na dátach: postupne vysvetlíme nové trendy, technológie a riešenia, ako boli vnímané na konci roku 2019.

3.1 Nové trendy

Rozvoj dátovej analýzy je jedným z aktuálnych trendov v IT. Objavujú sa stále nové a nové programy premieňajúce surové dáta (napríklad zo senzorov v prístrojoch vo výrobe alebo v sklade) na užitočné analýzy (kedy sa prístroj pokazí alebo aká by mala byť optimálna úroveň zásob) a využívajú na to inteligentné algoritmy. Tento trend začal v laboratóriách big tech a v súčasnosti sa presúva do organizácií po celom svete.

Rozvoj dátovej analytiky pritiahol pozornosť rizikového kapitálu (Venture Capital), ktorý do oblasti začal investovať. 35 startupov, ktoré robia dátovú analýzu je ocenených na viac ako 1 miliardu dolárov. Spolu dosahujú valuáciu až 73 miliárd dolárov, z toho je 6 najväčších ocenených na 45 miliárd dolárov. Rastú tiež prostriedky spoločností vynaložené na "big data" a "business analytics", predpokladá sa, že v roku 2019 dosiahnu až 67 miliárd dolárov. Konzultačná spoločnosť McKinsey minulý rok predpovedala, že analytika stojaca na AI do roku 2030 prispeje 16% rastom k svetovému HDP. Najväčší rast je odhadovaný v odboroch maloobchodu, prepravy a logistiky a dopravy (pozri Obrázok 1).

Obrázok 1: Príspevok AI analytiky k rastu jednotlivých odvetví

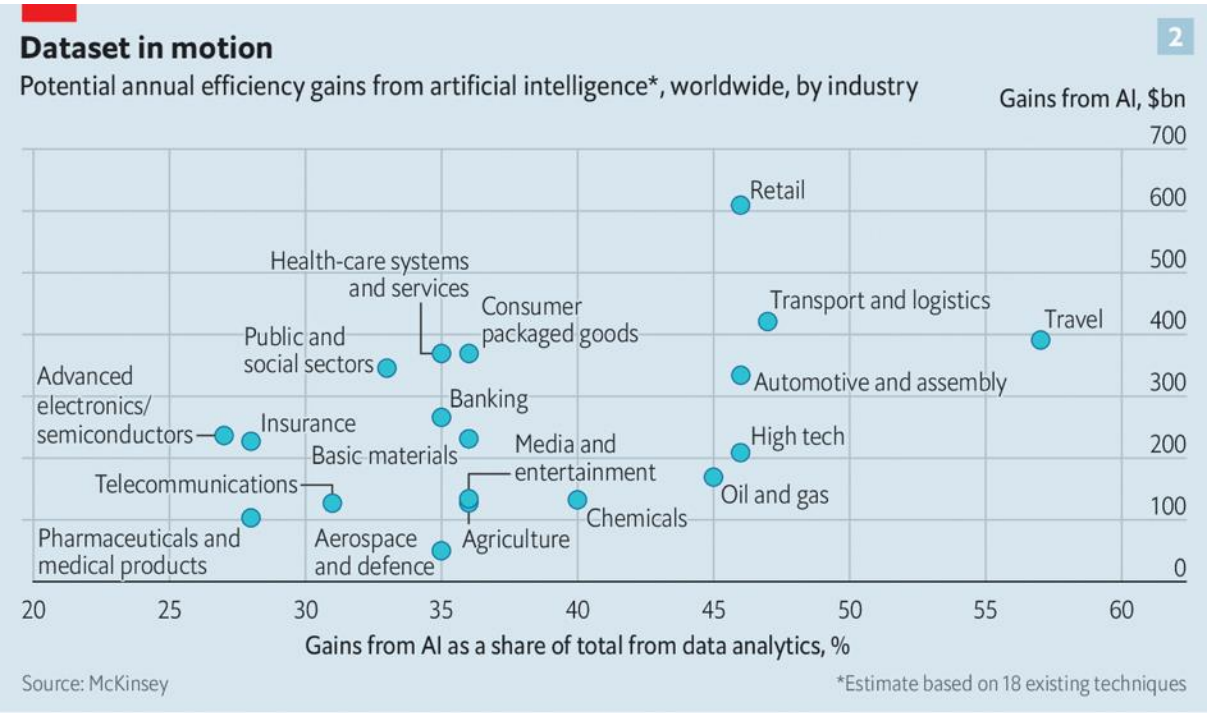

The Economist

Verejnú správu čaká ešte dlhá cesta než bude využívať umelú inteligenciu (AI) naplno. Spracovávanie informácii z množstva prepojených zariadení (Internet of Things) je ešte stále náročné a nákladné. Iba pár spoločnostiam sa podarilo vytvoriť platformy, kde sú schopné zbierať a analyzovať veľké množstvo informácií. Patria k nim Apple a Google so svojimi operačnými systémami pre mobilné zariadenia.

Snahou spoločností aktívnych v dátovej analýze je vybudovanie AI platformy, ktorá by automaticky premietala surové dáta do formátu vhodného pre algoritmy a ponúkala nástroje na návrh software, ktoré by mohli používať aj ľudia s obmedzenými programátorskými znalosťami.

3.2 Konkrétne firmy a riešenia

C3

Spoločnosť C3 začínala s cieľom pomôcť energetickým spoločnostiam efektívne spravovať ich siete. Táto úloha predstavuje komplexný problém, ktorý zahŕňa zber a spracovanie dát z množstva zdrojov. Spoločnosti sa podarilo uspieť vďaka pokrokom, ktoré sa uskutočnili v oblastiach ako machine learning, senzory a dátová prepojiteľnosť.

Cieľom spoločnosti C3 je, aby bola dátová analýza pre firemných klientov jednoduchá na používanie a zároveň dostatočne sofistikovaná. Spoločnosť 3M využíva SW spoločnosti C3 na rozpoznávanie faktúr, ktoré by mohli vyvolať problémy s klientami. Air Force Spojených Štátov Amerických ho používa na predpovedanie, ktorá časť lietadla by mohla mať v blízkej dobe poruchu. Jedným z možných použití je v zdravotníctve, kde riešenie umožní identifikáciu hroziacich zdravotných rizík, ako napríklad chrípkovej epidémie. Program príde tiež s návrhom najefektívnejších zásahov na odvrátenie hrozieb. Ďalší use case predstavuje správa rozvodnej sústavy elektrickej energie. Program vie vyhodnotiť, ako spravovať sieť, aby bola zachovaná kvalita dodávok pri najefektívnejšom využití prostriedkov.[3]

Obrázok 2: Prediktívna údržba na základe dátovej analýzy[4]

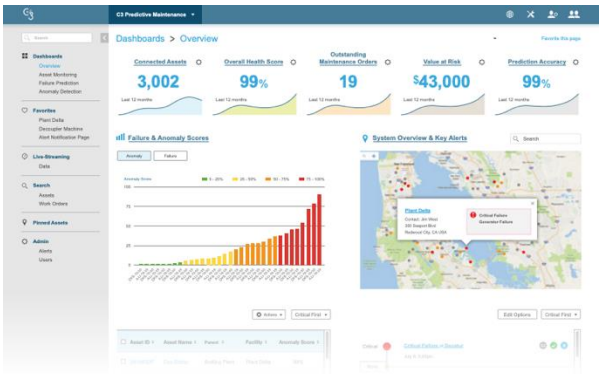

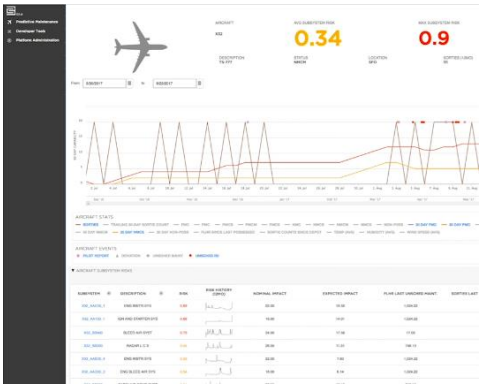

Databricks

Software spoločnosti Databricks je schopný spracovávať množstvá dát zo senzorov a pripojených zariadení v reálnom čase. V súčasnosti pracujú na rozšírení spracovávania na ďalšie dátové vstupy. Medzi ich klientov patria startupy, ako napríklad cestovateľský portál hotels.com alebo mediálne spoločnosti (Viacom). Portál hotels.com využíva SW na výber vhodných ilustračných obrázkov k hotelu, tak aby priniesli čo najvyššie predaje.

[3] https://c3.ai/industries/publicsector-cities/

[4] c3.ai

Ďalším možným spôsobom využitia je detekcia podvodov, napríklad pri výbere daní. Program je schopný na základe analýzy množstva dát a za využitia AI pri ich spracovaní upozorňovať na podozrivé prípady, ktoré je potom možné preveriť. Dátová analýza tiež umožní spracovať množstvo dát, ktoré majú už teraz k dispozícii verejné orgány a využiť ich pre poskytovanie lepších verejných služieb.[5] Ďalšie možnosti využitia dátovej analýzy v štátnej správe sú zobrazené na Obrázok 4

Očakávaný obrat Daatbriks v roku 2019 je 200 miliónov dolárov a pri poslednom zbieraní kapitálu vo februári tohto roku bola ocenená na 2,8 mld. dolárov.

Obrázok 3: Analýza predajov od Databricks[6]

Obrázok 4: Využitie Databricks v štátnej správe[7]

Dataiku, Domino, veľké technologické firmy

Ďalšie spoločnosti, ktoré sa snažia vytvoriť AI-platformu sú Dataiku z New Yourku alebo Domino Data Lab zo San Francisca. Dataiku je schopné spracovávať informácie z dopravných senzorov a informácie

[5] https://www.dataiku.com/solutions/industries/public-sector/

[6] https://www.g2.com/products/databricks/reviews

[7] https://databricks.com/solutions/industries/federal-government

využívať na optimalizáciu prevádzky verejnej dopravy a tiež na riadenie dopravy ako takej.[8] Pozadu však nezostávajú ani technologický giganti ako Amazon, Google a Microsoft, ktorí chcú byť dominantný, tak ako v ostatných oblastiach softvéru, aj v pokročilej dátovej analýze. Predpokladá sa, že táto aktivita bude mať za výsledok, že dátová analýza bude vďaka asistencii AI rovnako jednoduchá, ako práca v exceli. Je pravdepodobné, že data analytické programy budú rovnakou súčasťou firemných IT systémov, ako sú v dnešnej dobe CRM (customer relations management) systémy.

Obrázok 5: Spolupráca na dátovej analýze v programe Dataiku[9]

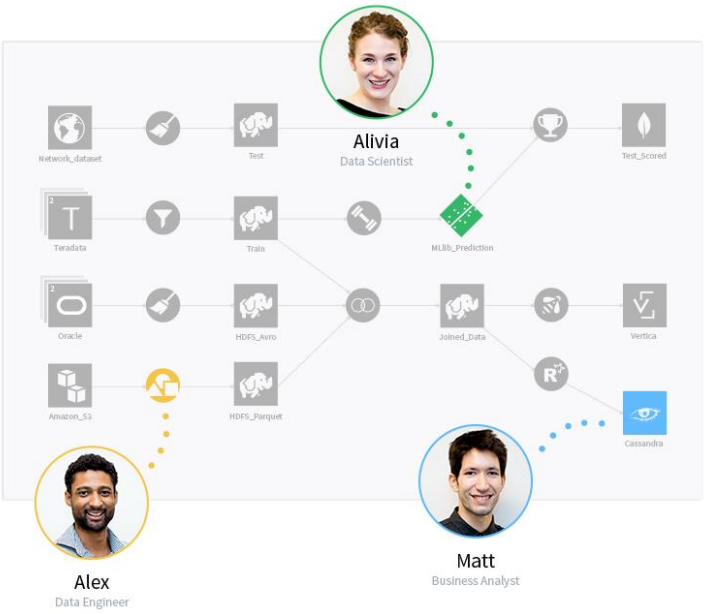

Obrázok 6: Dátová analýzy v prostredí Domino Data Lab[10]

[8] https://www.dataiku.com/solutions/

[9] https://www.g2.com/products/dataiku/reviews

[10] https://www.dominodatalab.com/demo/

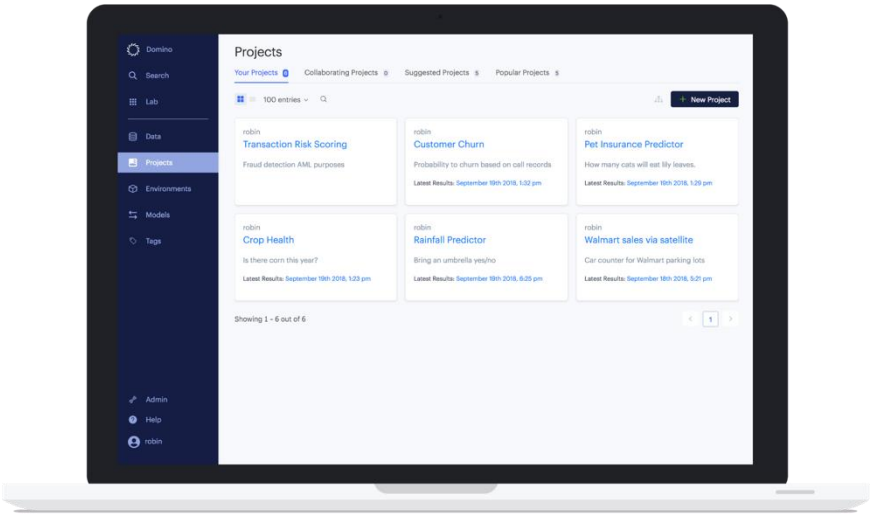
Domino
Search
Lab
Data
Projects
Environments
Models
Tags
Admin
Help
robin
Projects
Your Projects 6
Collaborating Projects 0
Suggested Projects 5
Popular Projects 5
100 entries
New Project
robin
Transaction Risk Scoring
Fraud detection AML purposes
robin
Customer Churn
Probability to churn based on call records
Latest Results: September 19th 2018, 1:32 pm
robin
Pet Insurance Predictor
How many cats will eat lily leaves.
Latest Results: September 18th 2018, 1:29 pm
robin
Crop Health
Is there corn this year?
Latest Results: September 19th 2018, 1:23 pm
robin
Rainfall Predictor
Bring an umbrella yes/no
Latest Results: September 19th 2018, 6:25 pm
robin
Walmart sales via satellite
Car counter for Walmart parking lots
Latest Results: September 18th 2018, 5:21 pm
Showing 1 - 6 out of 6
1

4 Metódy, techniky a nástroje pre lepšie využitie údajov

V tejto časti je popísaný prehľad metód, techník a nástrojov pre lepšie využitie údajov: štatistické analýzy, strojové učenie a umelá inteligencia. Venujeme sa základným modelom a analytické nástroje, ktoré je možné využiť pri spracovaní údajov a následnom rozhodovaní.

Tabuľka 3: Prehľad nových technológií a metód, na ktoré by sa mali inštitúcie verejnej správy sústrediť

Metóda	Definícia	Príklady aplikácie v praxi
Strojové učenie	Odbor počítačovej vedy, ktorý sa venuje návrhu a hodnoteniu algoritmov, ktoré dokážu v dátových množinách rozpoznať významné vzory. Algoritmus strojového učenia na vstupe spracuje dataset a vracia model, ktorý obsahuje vzor nachádzajúci sa v dátach. Strojové učenie umožňuje výrazne zefektívniť predikciu a je vhodné pre automatizáciu a objavovanie vzorov v dátach.	Strojové učenie môže pomôcť organizáciám s manažmentom zdrojov na efektívne riešenie verejných problémom, s nastavovaním politík a analýzou ich dopadov ako i s podporou rozhodovania, napríklad určovanie optimálnej výšky trestu, posudzovanie dôkazov, územné plánovanie, plánovanie budúcej kapacity verejných služieb ako i vysielanie policajných hliadok, aby bola minimalizovaná miera kriminality (prediktívna polícia). Strojové učenie dokáže tiež odhaľovať vzory a závislosti v dátach, čo má význam pri detekcii podvodov.
Analýza sociálnych sietí	Analýza sociálnych sietí (SNA) je proces skúmania sociálnych štruktúr pomocou sietí a teórie grafov. Charakterizuje sieťové štruktúry z hľadiska vrcholov (jednotlivých aktérov, ľudí alebo vecí v sieti) a hrán alebo väzieb (vzťahov alebo interakcií), ktoré ich spájajú. Medzi príklady sociálnych štruktúr bežne vizualizovaných prostredníctvom analýzy sociálnych sietí patria siete sociálnych médií, šírenie memov, obeh informácií, sociálne siete, obchodné siete, znalostné siete, pracovné vzťahy, grafy spolupráce, príbuzenstvo, prenos chorôb a sexuálne vzťahy.	Analýza sociálnych sietí sa dá vo verejnej správe použiť pri: ■ boji proti extrémizmu, ■ odhaľovaní štruktúry zločineckých skupín a ekonomickej kriminality (podvody s DPH a podobne), ■ kontrole verejného obstarávania, ■ efektívnom nastavovaní spolupráce a štruktúry organizácie verejnej správy a podobne.
Automatizácia	Automatizácia je vo všeobecnosti nahradenie ľudskej práce prostredníctvom umelo vykonávaných činností algoritmami (kognitívna časť) alebo robotmi (manuálna časť).	Automatizáciu je možné vo verejnej správe využiť: ■ na okamžitú obsluhu pri základných verejných službách

Metóda	Definícia	Príklady aplikácie v praxi
	Rozlišujeme tri druhy automatizácie: RPA, Automatizácia kognitívnych procesov a Kolaboratívna robotika.	(napríklad prevody nehnuteľností), ■ na vyriešenie duplicitných krokov (napríklad registrácie obchodných spoločností v rôznych inštitúciách), ■ na vyriešenie rutinných úloh (napríklad spracovanie a účtovanie platieb), ■ na manažment rizika pri sledovaní regulačnej zhody.
Internet vecí „IoT“	Internet vecí sa všeobecne považuje za motor digitálneho technologického rastu. Vďaka vysokému objemu dát, ktoré pochádza z inteligentných zariadení spoločnosti horlivo pracujú na analytických systémoch aby dali dátam, ktoré sa nepretržite a v reálnom čase zaznamenávajú, zmysel, a tým vytvárali hmatateľné poznatky. Práve prostredníctvom IoT môžu spoločnosti efektívnejšie, rýchlejšie a kvalitnejšie spracovávať dáta a využívať ich na ďalšie procesy.	Internet vecí vo verejnej správe je možné použiť: ■ ako zdroj údajov o regulovaných oblastiach, napríklad senzorové siete pre snímanie faktorov ovplyvňujúcich zdravie, parametrov životného prostredia, dopravných tokov a podobne. Senzorové siete sú tak dôležitým faktorom pre možnosť regulácie 2.0. ■ IoT je možné použiť pri sledovaní stavu verejnej infraštruktúry a pri jej prediktívnej údržbe.
Distribuované databázy a blockchain	Blockchain je buď najdôležitejšou technologickou inováciou od internetu alebo zbytočným a drahým riešením, ktoré vytvára najmä problémy. Technológia Blockchain je postavená na rastúcom zozname záznamov, nazývaných bloky, ktoré sú spojené pomocou kryptografie. Každý blok obsahuje kryptografický hash predchádzajúceho bloku, časovú pečiatku a údaje o transakciách (všeobecne reprezentované ako Merkle tree). Unikátnou vlastnosťou blockchainu je možnosť vytvoriť vrstvu dôvery medzi aktérmi bez potreby tretej strany.	Blockchain sa môže používať na finančné inovácie (takzvané kryptomeny), overovanie digitálnej identity, pravosti pôvodu, platobné systémy pre hudobníkov a generátory webového obsahu, ako aj mnohé ďalšie procesy, ktorých kvantita bude v najbližšom období rásť. Blockchain vo verejnej správe je možné použiť na: ■ realizáciu notárskej funkcie, ■ evidenciu a následné overovanie komplexných procesov (certifikácia, licencie, zahraničnо obchodné transakcie, patenty),

Metóda	Definícia	Príklady aplikácie v praxi
		■ manažment tokov hodnoty (napríklad manažment odpadov a cirkulárna ekonomika), ■ online ekonomiku (okamžité spracovanie transakcií a dôveryhodné účtovanie).
Rozšírená realita	Kombinuje technológiu umelej inteligencie a virtuálnej reality aby bolo možné vytvoriť nové vrstvy pre interakciu vo fyzickom svete.	Napríklad vizualizácia a ovládanie inžinierskych sietí cez mobilné zariadenie alebo použitie rozšírenej reality v colných skladoch (v colných procesoch) alebo v rámci činnosti zásahových jednotiek (polície, záchranných zložiek, hasičstva).

5 Odporúčania pre inštitúcie verejnej správy

V nasledujúcej časti je možné nájsť konkrétne návrhy a návody a špecifikáciu vzorových odporúčaní pre inštitúcie verejnej správy: definujeme konkrétne kroky na odstraňovanie problémov verejnej správy na základe dátových analýz a lepšieho rozhodovania ponúkame tutorial ako jednotlivé rozhodovania oprieť o dostupné údaje. Obsah je štrukturovaný podľa úrovne rozhodovania: od návrhu politík a strategického rozhodovania, cez plánovanie, po operatívne rozhodovanie v konkrétnych situáciach.

Pri nasadzovaní riešení postavených na umelej inteligencii odporúčame si najprv klásť takzvanú "otázku nula": či riešenie vo forme automatizácie, aj keď je v tej ktorej oblasti technicky možné, je vhodné, aby bolo naozaj z dôvodu vyšších princípov aplikované a činnosť ľudí nahradená. Otázka nula je zásadná z pohľadu budovania udržateľnej konkurencieschopnosti, zamestnanosti ale aj sociálnej stability a ďalšieho intelektuálno-kultúrneho smerovania obyvateľstva v SR.

Tabuľka 4: Prehľad oblastí vo verejnej správe, kde je možné zlepšiť rozhodovanie

Oblasť	Použitie	Príklady aplikácie v praxi
Lepší návrh politík a regulácií	Posudzovanie vplyvov regulácií pomocou veľkých dát: vďaka online posudzovaniu vplyvov a využitie údajov na simulácie dopadov a testovanie účinnosti politík.	Komplexné posudzovanie vybraných vplyvov regulácií Posudzovanie vplyvov na životné prostredie pomocou veľkých dát, napríklad využitie dátovej analýzy na naplnenie cieľov uhlíkovej neutrality 2050 a zníženia emisií do 2030 Posudzovanie sociálnych vplyvov
Lepší dozor a dohľad nad regulovaním prostredím	Využitie údajov pre online monitoring regulovaného prostredia.	**Modelovanie prostredia** Monitoring faktorov ovplyvňujúcich zdravie Monitoring kvality životného prostredia Monitoring dopravnej situácie
Inovácie procesov	Vďaka zdieľaniu údajov a využitiu automatizovaných analýz prípadov, využitie podporných analytických nástrojov pre lepšie operatívne rozhodovanie. Dôležité je navrhnutie metódy čistenia údajov a zabezpečenie, že údaje nie sú diskriminačné.	Podpora rozhodovania v správnom konaní (automatizovaný stavebný poriadok) Podpora rozhodovania v súdnych procesoch Automatizovaná identifikácia priestupkov
Lepšie riadenie zdrojov a	Vďaka využitiu predikcií budúcich udalosti.	**Prediktívna polícia** Prediktívne hasičstvo

Oblasť	Použitie	Príklady aplikácie v praxi
plánovanie činností		Prediktívne kontroly (daňové, colné, verejné obstarávanie a podobne)
Zvýšenie kvality služieb	Vďaka automatizovanému spracovaniu podaní, vytvárania znalostnej bázy, zavádzaniu automatizovanej obsluhy (cez „chatbotov“). Je potrebné zabezpečiť manažment osobných údajov počas ich celého životného cyklu.	Asistencia pri riešení životných situácií Právna pomoc
Lepší manažment zdrojov	Využitie umelej inteligencie pre manažment ľudských zdrojov a celkové riadenie organizácie a jej výkonnosti, a podobne.	Manažment ľudských zdrojov
Distribuovaná evidencia	Využitie technológie blockchain pre transformáciu evidencie	Automatizované notárstvo Zdravotná dokumentácia

5.1 Posudzovanie vplyvov regulácií pomocou veľkých dát

Veľké dáta a umelá inteligencia dokážu ovplyvniť aj strategickú činnosť verejnej správy, keď inštitúcia potrebuje navrhovať vhodné pravidlá a regulácie, aby vyriešila problémy v rámci svojho mandátu. V súčasnosti sa začínajú aj vďaka analytickým jednotkám zlepšovať schopnosti verejnej správy chápať dôsledky prijímanej legislatívy. Tento proces sa dá výrazne zlepšiť systematickým nasadením analytických metód v reálnom čase. V nasledujúcej časti sa pozrieme na posudzovanie vplyvov regulácií pomocou veľkých dát, ako je možné transformovať proces posudzovaniu vplyvov vďaka využitiu údajov na simulácie dopadov a testovanie účinnosti politík.

5.1.1 Úvod

Základným konceptom, ktorým sa budeme zaoberať v tejto kapitole je regulačná funkcia štátu. Regulácia je nevyhnutná pri napĺňaní spoločenských cieľov a zabezpečovaní verejného záujmu. Pod reguláciou sa zvyčajne chápe akýkoľvek riadený zásah štátu, úprava a usmernenie. V širšom kontexte ide nielen o zasahovanie štátu prostredníctvom platných právnych predpisov, ale aj prostredníctvom nelegislatívnych dokumentov.

Obrázok 7: Regulačný cyklus

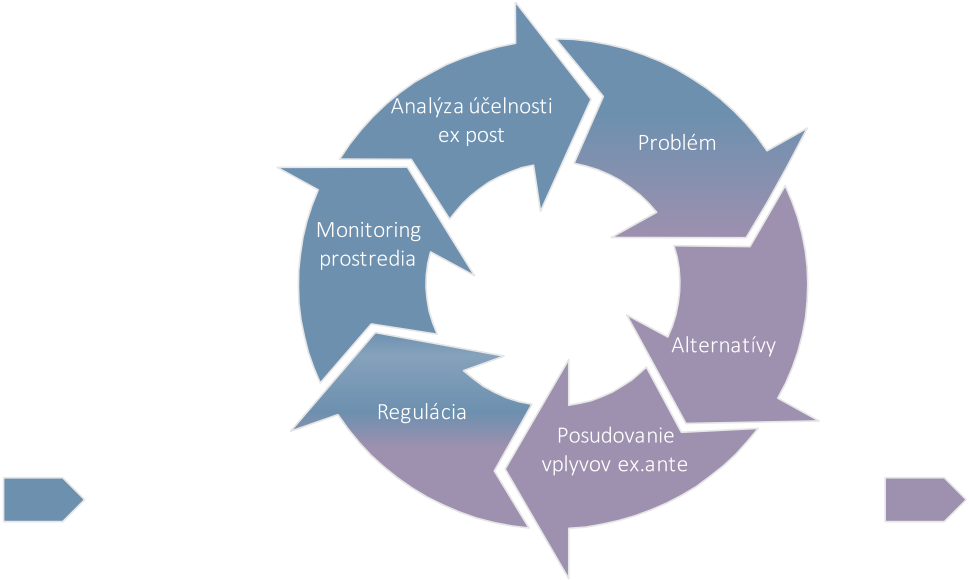

Posudzovanie vplyvov ex ante (v zahraničí často označované ako „Regulatory Impact Assessment“) je jedným z procesov v rámci životného cyklu regulácie. Začína sa definovaním problému a konzultáciami s dotknutými subjektmi. V rámci konzultácií sa diskutujú rôzne alternatívy riešenia daného problému (najmä zlyhania trhu). Často sa opomína, že daný problém nemusí byť riešený len novou reguláciou. Inou alternatívou je napríklad podpora samoregulácie alebo zlepšenie spôsobov dodržiavania a vymáhania existujúcej regulácie. Súčasťou konzultačného procesu je posúdenie vplyvov navrhovanej regulácie pred jej zavedením do praxe (ex ante), ak zavedenie novej regulácie bolo zvolené ako najlepšia alternatíva. Zároveň sa definujú ciele regulácie a spôsob vyhodnotenia jej účelnosti a efektívnosti, ktoré sa analyzujú po zavedení regulácie do praxe, v ktorej je možné získavať reálne informácie o jej vplyve na regulačné prostredie a na riešenie zlyhaní trhu. Ak regulácia v praxi na základe objektívnych dôkazov neplní svoj účel, alebo jej dodržiavanie nie je efektívne a spôsobuje vedľajšie neplánované vplyvy, je dôležité ju dôsledne prehodnotiť a následne upraviť alebo úplne odstrániť z regulačného rámca.

Agenda lepšej regulácie sa venuje dizajnu a spätnému a transparentému hodnoteniu sektorových politík a legislatívy za pomoci dát a dôkazov, ale i názorov občanov a ďalších dotknutých subjektov. Táto agenda pokrýva všetky sektorové oblasti a jej cieľom je, aby intervencia v podobe regulácie nešla za najnutnejší rámec, ale dosiahla svoj cieľ a priniesla očakávané prínosy za minimálnu cenu. Regulačný svet, ktorý zasahuje do veľa oblastí života a ekonomického diania, sa však stal príliš zložitým:

- na Slovensku máme vyše 700 zákonov a 2 300 podzákonných predpisov,
- na úrovni EÚ je vyše 19 000 regulačných aktov, len v roku 2017 pribudlo vyše 700 regulačných aktov
- v jednotlivých regulačných aktoch týkajúcich sa Slovenska je skrytých vyše 100.000 konkrétnych regulácií.

5.1.2 Vízia

Nové technológie, akými sú sémantická analýza legislatívy, umelá inteligencia a dátová veda, umožnia systematicky vylepšovať regulačný rámec obsahujúci obrovský počet regulácií. Okrem inovácie regulačných postupov je preto v posudzovanie vybraných vplyvov potrebné podporiť aj komplexným IT

riešením, ktoré bude schopné spracovať veľké množstvo relevantných údajov tak, aby v reálnom čase umožnilo sledovať vplyvy regulácií a hlavným aktérom v rozhodovacom procese prinieslo dostatočné nástroje pre posúdenie vypočítaných vplyvov a vzájomnú spoluprácu na zlepšovaní regulovaného prostredia.

Takýto prístup predstavuje významný posun smerom k štátu, ktorý funguje na základe využívania znalostí a dôkazov pri rozhodovaní o dôležitých otázkach, akými regulácie určite sú. Výsledkom aplikácie takéhoto riešenia bude lepšie a prehľadnejšie regulačné prostredie, ktoré umožní podnikateľom inovovať, fungovať flexibilnejšie a jednoducho si plniť svoje povinnosti, a občanom prinesie vyššiu kvalitu života.

Za základné požiadavky na nový spôsob posudzovania vplyvov považujeme:

- **Hladký priebeh procesov posudzovania vplyvov** - bude jednoduché sledovať a manažovať stav prípravy regulácie, zapojiť kľúčové strany do procesu konzultácií, prieskumov a konaní, vyhodnocovať a zlepšovať celý proces.
- **Interaktívna vizualizácia analýzy vybraných vplyvov** – pre prehľadosť sa vytvorí jednoduchá navigácia reguláciami, ich cieľmi, prepojenými s merateľnými KPI, dotknutými subjektmi a pravidlami. Vypočítané vplyvy pre jednotlivé regulácie budú interaktívne a zrozumiteľne znázornené, aby bolo jasné, na základe akých predpokladov boli vyčíslené a čo ich v reálnom prostredí bude ovplyvňovať. Bude možné simulovať rôzne scenáre vypočítaných vplyvov na základe zmeny vstupných parametrov, ako napríklad počtu dotknutých subjektov alebo zmeny prognózy vývoja rastu miezd.
- **Transparentné analytické modely** – odborná verejnosť a zamestnanci verejnej správy budú mať možnosť pristúpiť k analytickým a dátovým modelom, učiť sa z nich a kontrolovať ich.
- **On-line vyhodnotenie modelovania vplyvov** - analytické modely budú automaticky prepočítané na základe dostupnosti nových dát z monitoringu regulovaného prostredia. Bude možné porovnať predikcie dát v modeloch s realitou a objektívne hodnotiť kvalitu doložiek vybraných vplyvov k predkladaným materiálom.
- **Overené dátové zdroje** - všetky relevantné dátové zdroje verejnej správy a externé zdroje tretích strán budú dostupné pre modelovanie a overené z pohľadu authenticity, kvality a integrity dát.
- **Platforma pre širšiu spoluprácu** - každý dotknutý subjekt, regulátor, odborná a laická verejnosť sa budú môcť zapojiť podľa vopred nastavených pravidiel.

Ich realizáciou je možné dosiahnuť:

- Aby bola príprava regulácii vykonávaná na základe objektívnych znalostí.
- Aby boli vplyvy regulácií zanalyzované exaktne.
- Aby bol výsledný vplyv regulácií prospešný pre spoločnosť.
- Aby bol zabezpečený transparentný a participatívny proces tvorby regulácií.
- Aby bolo výsledné regulované prostredie prehľadné a jednoduché.

5.1.3 Transformácia

Ak máte záujem modernizovať posudzovanie vplyvov vo vašej inštitúcií, realizujte nasledujúce opatrenia:

- **Rozhodovací proces pri návrhu regulácii a ich zmene nastavte ako otvorený, transparentný a participatívny -** dôraz je kladený na posilnenie demokratizácie procesu a jeho priblíženie občanom, pričom zvýšenie počtu konzultácií v ranom štádiu tvorby regulácie a interaktívna tvorba regulácie, ktorá sa zameriava na zlepšenie riadenia využívaním IT nástrojov na zhromažďovanie a analyzovanie reakcií, sú najdôležitejším krokom,
- **Vytvorte podmienky, aby dotknuté subjekty mohli vstupovať do rozhodovania formou konzultácie a participácie -** konzultácie dokážu rozšíriť rozsah variant riešenia verejnej politiky a regulácie a vniesť do problematiky nové myšlienky, pričom ide o cenný a nenákladný zdroj údajov, dát a informácií, potrebných na tvorbu verejnej politiky, vrátane regulácií. Je ich možné aplikovať na overenie predpokladov a analýz vybraných vplyvov predkladateľa návrhu regulácie. Základom konzultačného procesu je vytipovanie dotknutých subjektov, t. j. zainteresovaných strán na ktoré bude mať navrhovaná právna úprava priamy či nepriamy vplyv. Tento spôsob konzultácie by sa však nemal zamieňať s (medzirezortným) pripomienkovým konaním, ktoré prebieha medzi ústrednými orgánmi štátnej správy a ktoré je prebieha v príliš neskorom štádiu celého procesu, keď je už hotové paragrafové znenie jediného variantu – regulácie. Dôležité je vytvoriť k dispozícii používateľsky jednoduché nástroje pre zapojenie sa do diskusie. Častým problémom hľadania riešení problémov pri online diskusie je takzvaný „trolling“ a nekonštruktívne hádanie. V súčasnosti sa už vyvíjajú technológie, ktoré na báze výsledkov behaviorálnych vied, umožňujú konštruktívnu diskusiu pri hľadaní problémov.
- **Zaveďte povinné rozhodovanie na základe dôkazov pri ex-ante posudzovaní (tzv. evidence based policy making) a zlepšite presnosť analytických dôkazov a údajov** - rozhodovanie na základe dôkazov si vyžaduje venovať väčšiu pozornosť spôsobu, akým sa získavajú údaje, ako sú presné a dôveryhodné, ako sa z nich generujú dôkazy, ako sa tieto dôkazy pretavujú do verejnej politiky a prípravy regulácií a tiež ako sa využívajú pri rozhodovaní.
- **Výsledky analytických modelov transparentne zverejnite**– ide o kontrolu vedeckej a analytickej kvality štúdií, správ a analýz vybraných vplyvov, ktoré vytvorili štátni zamestnanci alebo externisti a pomáhať kľúčovým ministerstvám zlepšovať spôsob využívania vedeckých zistení a analytických údajov v rámci prípravy regulácie.
- **Minimalizujte regulačné náklady a negatívne vplyvy na podnikateľský sektor, občanov či verejnú správu –** riešenie musí neustále upozorňovať na to, aké nové regulačné náklady vzniknú so zavedením regulácie, a musí byť schopné podporiť vizualizáciu negatívnych vplyvov a podporovať procesy a nástroje pre hľadanie opatrení, ako tieto negatívne vplyvy eliminovať alebo apoň minimalizovať,
- **Zaveďte proces skríningu proporcionality regulačných zásahov** - lepšia regulácia vyžaduje, aby štát intervenoval v podobe regulácií len vtedy, ak si to komplexnosť problémov skutočne vyžaduje. Preto je potrebné zaviesť proces skríningu miery vplyvu, ktorý sa bude vykonávať na základe vopred stanovených kritérií, na základe ktorých sa určí hĺbka analýzy, ktorá má byť proporčná k očakávanému vplyvu. Tieto kritériá sa musia pravidelne prehodnocovať na základe skúseností.
- **Zaveďte do praxe proces ex post - hodnotenia účelnosti a účinnosti -** ex post hodnotenie má vyhodnotiť či zamýšľané ciele a účinky, náklady a prínosy regulácie sa skutočne naplnili v praxi a identifikovať nezamýšľané účinky a vplyvy, ktoré počas implementácie regulácie z nej vyplynuli. Okrem sledovania účelnosti a účinnosti ex post hodnotenie slúži aj základnému pilieru vymožiteľnosti práva – zúčtovateľnosti vlády. Začnite z už platnými predpismi a postupne eliminujte všetky predpisy, ktorých vplyv je negatívny.

5.1.4 Požiadavky na dáta a analytické nástroje

Budovanie údajovej základne pre podporu posudzovania vplyvov (ex ante) a hodnotenia účelnosti a efektívnosti (ex post) regulácií

Základom pre vylepšenie posudzovania vplyvov je vytvorenie bázy relevantných dát. Údajová základňa pre správne posúdenie vplyvov navrhovaných regulácií by mala byť vytvorená kontinuálne a postupne. Je vhodné začať s využitím už existujúcich informačných zdrojov, ako sú štatistické dáta, kalkulačka nákladov regulácie a podobne. Údajovú základňu je potom potrebné dopĺňať aj o nové údaje, ktoré sú špecificky potrebné pre proces posudzovania vplyvov, respektíve také, ktoré sa počas posudzovania vplyvov vytvárajú.

Ako prioritné vnímame nasledujúce skupiny údajov:

- administratívne zdroje verejnej správy a oficiálne štatistické údaje,
- údaje z monitoringu regulovaného prostredia, ako sú údaje z API, IoT a M2M.

Administratívne zdroje a štatistické údaje

Tabuľka 5: Prioritné skupiny údajov pre posudzovanie vplyvov z administratívnych zdrojov a oficiálne štatistické údaje

Skupina údajov	Potencionálne zdroje
Katalóg metadát s číselníkmi a ontologický model	■ Centrálny model údajov verejnej správy v rámci Metainformačného systému
Referenčné údaje o subjektoch (podnikateľoch a občanoch)	■ Registra právnických osôb (RPO) ■ Registra fyzických osôb (RFO)
Finančné vzťahy subjektu a štátneho rozpočtu	■ Rozpočtový informačný systém ■ Databázy Finančnej správy, ■ Databázy Sociálnej poisťovne
Sociálny status subjektu	■ Databázy ÚPSVaR o nezamestnanosti ■ Systém sociálnych dávok ■ Sociálne prípady
Vzdelávanie	■ Rezortný informačný system (RIS)
Štatistické údaje	■ Databázy Štatistického úradu

Údaje z monitoringu regulovaného prostredia

Postupne je potrebné nasadiť zber údajov pre monitoring regulovaného prostredia. Ide o údaje, ktorými disponujú samotní podnikatelia vo svojich informačných systémoch a senzorových sieťach. Odporúčame vybudovať aplikačné rozhrania („API“) na viaceré kľúčové informačné systémy podnikateľov - ako účtovné a skladové systémy, štatistiky zahraničného obchodu, sledovanie investícií a dostupný internet vecí. Dôležitým rozhodnutím je určiť, ktoré údaje sa budú získavať na základe

regulácie, ktoré bude inštitúcia vytvárať vo vlastnej réžie a ktoré bude nakupovať od špecializovaných spoločností. Ďalšou zaujímavou skupinou údajov sú údaje zo sietí internetu vecí z takzvanej machine-to-machine komuniácie (M2M) v energetike, konkrétne v Smart Grid, Smart Metering a Smart Home. Zlepší a spríjemní sa tiež proces štatistického zisťovania vnímania adminstratívnej a regulačnej záťaže u podnikateľov. Namiesto vytvárania nových formulárov v rámci Programu štátnych štatistických zisťovaní bude snaha nachádzať riešenia pre automatizovaný import dát, ktoré si podnikatelia evidujú pri svojej podnikateľskej činnosti.

Tabuľka 6: Príklady údajov z monitoringu regulovaného prostredia

Skupina údajov	Potencionálne zdroje
Údaje z monitoringu trhu	■ z dát z telekomunikačných sietí od telekomunikačných operátorov ■ z marketingových dát a dát zo sociálnych sietí (napríklad od spoločnosti Google a Facebook) ■ alebo z finančných dát (nákup dát od bánk)
Geografické údaje	■ geografické údaje o objektoch pevne spojených so zemou ■ satelitné údaje

Nástroje pre komplexný monitoring regulovaného prostredia

Ak chcete zaviesť automatizované posudzovanie vplyvov a komplexný monitoring regulovaného prostredia, potrebujete:

- **Podporu zberu veľkých dát v takmer reálnom čase:** a ich vyhodnocovanie prostredníctvom analytickej platformy, ktorá umožní čistenie, transformáciu a analyzovanie veľkých dát z rôznorodých zdrojov (Analytické nástroje ako napríklad R, Matlab, STATA potrebujú byť napojené na takúto platformu a neumožňujú spracovávať neupravené veľké dáta v takmer-reálnom čase).
- **Vyhľadávanie dátových zdrojov:** Riešenie by malo podporovať napríklad dáta zo senzorových sietí (napríklad nasadených pre účely získania dát pre posudzovanie vplyvov na životné prostredie) alebo vyhľadávanie dát na sociálnych sieťach (pre účely získavania dát pre posudzovanie sociálnych vplyvov a sledovanie trendov). Rozpočet počíta so získavaním takýchto dát, ako je uvedené v module Údajová základňa pre podporu ex ante vyššie.
- **Nástroje pre monitoring regulácie:** Nástroje budú sledovať a vyhodnocovať KPI a indikátory nastavené v Modeloch monitorovania a pri výrazných zmenách nastavených v preddefinovaných udalostiach (takzvaných eventoch) budú notifikovať určených zamestnancov dozoru a dohľadu.
- **Dátová analýza v takmer reálnom čase:** oproti využitiu klasických analytických nástrojov pôjde o online analýzy v takmer reálnom čase, ktoré si vyžadujú inú a robustnejšiu architektúru ako štandardné ekonometrické modelovanie. V tomto prípade platia aj iné pravidlá pre ukladanie dát, pretože v prípade veľkých dát často nie je finančne udržateľné ani zmysluplné ukladať ich v surovom stave dlhodobo. Tieto dáta spravidla len „pretečú“ nástrojmi na online analýzy a uložia sa v agregovanejšej forme alebo len spracované znalosti z nich.

5.1.5 Najlepšia prax

Platforma vTaiwan pre konštruktívnu participáciu pri návrhu politík a regulácií na Taiwane[11]

Na začiatku marca 2016 skupina štátnych úradníkov a aktivistov v Taiwane začala používať online diskusnú platformu vTaiwan (www.vtaiwan.tw), v rámci ktorej začali navrhovať riešenia na správu vecí verejných v krajine. Táto platforma umožňuje taiwanským občanom, občianskym organizáciám, odborníkom a voleným zástupcom diskutovať o navrhovaných zákonoch. Jej cieľom je tak pomôcť tvorcom politík prijímať rozhodnutia, ktoré získali legitimitu prostredníctvom konzultácií so širokou verejnosťou.

Platforma vTaiwan funguje na báze hodgepodge open-source nástrojov na získavanie návrhov, zdieľanie informácií a manažovanie ankiet. Jednou z kľúčových sekcií platformy je „Pol.is"- V rámci Pol.is je preložená určitá téma na diskusiu a ktokoľvek, kto si vytvoril účet môže uverejňovať komentáre k danej téme a môže tiež hlasovať za alebo proti návrhom iných používateľov. Nejde tu však o štandardné online fórum, keďže dva aspekty robia Pol.is špeciálnym: prvým aspektom je, že ľudia môžu navrhnúť svoje nápady a napísať komentáre, ale na komentáre nemôže predkladateľ návrhu odpovedať. Fakt, že si používatelia nemôžu navzájom odpovedať, drasticky znižuje motiváciu trollov k trollovaniu a iným škodlivým aktivitám. Druhým dôležitým aspektom a zároveň pridanou hodnotou je, že platforma využíva systém hlasovania za a proti (tzv. upvotes a downvotes) na vytvorenie akejsi mapy všetkých účastníkov debaty, ktorí hlasujú podobne. Aj keď môžu existovať stovky alebo tisíce samostatných komentárov, na tejto hlasovacej mape sa rýchlo objavia „podobne zmýšľajúce skupiny", ktoré ukazujú, kde sú rozdiely a kde existuje konsenzus.

Tento systém sa ukázal byť veľmi užitočným pri hľadaní konsenzu pri komplexných či kontroverzných problémoch (napríklad online predaj alkoholu) a metódy platformy sa teraz používajú aj na rozsiahlejšej konzultačnej platforme niektorých taiwanských samospráv s názvom „Pripoj sa". vTaiwan sa pýši tým, že od augusta 2018 sa použil v 26 prípadoch, pričom 80 percent viedlo k rozhodujúcim krokom vlády.

vTaiwan je jedným z desiatok participatívnych projektov riadenia na celom svete. Väčšina z nich však čelí rovnakému problému: nezaväzujú vlády k ich rešpektovaniu a používaniu, čo znamená, že súčasne je pre tieto projekty ťažšie si získať dôveru od občanov. vTaiwan sa doteraz napríklad použil na verejnú debatu iba o niekoľkých desiatkach zákonov, pričom vláda nemusí brať ohľad na výsledky týchto diskusií (aj keď sa môže stať, že ešte v tomto roku bude prijatý nový zákon, ktorý túto skutočnosť zmení). Napriek tomu je taiwanský experiment významným počinom, ktorý sa vďaka svojmu inštitucionálnemu rozmeru a aspektom teší čoraz väčšej popularite a pozornosti doma aj v zahraničí.

5.1.6 Obmedzenia a problémy

Vysoká administratívna náročnosť postupu

Posudzovanie vplyvu a zabezpečenie všetkých potrebných údajov môže byť veľmi náročné na odbornú kapacitu (najmä v úvode, kým nie sú k dispozícii automatické postupy a skúsenosť). Správne využitie modelu si často vyžaduje odbornú kritiku a nezávislý expertný pohľad. Niekedy môže takto náročný

[11] https://www.technologyreview.com/s/611816/the-simple-but-ingenious-system-taiwan-uses-to-crowdsource-its-laws/

postup negatívne vyvážiť pozitívny vplyv regulácie alebo zastaviť celý postup zmeny. Pri zavádzaní do praxe je potrebné myslieť na správny pomer medzi administratívnou náročnosťou a odbornosťou výstupu.

Chýbajúce kvalitné zdroje údajov

Bez kvalitných údajov je veľmi ťažké generovať kvalitné predpovede. Súčasná kvalita údajov vo verejnej správe je veľmi nízka a je potrebné urýchlene realizovať opatrenia na jej zvýšenie. Dôležité rozhodnutie, ktoré inštitúcia musí spraviť je: či bude údaje zabezpečovať vlastnými silami, alebo si údaje zadováži od súkromného sektora alebo si od súkromného sektora zadováži výstupy modelu. Ide o strategické rozhodnutie. Odporúčame dočasne riešiť problém nákupom údajov, ale postupne začať budovať kapacity pre vlastnú údajovú základňu (údaje sa stanú strategickou surovinou štátu).

Modely budú zdôrazňovať perverzné dôsledky nastavenia

Každý model zachytáva len časť komplexnej reality. Ak sa model bude brať príliš vážne a nebude ďalej skúmaný a vylepšovaný, môže prínosy a náklady, na ktoré je nastavený príliš zvýrazňovať, čo povedie k neoptimálnym rozhodnutiam. Napríklad ak si pri posudzovaní investícií do IT berie ako základ ušetrený čas používateľov, automaticky sa blokujú projekty, ktoré síce neušetria čas, ale dokážu generovať iný typ hodnoty. Odporúčame preto neustále kriticky posudzovať moduly a metodiky posudzovania vplyvov a pravidelne ich aktualizovať.

Modely budú preparamterizované

Samotný model môže predikovať budúcnosť, ktorá nenastane, najmä ak obsahuje príliš veľa parametrov, ktoré sa prispôsobili minulému vývoju a interne tak model nahradzuje koreláciu kauzalitou.

5.2 Lepší dozor a dohľad nad regulovaním prostredím

V nasledujúcom návode preskúmame, ako využiť údaje pre online monitoring regulovaného prostredia a zabezpečiť tak lepšie plnenie cieľov regulácie (a tým riešenie problémov), vyššiu možnú flexibilitu účastníkov trhu a nižšiu administratívnu záťaž. Využitie dát dáva nádej pre presne mierené regulačné zásahy, ktoré skutočne fungujú.

5.2.1 Úvod

Dozor a dohľad nad regulovaným prostredím patrí k hlavným funkciám štátu. Štát vydáva pravidlá, aby riešil problémy, akými sú zlyhanie trhu a podobne a potrebuje mať k dispozícii presné informácie:

- o tom, ako sa účastníci na trhu chovajú,
- o tom, aké sú spoločenské a ekonomické dôsledky takéhoto chovania,
- o tom, ktoré subjekty porušujú (resp. môžu porušovať predpisy).

Príkladmi takýchto organizácií sú nezávislé regulačné úrady, ako Úrad pre reguláciu elektronických komunikácií a poštových služieb, Protimonopolný úrad, Úrad na ochranu osobných údajov, Národná banka Slovenska, Dopravný úrad, Úrad pre dohľad nad zdravotnou starostlivosťou a podobne. Regulačnú funkciu však vykonávajú aj priamo ministerstvá alebo ich podriadené organizácie, ako Úrad

verejného zdravotníctva a jednotlivé inšpekcie a inšpektoráty: inšpekcia životného prostredia, školská inšpekcia, inšpekcia práce a podobne. Regulačnú funkciu plní aj samospráva.

Pri posudzovaní vhodnosti regulácie a jej aplikácie je potrebné zvážiť nasledujúce otázky:

- Plní daná regulácia svoj účel? Najmä technologický, ale aj ekonomický vývoj často menia dobre myslené predpisy na brzdu pokroku. Predpisy sa stávajú neaktuálne a často produkujú neoprávnenú administratívnu záťaž alebo vytvárajú uzavretý systém, z ktorého zapojené strany môžu ťažiť rentu.
- Je administratívna záťaž spojená s dokazovaním súladu s reguláciou oprávnená?
- Do akej miery je regulácia účastníkmi trhu rešpektovaná?
- Máme k dispozícii potrebné a kvalitné informácie?

Jednou z odpovedí na položené otázky je takzvaná dynamická regulácia alebo nadčasové právne predpisy („future-proof regulation“). Dynamická regulácia nedefinuje presný postup, ako dosiahnuť súlad, ale definuje ciele, ktoré by mali byť v regulovanej oblasti dosiahnuté. Koncept dynamickej regulácie umožňuje dotknutým subjektom experimentovať a inovovať postupy tak, aby dosiahli očakávaný cieľ regulácie. Dynamická regulácia tak nepredpisuje presný postup ako ju dodržať, a tým necháva podnikateľskému prostrediu väčšiu voľnosť. Je obzvlášť vhodná pre nové odvetvia ako digitálna a platformová ekonomika, ktoré sa veľmi rýchlo vyvíjajú. Navrhovaný koncept sa najskôr odskúša ako pilot na objektívne merateľný cieľ v špecifikovanej oblasti. Pre testovanie nového typu regulácie sa využije koncept takzvaného „sandboxu“. V rámci neho štát navrhne kontrolovaný experiment, kde môžu firmy fungovať novým spôsobom legálne, kým zamestnanci štátnej správy neustále vyhodnocujú výsledky, konzultujú so spotrebiteľmi a účastníkmi trhu a získavajú tak znalosti pre širšie iniciatívy.

5.2.2 Vízia

Regulačný úrad konzultuje predpisy, vydáva metodické usmernenia a návody, ako interpretovať legislatívu, pomáha s dodržiavaním zhody a kontroluje zhodu pre dotknuté subjekty. V prípade nesúladu udeľuje sankcie. Tieto funkcie dokážu byť transformované pomocou nástrojov umelej inteligencie. Moderný regulačný úrad tak môže fungovať na základe presných znalostí, znamená to:

- že máme k dispozícii model, ktorý nám umožňuje v online čase chápať, čo sa v regulovanej oblasti deje (na úrovni interakcií jednotlivých aktérov regulovanej oblasti),
- že dokážeme predpovedať budúci vývoj a budúce udalosti (čo znamená, že omnoho lepšie chápeme riziko a sme schopní ho manažovať),
- že dokážeme porozumieť, ktoré opatrenia zo strany regulačného orgánu fungujú a prečo (napríklad aj vďaka používaniu RCT).

V praxi to znamená:

- že sme schopní znížiť administratívnu záťaž spojenú s preukazovaním súladu s reguláciami. V prípade, že je potrebné získavať informácie o prípadoch a chovaní na trhu je ideálne zbierať dáta automatizovaným spôsobom, cez API na ktoré by sa pripájali informačné systémy subjektov pôsobiacich v regulovanej oblasti. Napríklad takýmto spôsobom je možné jednoducho získavať údaje o preprave cez API od platforiem, ktoré poskytujú služby pre prepájanie vodičov a cestujúcich (ako Uber alebo Bold); od platforiem, ktoré sprostredkovávajú ubytovanie (AirBnB) alebo napríklad od utilitných spoločností. Ak medzi sebou komunikujú informačné systémy, celý proces zberu údajov sa dá zautomatizovať. Ďalším spôsobom, ako znížiť administratívnu záťaž je nastaviť systém na bázu

implicitnej dôvery a nutnosť splnenia podmienok preukazovať len v nevyhnutných prípadoch (napríklad v prípade kontroly alebo podozrenia s nedodržiavania podmienok). Tento spôsob je vhodný, ak informácie nie sú potrebné pre (napríklad, v prípade hygienických predpisov prevádzok sa bude predpokladať splnenie predpisov implicitne a príslušné dôkazy a potvrdenia sú preukázané až v prípade kontroly alebo inej výnimočnej udalosti na žiadosť RÚVZ). Treťou možnosťou na zníženie administratívnej záťaže je využitie konceptu Moje dáta, keď inštitúcia (regulačný orgán) má na základe prístup k iným údajom subjektu. Regulačné orgány umožňujú tiež vznik decentralizovaných databáz na ukladanie záznamov o transakciách na trhu.

- že regulačné opatrenie je naplánované a spustené spôsobom, ktorý zaručí jeho maximálny efekt vo vzťahu k vzniknutej záťaži respektíve regulačným nákladom. Vďaka využitiu dynamickej regulácie je možné dynamicky meniť pravidlá spôsobom, aby bol zásah vykonaný len keď je to nutné a prospešné. Takýto mechanizmus si vyžaduje transparentnosť a vysvetľovanie aktuálnych a plánovaných procedúr. Využitie metód umelej inteligencie umožní reagovať na krízové udalosti skôr, ako problémy prepuknú v plnej miere (čo má význam napríklad pri regulácií finančných trhov a podobne).
- komunikáciu s regulovanými subjektami a verejnosťou je možné zlepšiť a podporiť nasadením nástrojov participácie (pre participatívny návrh pravidiel za účasti dotknutých subjektov a reprezentantov relevantných záujmov) a s nasadením inteligentných asistentov a „chatbotov“ na presné vysvetlenie a návod regulačnej procedúry.
- že na dosiahnutie regulačného cieľa sa nepoužívajú len tvrdé regulačné opatrenia, ako zákazy a príkazy, ale s využitím konceptu behaviorálnych vied aj mäkké opatrenia, ako motivácia a spoločenský tlak.
- že efektívne dokážeme identifikovať subjekty, ktoré porušujú predpisy respektíve v budúcnosti budú náchylné porušovať predpisy. Je tak možné výrazne znížiť mieru podvodov, ako i prípadných problémov v regulovanej oblasti a účelnejšie využiť zdroje na plánovanie kontrol a výkon samotných kontrol. Znamená to, že v ideálnom prípade kontrole podliehajú problematické subjekty a čestné subjekty majú jednoduchší život. V prípade, že sa udeľujú sankcie je dôležité, aby orgán dokázal právne relevantne sankciu podložiť a uspieť v prípadných odvolaniach (tu dokáže tiež výrazne pomôcť riešenie postavené na umelej inteligencii, ktoré dokáže zanalyzovať prípad a podporiť dôkazy) a konaniach pred súdom. Ak sa rozhoduje o výške a type sankcie dokáže algoritmus odporučiť jej ideálnu formu aby dokázala zmeniť chovanie subjektu a mať relevantný dopad.

Dôležitým aspektom práce regulačných a kontrolných úradov je tiež medzinárodná spolupráca a výmena skúseností a najlepšej praxe v rámci nadnárodných organizácií, s nadradenými orgánmi na EÚ úrovni alebo so špičkovými orgánmi zo zahraničia.

5.2.3 Transformácia

Modernizujte regulačný rámec a zaveďte dynamickú reguláciu

Regulačný rámec je najdôležitejší nástroj regulačného orgánu. Ide o súbor pravidiel, ktoré určujú podmienky, ako je možné správať sa v rámci regulovanej oblasti (požiadavky na subjekty, napríklad požiadavka na výšku kapitálovej rezervy pre banky), aké pravidlá sú vyžadované od ponúkaných tovarov a služieb (napríklad požiadavky GDPR pre digitálne služby, bezpečnostné požiadavky a podobne), akým spôsobom je možné tvoriť ceny (pravidlá pre ceny energií, regulované poštové služby a podobne).

Navrhujeme, aby regulačný rámec modernizovali:

- Regulačný rámec zjednodušili (aj za pomoci lingvistických metód a behaviorálnych metód).
- Realizovali ex-post hodnotenie pravidiel z regulačného rámca a vypustili pravidlá a mechanizmy, ktoré neprinášajú dostatočný prínos voči nákladom.
- Štandardizujte spôsob interpretácie regulačného rámca, aby všetky orgány interpretovali pravidlá rovnakým spôsobom (napríklad jednotlivé regionálne úrady respektíve pobočky). Investujte do prípravy kvalitných návodov a príručiek pre zhodu a uvažujte o zavedení inteligentných asistentov pre subjekty pôsobiace v regulovanej oblasti. Zdieľajte najlepšiu prax.
- Upravte pravidlá smerom k dynamickej regulácií. Znamená to väčšiu flexibilitu pri uplatňovaní pravidiel a posun od dodržiavania presného postupu dokazovania súladu k dosahovaniu cieľových hodnôt (ktoré sú relevantné pre cieľovú oblasť).
- Upravte pravidlá smerom k automatickému spracovaniu dát cez otvorené API, namiesto dokladovania informácií a dokladov manuálne. Znamená to, že získame veľké množstvo údajov, pričom nebudú prestavovať prevádzkovú záťaž pre subjekty (nižšie prevádzkové náklady oproti nutnosti vybudovať automatizované spracovanie údajov cez API).
- Zoberte si zodpovednosť za dokazovanie zhody na starosť, výmenou za prístup k dátam od regulovaných subjektoch. Výrazne tým znížite administratívnu záťaž pre subjekty a podporíte rast konkurencieschopnosti.
- V prípade potreby sledovať toky hodnoty (tovary, služby a ich certifikácia), zvážte využitie „tokenovej ekonomiky“ a distribuovaných systémov zhody.
- Anonymizované údaje o regulovanej oblasti a chovaní subjektov zverejňujte pravidelne ako otvorené údaje. Umožní to ďalším nezávislým subjektom vytvárať pohľady na realitu a všímať si miesta, ktoré môžu byť problematické.

Na základe tohto zoznamu je možné systematicky modernizovať konkrétny regulačný rámec.

Vytvorte dátový model regulovaného prostredia

Dôležitým aspektom regulačného orgánu, ktorý funguje na základe lepšieho využívania údajov je jeho schopnosť rozumieť situácií v minulosti, súčasnosti a budúcnosti (vďaka využitiu prediktívnych modelov). Je preto nevyhnutné, aby úrad mal k dispozícii čo najlepší dátový model regulovaného prostredia, ktorý bude obsahovať:

- Informácie o dôležitých ukazovateľoch (KPI), ktoré chceme v rámci regulovanej oblasti dosiahnuť, respektíve neprekročiť (napríklad cieľové parametre ovzdušia v prípade regulácií životného prostredia).
- Vstupné veličiny (údaje o transakciách v rámci regulovanej oblasti a ich parametroch, údaje o subjektoch regulovaného trhu), ktoré je možné ovplyvniť nastaveným regulačným rámcom.
- Ďalšie dodatočné údaje, ktoré môžu byť relevantné v rámci skúmania.

Dátový model by mal obsahovať systém pre trénovanie algoritmov, ktoré by mali byť schopné: analyzovať súčasnú a historickú situáciu regulovanej oblasti, analyzovať chovanie regulovaných subjektov a identifikovať problematické chovanie, predikovať budúci vývoj regulovanej oblasti a počítať riziká definovaných incidentov a problémov, identifikovať kauzálne vzťahy medzi jednotlivými veličinami.

Takýto model bude vznikať dlhé obdobie a je potrebné naplánovať jeho evolučný vznik a postupné zlepšovanie presnosti (dopĺňaním dátových zdrojov, aktualizáciou algoritmov). Model je potrebné dostatočne popísať a vysvetliť a odporúčame jeho zverejnenie vo formáte otvorených údajov. Model je možné jednoducho vytvoriť v rámci Konsolidovanej analytickej vrstvy.

Zaveďte do praxe systematický zber údajov

Aby mohol model predikovať budúci stav regulovanej oblasti potrebuje k dispozícii trénovaciu množinu dát ako i aktuálny tok údajov, s ktorého sa dá vyvodiť realita. Odporúčame pripojiť čo najväčšie množstvo dátových zdrojov:

- Informácie z administratívnych zdrojov (z ostatných evidencií a registrov verejnej správy). Tu je dôležité zabezpečiť najmä kvalitnú evidenciu v kompetencii regulačného úradu a zaviesť vysokú opatrenia pre vysokú kvalitu údajov (ako je automatizované prepojenie s referenčnými registrami a podobne).
- Informácie zo štatistických zisťovaní (integrácia databáz štatistického úradu).
- Informácie z informačných systémov regulovaných subjektov a platforiem. Je dôležité navrhnúť kvalitné API (rozhrania), dostatočné ich popísať a vytvoriť testovaciu verziu API.
- Ďalšie informácie zo zdrojov big data, napríklad informácie zo senzorov, informácie z webu a sociálnych sietí, satelitné snímky, telekomunikačné údaje.

Pri návrhu redizajnu služieb sa riaďte výsledkami behaviorálnej vedy

Každý regulačný úrad komunikuje a interaguje so subjektami, ktorých sa regulácia týka. Táto komunikácia môže byť podporená sériou služieb (služby pre registráciu, pre preukazovanie zhody s reguláciami, služby pre dopĺňanie údajov potrebných údajov, certifikácia a podobne).

Moderný regulačný úrad poskytuje používateľsky prívetivé a kvalitné služby. V dnešnej dobe to znamená dostupné klientska podpora (pozri aj časť 7.5 venovanú zvyšovaniu kvality služieb vďaka využitiu inteligentných asistentov) a digitalizácia všetkých aspektov služby. Pri dizajne služby využitie behaviorálne prístupy:

- Služby doplňte prehľadnými návodmi,
- Využite systém notifikácií podľa architektúry voľby vašich klientov,
- Zjednodušte formuláre,
- Zapojte používateľov do návrhu jednotlivých krokov digitálnej služby,
- Umožnite zadávať spätnú väzbu.

Vytvorte systém pre eskaláciu problémov

Dynamická regulácia má jednu vlastnosť, umožňuje výrazne znížiť regulačné a súvisiace administratívne zaťaženie v prípade, že sa podmienky vyvíjajú priaznivo. Čo však v prípadoch, keď sa situácia vymkne kontrole (vypukne napríklad epidémia salmonely v prípade verejného zdravotníctva)? Regulačný orgán musí mať vypracovaný plán pre riešenie jednotlivých problematických situácií:

- Identifikujte možné problémy a vytvorte model pre výpočet rizika, že takýto problém môže nastať. Začnite s expertne stanoveným rizikom a postupne integrujte do dátového modelu, ktorý bude riziko počítať automaticky.
- Pre problémy vypracujte eskalačné procedúry (zamerané napríklad na preventívne kontroly, vyhlásenie núdzového stavu, vyhlásenie špeciálneho regulačného režimu).
- Eskalačné procedúry zahŕňajú spôsob alokácie zdrojov na riešenie problému a tiež plán informovania dotknutých subjektov (cez notifikačný modul, webové sídlo a podobne).
- Riešenie by tiež malo podporovať učenie sa na základe reálnych krízových udalostí, aby sme dokázali plánovanú reakciu plánovať lepšie a účinnejšie.

Vybavte kontrolórov vhodnými nástrojmi

Úradníci a najmä kontrolóri musia byť vybavení modernými nástrojmi a postupmi, ako kontrolovať dosahovanie cieľov stanovených dynamickou reguláciou. Mali by byť vybavený mobilnou technikou (tabletmi respektíve mobilnými zariadeniami), ktorá im umožní:

- Prístup k úlohám, pokynom (aby bolo možné udalosť čo najefektívnejšie vyriešiť) a k elektronickému spisu.
- Zadávanie zistení na základe štandardizovaného pracovného postupu. Zber dát senzormi a inými spôsobmi (kamerový záznam)
- Prístup k predikčným modelom a k výstupom algoritmov na základe zadaných vstupov, napríklad pri využití takzvanej rozšírenej reality program informuje o objektoch, navigácií a podobne.
- Online analýza situácie na regulovanom trhu.
- Prístup k expertnej nápovede.

Každá pracovná pozícia si vyžaduje špecifickú techniku. Je potrebné zanalyzovať požiadavky na digitálne vybavenie a skúšať zavádzanie postupne.

5.2.4 Požiadavky na dáta a analytické nástroje

Lepší dohľad nad regulovaným prostredím si vyžaduje intenzívny zber a spracovanie údajov. Zber a spracovanie údajov a ich následná interpretácia sa stane jadrom budúceho výkonu verejnej moci. Aj keď každá oblasť má kľúčové údaje viac menej jasné, je vhodné ich dopĺňať ďalšími dátami z externých zdrojov, aby sa mohol algoritmus a dátový model neustále zlepšovať:

- V prvom kroku je potrebné zabezpečiť automatizovaný informačný systém pre základné evidencie v rámci regulovanej oblasti (či už centrálny alebo distribuovaný). Tento systém prepojíme cez platformu dátovej integrácie s ostatnými administratívnymi zdrojmi.
- V druhom kroku sa doplnia toky vstupných a výstupných údajov o transakčné údaje v regulovanej oblasti a vzťahy (grafy) medzi subjektami a ďalšími prvkami systému (pričom sa odporúča navrhnúť a využívať API pre prístup do informačných systémov dotknutých subjektov).
- V treťom kroku sa doplnia dynamické údaje zo senzorov, IoT, satelitov a internetovej komunikácie.

Pre vývoj a prevádzku dátového modelu je vhodné využívať nasledujúce množiny analytických nástrojov (budú dostupné v rámci riešenia KAV):

- tradičné BI nástroje - ktoré podporujú analytické funkcie nad klasickými štruktúrovanými dátovými zdrojmi (faktov), OLAP, podpora dátových kociek – „data cubes“, prieskum dát a reporty: pre skúmanie kauzality medzi vstupmi a výstupmi a výpočet ukazovateľov.
- netradičné BI nástroje, ktoré podporujú grafové analýzy, new SQL a podobne: pre analýzu komplexných (trhových) vzťahov medzi subjektami a parametre sociálnej siete ako i systémové analýzy regulovanej oblasti.
- „machine learning“ – množina nástrojov a knižnice ready to run modelov, ktoré podporujú spracovanie údajov metódami umelej inteligencie – strojového učenia: najdôležitejšia množina nástrojov, ktorá nám umožní spracovanie predikcií budúceho vývoja regulovanej oblasti, ktorá dokáže poukázať na problematické subjekty a odporučiť ideálne nastavanie regulačného rámca.
- štatistické nástroje - ktoré umožňujú tvorbu štatistických dátových modelov, testovanie hypotéz, faktorové analýzy, korelácie, regresie a podobne: pre rigorózne testovanie vhodných regulačných modelov.
- nástroje pre simulácie, ktoré umožňujú simulovať historický aj budúci priebeh modelovaných udalostí nad vybranou množinou historických a aktuálnych údajov. Simulačné scenáre môžu byť založené na metodikách, ako je prognóza trendov, modelovanie založené na agentoch, analýza systémov, „croud-sourcing“ a „red teaming“: pre plánovanie budúceho vývoja.
- vizualizácia dát a publikácia: služby, vizualizácie výsledkov, ktoré umožňujú pre zamestnancov alebo pre verejnosť vidieť výsledky analýz v interaktívnych grafoch vo webovom priestore: pre publikáciu a prezentovanie dátového modelu regulačnej oblasti.
- publikácia otvorených údajov, zdrojové údaje a výsledky vo formáte otvorených dát, dostupné cez OpenAPI, registrácia v centrálnom katalógu otvorených údajov. pre transparentné informovanie verejnosti a tretích strán.

5.2.5 Najlepšia prax

Inteligentné spôsoby monitorovania solárnej energie v Holandsku[12]

Slnečná energia je hlavným zdrojom obnoviteľnej energie. V posledných rokoch sa inštalácia solárnych panelov prudko zvýšila, zatiaľ čo ceny prudko poklesli. Na účinnú implementáciu politiky energetického prechodu vláda potrebuje spoľahlivé odhady výroby pre celkové množstvo vyrobenej slnečnej energie. Vytvorený bol spôsob, ako zo satelitných snímok odhadnúť a predikovať celkovú inštalovanú kapacitu solárnej energie v danom období a na základe toho nastavovať ciele politiky podpory energetickej politiky a zároveň plánovať energetický mix.

[12] https://www.cbs.nl/en-gb/our-services/innovation/project/automatically-detect-solar-panels-with-aerial-photos

5.2.6 Obmedzenia a problémy

Neznáme situácie

Ak nastane situácia, ktorá doteraz nebola zaznamenaná alebo si ju neviem predstaviť, pre mechanizmus dynamickej regulácie to môže znamenať problém. Dátový model nedokáže správne určiť riziko a môže nastať celková destabilizácia regulovanej oblasti. Preto odporúčame sledovať výkon modelu a skúmať realitu aj inými nástrojmi a neustále zapájať kritickú analýzu a nezávislý pohľad (využitie služieb neziskového sektora alebo akademickej obce).

Perverzné dôsledky cieľov a ukazovateľov

Každý model je len určité priblíženie reality a nutne to platí aj pre modelovanie regulovanej oblasti a jej výkonnosti pomocou systému výstupových ukazovateľov. Ak sa pri riešení regulácie príliš fixujeme na dosahovanie konkrétnych cieľov a táto informácia je známa aj dotknutým subjektom (účastníkom trhu), takmer vždy sa správanie zmení spôsobom, aby bol ukazovateľ dosiahnutý, ale k celkovému zlepšeniu nedochádzalo. Napríklad ak je našim ukazovateľom čakacia doba v čakárni pri návšteve ambulantného lekára, dá sa prístup do čakárne obmedziť, aby čakatelia na zdravotnú starostlivosť priamo v čakárni strávili len minimálnu dobu, ale čakali niekde inde. Dosiahne sa zlepšenie ukazovateľa ale nedosiahne sa objektívna kvalita služby. Túto tendenciu treba mať vždy na pamäti a počítať s ňou. Pri hodnotení výsledkov regulovanej oblasti sa pozerať s potrebného nadhľadu.

Kontinuálne vzdelávanie

Využitie dátových modelov a algoritmov pri dozore a dohľade nad regulovanou oblasťou vytvorí tlak na schopnosti a zručnosti zamestnancov. V prvom rade musia vedieť používať nástroje v rámci svojej činnosti, ale i rozumieť dátovej vede a interpretovať výstupy modelov. Zmenu pracovného postupu si vyžiada tiež prechod s procedurálneho prístupu na otvorený dynamický prístup. Okrem postupu je potrebné, aby úradník rozumel širším súvislostiam regulovanej oblasti. Je preto potrebné sa pripraviť na zmenu pracovnej náplne a filozofie pracovných pozícii kontinuálnym programom vzdelávania pre zamestnancov organizácie.

Dostupnosť a kvalita dát

Celý koncept zlepšenia dozoru a dohľadu môže fungovať len za podmienky, ak budú dostupné kvalitné údaje o regulovanej oblasti online. Vyžaduje si to úvodnú investíciu na strane regulačných orgánov, ako i dotknutých účastníkov trhu, dá sa však predpokladať jej vysoká miera návratnosti. Zavedenie manažmentu údajov v rámci organizácie musí byť úvodný krok transformácie.

5.3 Inovácie procesov

Vďaka zdieľaniu údajov a vyžitiu automatizovaných analýz prípadov alebo vďaka využitiu podporných analytických nástrojov je možné dosiahnuť lepšie operatívne rozhodovanie. V nasledujúcej časti sa budeme venovať otázke, akým spôsobom dokážeme zlepšiť prácu bežného úradníka. Umelá inteligencia má výrazný potenciál eliminovať najmä rutinné, často sa opakujúce a formálne úkony. Nasledujúci návod sa venuje otázke, ako zmeniť bežnú agendu úradníka s pomocou aplikácií umelej inteligencie a algoritmov.

5.3.1 Úvod

V súčasnosti je možné vidieť snahu inovovať procesy nad rámec automatizácie:

- doplniť schopnosti úradníkov o nové možnosti vyplývajúce z využitia algoritmov: zvýšenie schopnosti chápať situácií vďaka analýze dát a paralelnému riešeniu viacerých prípadov.
- zmeniť náplň práce úradníkov spôsobom, aby pomáhali vytvárať lepšie a účinnejšie algoritmu (zber dát, korekcia rozhodnutí a podobne): úradníci môžu pomáhať trénovať algoritmy, vysvetľovať dosiahnuté výstupy a starať sa o celkovú prevádzku týchto riešení.

Tabuľka 7: Silné stránky ľudí a algoritmov

Silné stránky ľudí	Silné stránky algoritmov
■ Kreativita ■ Improvizácia ■ Úsudok ■ Obratnosť ■ Sociálne a líderske schopnosti	■ Rýchlosť ■ Presnosť ■ Predpovedanie budúceho stavu ■ Škalovateľnosť

Zavádzanie dátových metód do procesov verejnej správy umožní premyslieť celý koncept fungovania inštitúcie. Biznis proces už nie je ďalej možné vnímať ako predpísanú sekvenciu krokov a procedúr, ale proces sa stáva viac dynamický, agilný a prispôsobiteľný situácií.

5.3.2 Vízia

Úradníci sú vybavení nástrojmi (algoritmami umelej inteligencie), ktoré im pomáhajú efektívne riešiť zadané prípady. Ich činnosť je neustále monitorovaná, aby rozhodnutia boli v súlade zo zákonom, obdobné a vykonané čo najrýchlejšie. V prípade, že od rozhodnutia závisí nejaké udalosti v budúcnosti, úradník získa aktualizovanú predstavu o pravdepodobnosti takýchto udalostí (napríklad pravdepodobnosť úspechu respektíve neúspechu posudzovaného projektu).

Algoritmy, ktoré budú pomáhať úradníkom s najlepšími rozhodnutiami bude potrebné trénovať a budú sa zlepšovať postupne. Pôjde o dynamickú skúsenosť. Tieto nástroje nepovedú len k automatizácií rutinných činností, ale dokážu posunúť schopnosti úradníka na novú úroveň:

- Zamestnanec verejnej správy bude schopný predpovedať, ako dopadne prípad, ktorému sa venuje (aké je riziko podvodu pri colnom konaní, je bezpečné udeliť povolenie na prevoz nebezpečného odpadu, ako je riziko zlého školského prospechu pre dieťa zo sociálne marginalizovaného prostredia, aká je pravdepodobnosť, že podnikateľ využíva čiernu prácu alebo získa návod ako nájsť najlepšiu ponuku pre konkrétneho uchádzača o prácu).
- Nové schopnosti sa získajú pri tvorbe návrhov (riešení verejných problémov): napríklad pri mestskom plánovaní stačí zadať parametre priestoru, a algoritmus navrhne optimálne zóny a ich vývoj v čase. Schopnosti umelej inteligencie preskúmať všetky možnosti sa dajú využiť pri návrhoch dopravných riešení, pri plánovaní kapacity sociálnych služieb, škôl a škôlok, pri návrhu optimálnej siete poskytovateľov zdravotnej starostlivosti, pri návrhu štruktúry opatrení operačných programov. Cieľom je, aby kalkulácie a riešenia prinášal stroj (ktorý má výrazne lepšiu schopnosť premyslieť všetky varianty).

- Zamestnanec verejnej správy bude mať k dispozícii nástroje, ktoré mu zjednodušia život v rôznych úlohách, akými sú: preklady textu do cudzích jazykov, prekladanie hovoreného slova do štruktúrovanej formy, automatická identifikácia možných chýb v žiadostiach, jednoduchšia anonymizácia spisov.
- Zamestnanec verejnej správy získa prehľad dostupných znalostí a skúseností: prehľad podobných prípadov, ktoré sa realizovali v minulosti, zoznamy pravidiel legislatívy, ktoré riešia daný prípad a podobne.

Výsledkom tak budú rýchlejšie, presnejšie a lepšie rozhodnutia pri súčasnom znížení administratívnej náročnosti úkonov a najmä zaujímavejšia práca pre úradníkov, ktorí sa môžu venovať ľudskému aspektu povolania (kreativite, pomoci a poradenstvu ľuďom).

5.3.3 Transformácia

Vytvorte tím pre zber údajov a trénovanie algoritmov

Aby dokázali nástroje postavené na umelej inteligencii pomôcť v úlohách a rozhodovaní, je potrebné zabezpečiť neustály zber údajov pre vylepšovanie a trénovanie algoritmu. Ide o úplne novú rolu (ktorú by mala zastrešiť napríklad rezortná Dátová kancelária), o ktorej sa v tradičnej organizácie neuvažovalo. V princípe potrebujeme, aby niekto nahrával a čistil údaje; aby sa pre jednotlivé dátové sady označovali výsledky pre lepšie porozumenie procesy; aby sa identifikovali dôležité vstupné datasety a „prúdy“ dát a aby dokázali algoritmy sledovať rozhodnutia, ktoré sa vydávajú. Je dôležité chápať nové zdroje dát, ako napríklad satelitné snímky, dáta zo senzorov, biometria, dáta o doprave a podobne. Tím sa musí odborne venovať aj otázke takzvanej dátovej hygieny, aby dokázal chápať skryté predsudky, ktoré sa v dátach nachádzajú a navrhovať „korektívne“ opatrenia. Úvodný tréning algoritmu by mal vychádzať z expertnej skúsenosti najlepších zamestnancov, ako i z „nakódovania“ daných pravidiel verejnej politiky.

Počas používania algoritmu je potrebné myslieť na prevádzku systému: pravidelne kontrolovať kvalitu výstupov, označovať chyby a zlé úsudky, hodnotiť výkonnosť a použiteľnosť.

Vytvorte expertný systém pre posudzovanie výsledkov

Veľmi dôležitou úlohou pre zapojenie umelej inteligencie do verejnej správy je schopnosť chápať a vysvetľovať nasadené nástroje a algoritmy. Napríklad, je dôležité, aby sme dokázali v prípade „chybného rozhodnutia“ algoritmu pochopiť, čo a prečo zlyhalo. Vhodné je nasadiť štandardizovaný model pre pochopenie algoritmu, ako je Local Interpretable Model-Agnostic Explanations (LIME)[13].

Automatizujte, všetko čo sa dá

Mnohé manuálne činnosti je možné efektívne automatizovať aj klasickými IT postupmi. Dôležité je zautomatizovať všetko, kde nie je potrebný priamy zásah človeka. Umožní to: samoobslužné služby pre občanov a podnikateľov a výrazne to skráti čas. Úradník sa tak môže sústrediť na činnosti, kde potrebuje

[13] https://medium.com/intel-student-ambassadors/local-interpretable-model-agnostic-explanations-lime-the-eli5-way-b4fd61363a5e

použiť svoj úsudok. Dôležitá je aj polo-automatizácia, keď algoritmus navrhne najlepšie možné riešenie problému (alebo varianty riešení) a ponechá na úradníkovi, aby vykonal konečné rozhodnutie (napríklad pri posudzovaní oprávnenosti nároku). Predpokladom automatizácie je kvalitný informačný transakčný systém a dátová integrácia s ostatnými informačnými systémami verejnej správy.

Určite mapy rozhodovania pre vaše procesy

Pre každý obslužný proces nakreslite jeho procesnú mapu a určite:

- ktoré kroky je možné automatizovať (pomocou automatizácie spracovania, pomocou získania informácií cez dátovú integráciu, pomocou získania informácii cez službu moje dáta),
- v ktorých bodoch procesu dochádza k rozhodovaniu,
- kategorizujte rozhodovacie body a určite (ktoré rozhodovanie môže byť automatizované podľa jednoduchých pravidiel, kde dokážeme rozhodovanie zlepšiť na základe analýzy dát a strojového učenia),
- určite, v ktorých krokoch je potrebné zapojiť ľudský faktor,
- navrhnite plánovanú cestovnú mapu modernizácie procesov vo vašej organizácií.

Odporúčame kombinovať transformatívne iniciatívy (investície) s experimentovaním a overovaním konceptov.

Zapojte občanov a podnikateľov

Problémy, ktoré rieši verejná správa sa do veľkej miery týkajú občanov a podnikateľov. Mnohí z nich majú dostatočné know-how a energiu na to, aby dobrovoľne pomohli inštitúciám verejnej správy zlepšovať svoje služby, alebo riešiť príslušné problémy:

- vytvorte stratégiu pre zapojenie občianskej spoločnosti a inovatívnej komunity do riešenia problémov, za ktoré vaša inštitúcia zodpovedá. Predpokladom dobrej stratégie je určenie priorít a výber politík, ktoré budú navrhované so zapojením verejnosti,
- nasaďte nástroje pre kolaboráciu verejnosti,
- zorganizujte podujatia, ako hackathony, fokusové skupiny a iné formy občianskej participácie.

5.3.4 Požiadavky na dáta a analytické nástroje

Údaje o regulovanej oblasti a jej fungovaní

Pri inovácií procesov v rámci organizácie verejnej správy je možné klásť obdobné požiadavky na zdroje údajov, ako bolo spomenuté v predchádzajúcom návode (Lepší dozor a dohľad nad regulovaným prostredím). Kľúčové je, aby inštitúcia mala kvalitnú evidenciu, spisovú službu a transakčnú databázu, ktorá umožňuje automatizované spracovanie a online. Pre pochopenie regulovanej oblasti je vhodné následne doplniť aj údaje z ostatných administratívnych zdrojov, štatistické údaje a údaje zo senzorov, ako i satelitné snímky a údaje z neštruktúrovaných zdrojov. Cieľom je vytvoriť verejný a transparentný model fungovania regulovanej oblasti.

Historické údaje z výkonu agendy

Pre učenie algoritmov je veľmi dôležité mať prístup k historickým údajom, na základe ktorých je možné automatizovať rozhodovací proces alebo navrhovať odporúčané formuláre. V prípade spracovania historických údajov, ako sú rozhodnutia v správnom konaní alebo súdne rozhodnutia, je však potrebné brať do úvahy možné skreslenia a zakódované predsudky. V historických údajoch, ako sú štatistiky a transakčné údaje (napríklad vývoj nezamestnanosti) je tiež možné objavovať nové súvislosti a kauzálne závislosti.

5.3.5 Najlepšia prax

Nasadenie umelej inteligencie v súdnictve v Spojených štátoch[14]

V Spojených štátoch amerických momentálne prebieha vážna diskusia[15] medzi právnikmi, expertmi na technológie a aktivistami o správnosti využívania umelej inteligencie v americkom súdnictve. V USA je vo väzení viac ľudí ako v ktorejkoľvek inej krajine na svete – na konci roka 2016 bolo vo väzení takmer 2,2 milióna dospelých a ďalších 4,5 milióna ľudí bolo umiestnených v iných nápravných zariadeniach. Inak povedané, 1 z 38 dospelých Američanov bolo v danom roku pod nejakou formou nápravného dohľadu. Táto alarmujúca skutočnosť prirodzene viedla k obrovskému politickému a spoločenskému tlaku na zníženie počtu väzňov bez toho, aby hrozilo riziko nárastu kriminality, čo priviedlo americké úrady k myšlienke využitia umelej inteligencie v trestnom systéme.

V súčasnosti orgány činné v trestnom konaní v Spojených štátoch používajú prognostické algoritmy systémy na rozpoznávanie podozrivých ľudí. Tieto praktiky si však vyslúžili opakovanú kritiku. Napríklad vedci a obhajcovia občianskych práv už niekoľkokrát preukázali, že systémy na rozpoznávanie tváre môžu veľmi výrazne zlyhať, a to predovšetkým v prípade ľudí s tmavšou pleťou – systém si dokonca zmýlil členov Kongresu s odsúdenými kriminálnikmi.

Najkontroverznejším nástrojom je však algoritmus na hodnotenia rizika kriminálneho správania. Tieto systémy sú navrhnuté tak, aby zhodnotili informácie o profile obžalovaného a na tom základe vyprodukovali „skóre recidívy“, to je číslo, ktoré odhaduje pravdepodobnosť, že obžalovaný znovu spácha trestný čin. Sudca potom toto „skóre“ zohľadňuje a pomáha mu v rozhodovaní o tom, aký prísny trest by mal obžalovaný dostať – čím vyššie skóre recidívy, tým prísnejší trest obžalovanému hrozí. Logika za používaním takýchto algoritmických nástrojov spočíva v tom, že ak sudcovi pomôžu predpovedať potenciál budúceho trestného správania u jednotlivca, sudca sa môže rozhodnúť, či sa obžalovaný hodí na menej prísny, prevýchovný trest alebo prísnejší trest, a to odňatie slobody. Teoreticky to tiež znižuje akúkoľvek zaujatosť ovplyvňujúcu rozhodnutie, pretože sudcovia rozhodujú na základe odporúčaní založených výlučne na dátach.

Hlavným problémom však je, že moderné nástroje posudzovania rizika kriminálneho správania sú často poháňané algoritmami založenými na historických dátach o trestnej činnosti. Algoritmy fungujúce na báze strojového učenia používajú štatistiku na nájdenie vzorcov v dátach – ak používajú historické údaje o trestnej činnosti, vyberú vzory spojené s trestnou činnosťou. Ale tieto vzorce sú štatistické korelácie a

[14] https://obamawhitehouse.archives.gov/the-press-office/2016/06/30/fact-sheet-launching-data-driven-justice-initiative-disrupting-cycle

[15] https://medium.com/legal-design-and-innovation/ai-goes-to-court-the-growing-landscape-of-ai-for-access-to-justice-3f58aca4306f

nepredstavujú príčiny trestnej činnosti. Ak napríklad algoritmus zistí, že jednotlivci s nízkym príjmom v minulosti páchali viac trestných činností, neznamená to, že nízky príjem skutočne spôsobil trestný čin. Presne to však robia nástroje na hodnotenie rizika: premieňajú štatistické korelácie na mechanizmy kauzálneho bodovania.

V súčasnosti tak hrozí, že niektoré skupiny obyvateľstva, ktoré boli v minulosti odsúdené, dostali pokutu alebo prišli do nejakého iného styku s orgánmi činnými v trestnom konaní – čiže najmä nízkopríjmové skupiny a menšiny – budú dostávať vyššie skóre o tom, že sa môžu dopustiť opätovnej trestnej činnosti. Výsledkom je, že existujú relevantné pochybnosti či algoritmus skutočne zvyšuje bezpečnosť alebo len prehlbuje existujúce nerovnosti medzi obyvateľstvom a generuje ešte viac dát pre prehĺbenie tohto skresľovania. Odborná diskusia o správnosti a relevancii používania týchto nástrojoch tak naďalej pokračuje.

5.3.6 Obmedzenia a problémy

Etické využitie AI

Predikcie z algoritmov umelej inteligencie môžu viesť k diskriminácií. Tento problém, často spôsobený historickými predsudkami zakódovanými v dátach je potrebné mať na pamäti a počítať s ním a proaktívne ho manažovať.

Algoritmus môže byť “kŕmený” zlými dátami

Veľkým problémom pre inteligentné algoritmy môže byť snaha o ich manipuláciu, ktorá môže viesť k chybným rozhodnutiam alebo odporúčaniam. Vďaka chybnému rozhodnutiu môže dôjsť k havárií procesu, ale možné sú i malé odchýlky, ktoré ostanú nepovšimnuté dlhý čas (čo môže zneužiť útočník respektíve môžeme očakávať sub-optimálnu výkonnosť napadnutého riešenia). Existuje viacero spôsobov, ako zmanipulovať algoritmus:

- Dôjde ku skresleniu údajov pri vstupe (napríklad použitím filtra),
- Dôjde k systematickému učeniu algoritmu na základe chybných údajov.

Odporúčame preto používať algoritmy, ktoré nepracujú ako čierna skrinka, neustále testovanie a zlepšovanie algoritmov, ako i nezávislý vývoj viacerých riešení, aby sme riziko takýchto chýb eliminovali.

Algoritmus ako "čierna skrinka"

Častým problémom mnohých algoritmov strojového učenia (najmä postavených na technológií "Deep Learning") je, že je principiálne nemožné pochopiť dôvody, na základe ktorých navrhuje algoritmus rozhodnutie. V mnohých aplikáciách vo verejnej správe ale potrebujeme mať transparentne preukázané, prečo je rozhodnutie udelené spôsobom, akým je: napríklad povolenie stavby, rozhodnutie o výške trestu a podobne. Ak algoritmus funguje ako čierna skrinka, môžeme mať problém s legálnosťou takýchto rozhodnutí a odporúčaní.

Odporúčame preto zavádzať algoritmy, ktoré podporujú vysvetľovanie svojho fungovania a sú v tomto pohľade transparentné. Všetky zúčastnené strany by mali pochopiť, ako a prečo sa prijímajú rozhodnutia. Toto je obzvlášť dôležité v súvislosti s rozhodnutiami o pridelení obmedzených zdrojov, napríklad keď výstup z algoritmu pomáha pri výbere obmedzeného počtu žiadateľov o štipendiá, granty

alebo povolenia. V extrémnych prípadoch môže aplikácia AI fungujúcej ako čierna skrinka - jej fungovanie nie je alebo nemôže byť vysvetlené - potenciálne spôsobiť viac škody ako pomoci. Algoritmy môžu robiť chyby a dospieť k zlým záverom, najmä v hraničných situáciách.

5.4 Lepšie riadenie zdrojov a plánovanie činností

Vďaka využitiu predikcií budúcich udalosti je možné lepšie riadiť zdroje a plánovať činnosti pracovníkov, ktorý sú k dispozícii. Ako vhodný príklad využitia dát v tejto oblasti považujeme **prediktívnu políciu**, kde je dátová analýza použitá pri plánovaní pohybov hliadok spôsobom, aby bola minimalizovaná trestná činnosť a priestupky. Táto metóda sa dá použiť aj na obdobné aplikácie, ako napríklad hasičstvo, ochrana prírody alebo realizácia kontrol.

5.4.1 Úvod do problematiky prediktívnej polície

Použitie prediktívnej polície

Keďže trestná činnosť a interakcia s občanmi sa čoraz viac realizuje v online svete, tradičný model odhaľovania trestnej činnosti a ochrany verejnosti už sám osebe nestačí. Tradičný model je tiež relatívne nákladný. Policajné sily sa musia naučiť využívať digitálne technológie, ak majú poskytovať služby vhodné pre 21. storočie. Digitálne technológie majú potenciál zmeniť spôsob, akým polícia funguje, a to priblížením policajtov ku komunitám a miestam realizácie trestnej činnosti. Aby bolo možné skutočne ťažiť s nových technológií, je potrebné do praxe zaviesť holistický prístup, ktorý sa začína základnými procesmi a správaním. Pri využívaní potenciálu digitálnych technológií sa môžu policajné sily učiť od organizácií zo súkromného sektora, ktoré majú podobné vlastnosti a výzvy:

- mobilná pracovná sila,
- potreba spracovať a analyzovať obrovské množstvo údajov, aby sa mohli robiť rozhodnutia, a urýchlene ich v praxi realizovať,
- potreba interakcie s klientami prostredníctvom viacerých kanálov,
- schopnosť reagovať na túžby a potreby klientov pri samoobsluhe.

Prediktívne policajné metódy sa týkajú použitia analytických techník na štatistické predpovede o potenciálnej trestnej činnosti, čo môže zahŕňať predpovedanie udalostí (predpovedanie, kedy a kde sa môžu zločiny vyskytnúť) alebo identifikovanie ľudí (jednotlivcov, ktorí sa pravdepodobne stanú obeťami alebo páchateľmi trestných činov). Účelom prediktívnych policajných metód, založených na technológii veľkých dát na zobrazenie vzorcov kriminálneho správania, je doplniť a zlepšiť tradičné policajné postupy. Zatiaľ čo tradičné policajné metódy sú reaktívne, prediktívne policajné metódy sú proaktívne a majú spoločný cieľ predchádzania trestnej činnosti. Predchádzanie trestnej činnosti sa zvyčajne skladá z troch pilierov:

- Stratégie primárnej prevencie, ktoré sa snažia minimalizovať rizikové faktory spojené s trestným správaním. Účelom týchto programov, často umiestnených v školách a komunitných centrách, je zlepšiť zdravie a pohodu detí a mladých dospelých.
- Stratégie trestného súdnictva pri riešení prípadov recidivistov; rehabilitácia väzňov, ktorej cieľom je zabrániť opätovnému porušovaniu zákona odsúdenými.

- Policajné stratégie zamerané na zníženie pravdepodobnosti výskytu trestnej činnosti v konkrétnej oblasti, dosiahnuté znížením príležitosti na trestný čin a zvýšením rizika zatknutia. Prediktívna analytika je jednou zo stratégií na dosiahnutie tejto formy prevencie. Zhromažďovaním a analýzou údajov z viacerých zdrojov prediktívne metódy identifikujú vzorce a generujú odporúčania o tom, kde k zločinom pravdepodobne dôjde.

Metódy prediktívnej polície

Prediktívne policajné metódy pozostávajú z:

- metód predpovedania trestných činov,
- metód predpovedania páchateľov,
- metód predpovedania totožnosti páchateľov,
- metód predpovedania obetí.

Najbežnejšou formou prediktívnej policajnej metódy je lokalizovaná predpoveď, ktorá berie retrospektívne údaje o trestnej činnosti a používa ich na určenie nasadenia jednotiek. Napríklad, zvážte konkrétnu ulicu, kde dochádza v noci často k vlámaniu. Na základe teórie takmer opakovaného výskytu, ktorá naznačuje, že akonáhle sa trestný čin vyskytne na konkrétnom mieste, je pravdepodobnejšie, že sa v tejto oblasti stane znova - je logické usudzovať, že domy môžu byť aj naďalej predmetom trestného činu, pokiaľ nedôjde k nejakému druhu policajného zásahu. Údaje ukazujú, že páchatelia sa zameriavajú na známe oblasti. Dispečing by v tomto prípade mohol jednoducho nasadiť policajta, ktorý bude hliadkovať v oblasti, aby sa predišlo ďalším prienikom. Fyzická prítomnosť polície môže odradiť jednotlivcov od páchania trestných činov alebo ich môže premiestniť do inej oblasti. V iných prediktívnych systémoch môže polícia predpovedať jednotlivcov alebo skupiny, ktoré budú s najväčšou pravdepodobnosťou zapojené do trestných činov, buď ako obete alebo páchatelia. Osobné prediktívne policajné metódy by mohli zahŕňať analýzu sociálnych sietí alebo regresné modely využívajúce rizikové faktory.

Keď sú jednotlivci identifikovaní ako vysoko rizikoví, polícia by mohla hliadkovať v oblastiach, v ktorých jednotlivci bývajú, alebo hovoriť s identifikovanými jednotlivcami alebo ich rodinnými príslušníkmi. Či už ide o predikciu umiestnenia alebo jednotlivca, v praxi metód prediktívnej polície existujú štyri kľúčové fázy:

Obrázok 8: Fázy prediktívnej polície

V prvej fáze sa zhromažďujú údaje. Tieto údaje sa môžu pohybovať od základných údajov o trestnej činnosti (kedy a kde k zločinom došlo v minulosti) až po zložitejšie údaje o prostredí a podmienkach, ako sú sezónnosť, zloženie susedstva alebo rizikové faktory (napríklad neobývané pozemky, parky, bankomaty). Druhá fáza zahŕňa analýzu údajov, ktorá poskytuje predpovede o budúcom zločine. Pri rozhodovaní o tom, ktorá prediktívna metóda sa má použiť, je potrebné zvážiť druh zločinu a zdroje oddelenia. Treťou fázou prediktívneho cyklu sú policajné zásahy. Policajný zásah zvyčajne zahŕňa distribúciu predpovedí zločinu veliteľom, ktorí ich používajú na rozhodovanie o tom, kam nasadiť príslušníkov polície. Štvrtá etapa, reakcia cieľa, zdôrazňuje, že tento prediktívny policajný cyklus sa časom stáva čoraz zložitejším.

5.4.2 Vízia prediktívnej polície

Všeobecnými cieľmi metód prediktívnej policajnej kontroly sú: zmierňovanie rizika, efektívne prideľovanie zdrojov, znižovanie kriminality a znižovanie chýb alebo zaujatosti ľudí.

So zvýšenou a aktuálnou dostupnosťou spravodajských informácií môžu jurisdikcie strategicky znižovať riziko pre policajtov a civilistov prijímaním informovaných rozhodnutí na základe zozbieraných údajov. Tieto údaje môžu tiež pomôcť jurisdikciám s presným nasadením zdrojov tam, kde sú najviac potrebné. Presnosť a efdektívnosť sú dôležité pri účinnej reakcii na trestné činy a ich znižovanie. Hoci prediktívne policajné modely využívajú mnohé jurisdikcie na celom svete, neexistuje jednotný prístup k implementácii ani hodnoteniu používaných mechanizmov. Prediktívne policajné metódy sa snažia identifikovať tri hlavné oblasti: obete, páchatelia a geo-priestorové faktory prispievajúce k zločinu. Použitie matematických, prediktívnych analýz a iných techník presadzovania práva môže identifikovať tieto hlavné oblasti, ktoré majú zvýšený potenciál pre trestnú činnosť. Schopnosť úspešne predpovedať trestnú činnosť je opodstatnená v rámci kriminologických teórií, ktoré pozostávajú z niekoľkých základných predpokladov:

- Zločinci a obete sa správajú predvídateľne; tieto vzorce správania naznačujú zvýšenú pravdepodobnosť trestnej činnosti.
- Geografické a časové znaky trestnej činnosti ovplyvňujú miesto a čas týchto vzorcov správania.
- V rámci týchto vzorcov správania sa zločinci „racionálne“ rozhodujú, či sa dopustia trestných činov, berúc do úvahy také faktory, ako je oblasť, vhodnosť cieľa a riziko zatknutia.

Ak sa digitálne technológie použijú na policajnú kontrolu, môžu posunúť hranice v štyroch oblastiach podľa nasledujúceho obrázka.

Obrázok 9: Oblasti prediktívnej polície

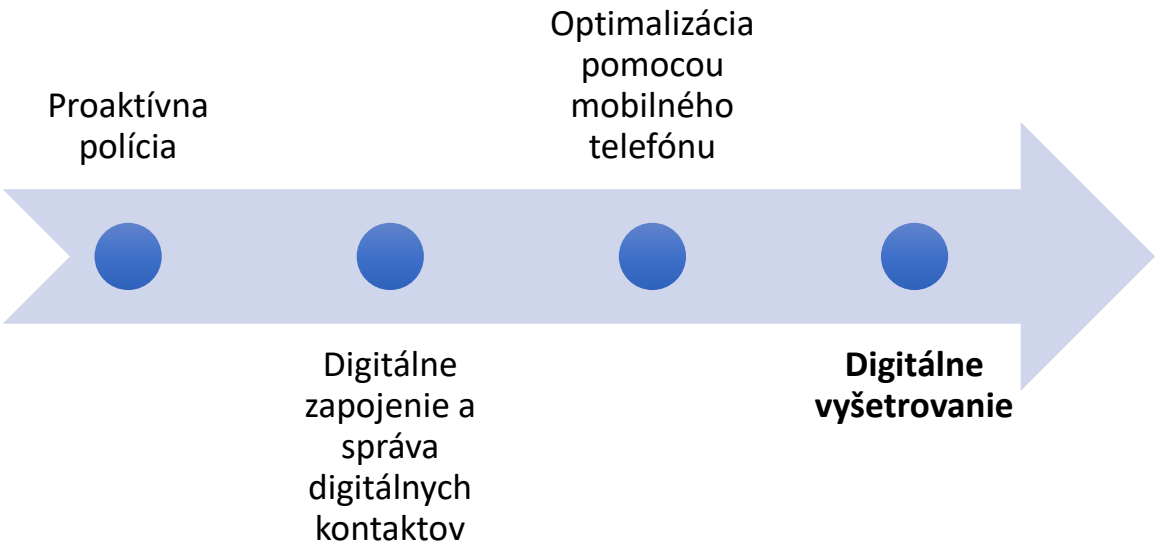

Proaktívna polícia

Odrádzanie od trestnej činnosti prostredníctvom aktívnej činnosti založenej na základe dôkazov a policajnej kontrole.

- Prognózovanie dopytu na usmernenie rozhodnutí - posúdenie priorít zdrojov na riešenie vznikajúcich hrozieb, rizík a potenciálneho poškodenia. Spolu s údajmi o nových trendoch kriminality, analytika umožňuje určiť najprimeranejšie potrebné zdroje a pochopiť, ako prispôsobiť reakciu sily na najvyššie priority.
- Prediktívne analytické nástroje na modelovanie budúcich rizík - Automaticky generovaný informačný systém zdôrazňujúci bezprostredné prepustenie väzňa s bohatou históriou zločinu a percentuálnu pravdepodobnosť recidívy väzňa. Na vhodných miestach na mape je zvýraznená odporúčaná akcia zvýšených hliadok. Policajti nasadení v tejto oblasti dostanú na svojich mobilných zariadeniach odporúčanú hliadkovú trasu, ako aj aktualizovaný prehľad aktuálnych informácií. Potenciálny páchateľ trestnej činnosti je odradený zvýšením viditeľnej prítomnosti polície a nedochádza k predpokladanému incidentu.
- Analytika založená na dôkazoch s cieľom riadiť rozhodnutia o nasadení.

Digitálne zapojenie a správa digitálnych kontaktov

Zníženie dopytu v dispečingoch a kontaktných centrách vďaka viackanálovej komunikácii s verejnosťou, ako je online hlásenie trestných činov a vyšetrovanie prostredníctvom platforiem sociálnych médií pre kontakt s políciou s nízkym rizikom.

- Analýza sociálnych médií s cieľom rýchlo identifikovať prípady trestnej činnosti - Nástroj na monitorovanie sociálnych médií automaticky generuje správu, ktorá zobrazuje informácie o incidentoch trestných činov a informuje najbližších vhodných policajtov prostredníctvom mobilných zariadení.

Optimalizácia pomocou mobilného telefónu

Mobilné zariadenia umožňujúce prijímať a doručovať úlohy a informácie, prehľadávať interné systémy, zaznamenávať vyhlásenia a ukladať podporné dôkazy.

- Vzdialené dynamické zadávanie úloh na nasadenie najbližších najvhodnejších zdrojov - mobilné zariadenie umožňujúce rýchlejšiu podporu, iniciovať digitálny súbor prípadu, formuláre digitálnych výpisov a zdieľať priečinok s príslušným vyšetrovateľom

Digitálne vyšetrovanie

Digitálne spisy prípadov obsahujúce dôkazy, nahrané a upravené viacerými vyšetrovateľmi a zdieľané v reálnom čase s prokuratúrou:

- Elektronické svedecké vyhlásenie a elektronický obraz podozrivého.
- Mobilný digitálny trestný spis so zdieľaním v reálnom čase a digitálnym zaznamenávaním dôkazov.
- Mobilný systém na overenie ID a vyhľadávanie podozrivých osôb vo viacerých systémoch a databázach.
- Občianska účasť na vyšetrovaní prostredníctvom sociálnych médií.
- Digitalizovaná spolupráca s prokuratúrou a súdnym konaním - vzdialená spolupráca s vyšetrovateľmi a prokuratúrou v reálnom čase na príprave súdneho priečinka prostredníctvom mobilnej aplikácie, aby sa zabezpečilo, že súdny spis spĺňa požiadavky a poskytnuté dôkazy sú spoľahlivé.

5.4.3 Transformácia fungovania

Policajné oddelenia využívajú technológie ako sú rádiá, autá, IT, systémy správy záznamov a podobne. Ide predovšetkým o inteligentnejšie využívanie informácií, ktoré boli historicky zamknuté v silách, uchovávané v samostatných databázach a samostatných nástrojoch. Prediktívna analýza je o kolektívnom použití týchto informácií. Vďaka manažmentu rôznych zdrojov údajov dospejeme k novým záverom a predpovediam rýchlejšie a včas. Transformácia v policajných službách je veľmi dlhá cesta, ale je to obrovská príležitosť. Je to príležitosť na zníženie nákladov, zvýšenie efektívnosti, predchádzanie trestnej činnosti, zdieľanie vedomostí, zmenu vzťahu medzi políciou a občanom a zapojenie verejnosti a príležitosť na vybudovanie bezpečnejšej spoločnosti.

Všeobecnými základnými zásadami polície ostávajú zachovanie mieru, ochrana života a majetku a vynútiteľnosť práva a to s dôverou občanov, ktorým slúžia. Dnešní policajní predstavitelia nesú

zodpovednosť za zachovanie týchto základných zásad pri riešení zložitých problémov a hrozieb modernej doby. Väčšina policajných síl čelí trom spoločným výzvam:

- Zvyšujúce sa očakávania občanov. Občania očakávajú, že polícia ponúkne flexibilné spôsoby interakcie vrátane schopnosti zdieľať informácie pomocou nových technológií vrátane aplikácií pre smartfóny, občianskych portálov a sociálnych médií. Občania oceňujú aj efektívny prístup zameraný na zákazníka podobný tomu, ktorý by dostali v banke, a zároveň chcú, aby boli verejné priestory v bezpečí, pričom sa očakáva, že bude zaistená policajná prítomnosť, ktorá im pomôže cítiť sa bezpečne;
- Rastúca sofistikovanosť a meniaca sa povaha trestnej činnosti. Okrem zločinu a protispoločenského správania na miestnej úrovni čelia policajné sily čoraz komplexnejšej hrozbe zo strany sietí organizovaného zločinu, ktoré sú často globálne a vybavené najmodernejšou technológiou. Podľa správy Úradu OSN pre drogy a kriminalitu sa v posledných desiatich rokoch v krajinách OECD zvýšil organizovaný zločin o 127%.
- Vážne rozpočtové obmedzenia. Policajné útvary musia často týmto narastajúcim očakávaniam občanov a hrozbám trestnej činnosti čeliť s výrazne zníženým rozpočtom. Vlády na celom svete znižujú finančné prostriedky poskytované polícii a zároveň požadujú, aby „urobili viac za menej“.

Polícia môže tieto výzvy dneška prekonať a pripraviť sa na výzvy budúcnosti pomocou týchto priorít:

1. Zapojiť občanov cez digitálne kanály
2. Vybaviť policajtov správnou technológiou a školením
3. Optimalizovať organizačné štruktúry a infraštruktúru
4. Zlepšovať služby prostredníctvom dát
5. Zlepšiť spoluprácu

Zapojiť občanov cez digitálne kanály:

Verejnosť je ochotná a schopná pomáhať polícii. S cieľom povzbudiť ich musí polícia zapojiť občanov novými a odlišnými spôsobmi. Zapojenie verejnosti do boja proti zločinu v digitálnom veku si vyžaduje využitie celej škály dostupných digitálnych kanálov na zlepšenie interakcie medzi políciou a občanmi, ako sú špecializované webové stránky polície a občianske portály. Dôležitosť Facebooku a podobných technológií je už jasná, no vynárajú sa aj nové a dynamické aplikácie, ktoré umožňujú občanom nahlasovať zločin, zdieľať a požadovať informácie v reálnom čase a komunikovať s políciou viac prispôsobeným a efektívnejším spôsobom. Napríklad aplikácia s názvom Facewatch, ktorú vytvoril majiteľ vinárne v Londýne, vyvinula šablóny na podávanie správ o dôkazoch, ktoré umožňujú podnikateľskej komunite rýchle hlásenie krádeží v baroch a obchodoch. Samostatne vyvinuli aj aplikáciu „Facewatch ID“, ktorá využíva technológiu smartfónov, aby občania mohli prezerať obrázky hľadaných zločincov a dôverne oznamovať informácie polícii. Práca Facewatch ilustruje potenciál pre dynamickejší a efektívnejší digitálny vzťah medzi políciou a komunitou, ktorej slúžia. **Vytvorte preto komplexnú stratégiu pre zapojenie občanov do práce polície prostredníctvom digitálnych kanálov a aplikujte ju do praxe.** Znamená to výber vhodných kanálov a zabezpečenie zdrojov pre ich monitoring a interakciu s používateľmi (napríklad formou integrácie do dispečingu).

Vybaviť policajtov správnou technológiou a školením:

Je dôležité, aby príslušníci polície boli vybavení správnou technológiou, ktorá im umožňuje byť čo najúčinnejší a robiť informované rozhodnutia v reálnom čase. Schopnosť prezentovať históriu miesta, informácie o jeho obyvateľoch a možnú prítomnosť zbrane sú dôležité informácie, ktoré nielenže pomôžu zlepšiť spôsob, akým dôstojníci zvládajú incident, ale môžu im tiež pomôcť zostať v bezpečí. **Je potrebné navrhnúť požiadavky na digitálne vybavenie policajta, ktoré by malo obsahovať: inteligentné mobilné zariadenie, čítačky dokladov, senzory a podobne.**

Optimalizovať organizačné štruktúry a infraštruktúru:

Je potrebné preskúmať, ako sú policajné útvary štruktúrované a organizované, aby sa zabezpečilo, že majú najlepšie predpoklady na využívanie nových technológií a spoluprácu s ostatnými zložkami, úrady a partnermi. Integrácia a zdieľanie informácií medzi doposiaľ samostatnými systémami súdnictva a orgánmi činnými v trestnom konaní je životne dôležité pre rozvoj účinnejších spôsobov práce a zvýšenie úrovne spolupráce. Napríklad polícia v Toronte realizovala štúdiu s cieľom zlepšiť efektívnosť svojich policajných služieb a lepšie porozumieť počtu policajtov potrebných na splnenie súčasných požiadaviek.

Zlepšovať služby prostredníctvom dát a analýz:

Schopnosť začleniť sociálne faktory a miestnu demografiu môže zohrávať významnú úlohu pri posilňovaní policajnej práce na základe dát a môže pomôcť silám predvídať zločin a efektívnejšie riadiť riziká. Polícia by mala tiež zaviesť postupy na zabezpečenie toho, aby policajti a zamestnanci zadávali spoľahlivé a konzistentné údaje, ktoré je možné rýchlo analyzovať, aby sa umožnilo nahliadnutie v reálnom čase. Existuje riziko, že objem údajov, ktoré sa majú uchovávať a zhromažďovať, bude ohromujúci. Jediný závažný incident môže vyvolať obrovskú vlnu obrazov, správ a iných údajov od občanov, a preto sú účinné analytické filtre nevyhnutné na to, aby polícia mohla identifikovať cenné prvky, ktoré sa musia rýchlo dostať k vyšetrovateľom, aby podporili účinné rozhodnutie v reálnom čase.

Zlepšiť spoluprácu:

Polícia sa musí pýtať, či využili potenciál spolupráce, a to nielen s inými zložkami a organizáciami súdnictva na Slovensku a v zahraničí, ale aj s inovatívnejšími partnerstvami s verejným, súkromným a dobrovoľníckym sektorom a dokonca aj s občanmi. Napríklad boj proti počítačovej kriminalite môže byť posilnený iba väčšou spoluprácou polície s akademickými inštitúciami a technologickým sektorom. Napríklad policajné oddelenie v Londýne úspešne použilo analýzu sociálnych médií s cieľom nájsť účinnejšie spôsoby komunikácie s komunitou a identifikovať trendy a vzorce v rámci správania online.

Aby boli technické, organizačné a kultúrne zmeny úspešné a udržateľné, je nevyhnutné, aby všetci zamestnanci jasne porozumeli cieľom zmien a pochopili výhody, ktoré metódy prediktívnych nástrojov prinesú do ich vlastného pracovného života. Vyššie uvedených šesť priorít môže pomôcť súčasnému stavu polície vyrovnať sa s vyvíjajúcimi sa výzvami súčasnosti i do budúcnosti. Nasledujúcich päť krokov môže pomôcť pri implementácii skutočnej transformácie a poskytovaní komplexnejších policajných služieb, ktoré budú vedieť účinnejšie zapojiť občanov a dosiahnuť tak lepšie výsledky.

- Krok 1: Identifikácia problému
- Krok 2: Stanovenie postupov zhromažďovania údajov
- Krok 3: Identifikácia potenciálnych metód
- Krok 4: Implementácia prediktívnej policajnej technológie
- Krok 5: Hodnotenie a preskúmanie dopadov

Identifikácia problému:

Prvým krokom pri implementácii prediktívnych policajných metód alebo akejkoľvek policajnej stratégie je identifikácia potreby polície alebo komunity. Je v najlepšom záujme polície presadzovať transparentnosť a zapojenie verejnosti do rozhodovania a implementácie stratégie. Jedným zo spôsobov, ako to dosiahnuť, je zriadenie výboru pre civilný dohľad. Výbor môže ponúknuť jedinečný pohľad na komunitné potreby, ktoré polícia nemusí vidieť. Hoci tieto orgány nie sú vytvorené za ideálnych okolností, pomáhajú identifikovať obavy spoločenstva a problémy s policajným správaním, ktoré môžu byť vyriešené zavedením novej prediktívnej policajnej technológie. Začatím dialógu s komunitou je polícia tiež schopná komunikovať o svojich vnútorných problémoch, ako je nedostatok príslušníkov alebo nedostatok podporného personálu. Pri identifikácii konkrétnych problémov sa môžu použiť historické údaje o trestnej činnosti na určenie stúpajúcich trendov konkrétnych druhov trestnej činnosti a oblastí, v ktorých sú najčastejšie. Napríklad policajné útvary môžu analyzovať historické údaje o trestnej činnosti, aby určili, či došlo k vzostupu majetkových trestných činov a kde sa môžu vyskytnúť, a potom môžu osloviť dotknuté komunity, aby sa do riešenia zapojili.

Stanovenie postupov zhromažďovania údajov:

Na podporu polície existujú 4 hlavné typy dátových nástrojov: naratívne nástroje (*Narrative Tools*), sieťová analytika (*Network Analytics*), priestorovočasová analýza (*Spatiotemporal Analytics*) a spoločné prevádzkové postupy (*Common Operational Procedures*). Naratívne nástroje pozostávajú zo záznamov a poznámok o entitách a udalostiach, ktoré umožňujú polícii zamerať sa na špecifiká oblasti, osoby alebo udalosti a aktualizujú sa, keď prichádzajú nové informácie týkajúce sa danej témy. Sieťová analýza ukazuje sociálne vzťahy medzi občanmi a udalosťami. Priestorovočasová analýza sa venuje označovaniu času, miesta a okolností výskytu trestnej činnosti. Tieto tri atribúty pomáhajú vytvárať spoločné operačné postupy. Je to v podstate vyvrcholenie všetkého úsilia o zhromažďovanie údajov, ktoré je potom zobrazené užívateľsky prívetivým spôsobom.

Pred zavedením akýchkoľvek nových policajných postupov, prediktívnych alebo iných, musia byť údaje zo súborov údajov overiteľné a presné, pretože objem a kvalita zozbieraných údajov ovplyvní užitočnosť akéhokoľvek prístupu. Oddelenie musí vyhodnotiť svoje existujúce postupy zhromažďovania údajov a vyriešiť akékoľvek nezrovnalosti predtým, ako sa na ne spoľahne pri prediktívnej analýze. Jednou z prekážok prediktívnych policajných iniciatív je to, že ak sú zozbierané údaje neobjektívne alebo neúplné, prediktívny nástroj nebude presný a môže zhoršiť obavy o spravodlivosť.

Identifikácia potenciálnych metód:

Prediktívne opatrenia poskytnú presnejšie a aktualizovanejšie informácie pre taktické kroky, ale nemusí sa to vždy vyžadovať na zníženie kriminality. Pokročilejšie prediktívne analýzy na predpovedanie konkrétnych trestných činov môžu zahŕňať pokročilé modely identifikácie horúcich miest (*heat maps*), analýzu rizikového terénu, zhlukovacie a klasifikačné modely (*clustering & classification*), takmer opakujúce sa modelovanie (*near-repeat modeling*), metódy priestorovo-časovej analýzy (*spatiotemporal analysis*). Ďalšie informácie k metódam nájdete v kapitole 5.

Implementácia prediktívnej policajnej technológie:

Oddelenie implementujúce prediktívne technológie sa musí v prvom rade zaoberať prípadnými štrukturálnymi zmenami, ako je napríklad zavedenie nových výcvikových protokolov, vyhradených zamestnancov na údržbu technológie, ako aj akékoľvek ďalšie technologické zmeny alebo doplnky. Odborná príprava v oblasti novej technológie by sa mala testovať na spôsobilosť a mala by sa často preverovať. Kultúra departementu musí akceptovať nové politiky a prípadne otvoriť následnej

reorganizácii. Verejnosť by si mala byť vedomá posunu v policajných technikách a mala by byť vypočutá aj jej predbežná obava.

Hodnotenie a preskúmanie dopadov:

Jednou z najväčších prekážok prediktívnej policajnej technológie v súčasnosti je nedostatok presvedčivých dôkazov o jej účinnosti. Výskumní pracovníci by mali byť vyzvaní, aby uskutočnili hodnotenia policajnej praxe, čo je prospešné pre tvorcov politiky, ako aj pre políciu. Kľúčové zistenia z výskumu pomáhajú informovať o budúcich implementáciách a umožňujú prispôsobiť súčasné postupy tak, aby sa dosiahli optimálnejšie výsledky. Metriky, ktoré možno použiť na hodnotenie efektívnosti, môžu zahŕňať znížené hlásenia o trestných činoch, zvýšenú mieru zatknutia, prieskumy spokojnosti občanov, odpovede z dotazníkov obetí, nižšiu celkovú mieru kriminality alebo zvýšenú efektívnosť zdrojov. Dôležité metriky, ktoré sa používajú na meranie rovnosti, sociálneho pokroku a kvality života, sú tiež dôležité a zaslúžia si ich meranie. Neexistuje žiadny konkrétny spôsob, ako vytvoriť dokonalú izolovanú štúdiu o vplyve prediktívnej technológie, avšak pozorovanie trendov a sledovanie zmien v implementácii prediktívnych technológií v dlhodobom časovom horizonte nám môže umožniť porozumieť skutočným výhodám prediktívnej analýzy pre verejnosť. S cieľom pomôcť pri identifikácii potrieb a pripraviť policajné služby do budúcnosti by policajní predstavitelia mali zvážiť tieto otázky:

- Zúčastňujú sa občania proaktívne na dvojstrannom dialógu prostredníctvom rôznych kontaktných kanálov?
- Prináša správna technológia a výcvik policajtom výhody?
- Sú organizačné štruktúry a infraštruktúra optimalizované, aby sa dosiahlo lepšie riadenie zdrojov a majetku?
- Používajú sa sofistikované analytické nástroje na informovanie policajtov a získavanie informácií v reálnom čase?
- Existujú systémy spolupráce s vnútroštátnou a cezhraničnou sieťou polície, so súdnymi orgánmi, verejnými, súkromnými, dobrovoľníckymi organizáciami a občanmi?

5.4.4 Požiadavky na dáta

Požiadavky na dáta

Vo všetkých prípadoch je kvalita analytického výstupu iba taká dobrá ako kvalita analyzovaných údajov. Dnes je bežnejšie ako v minulosti, že policajné útvary disponujú počítačovými systémami na správu záznamov, na rozdiel od papierových záznamov. Odhaduje sa tiež, že množstvo údajov na svete sa bude každých 20 mesiacov zdvojnásobovať. a pri každej udalosti alebo incidente sa zvýši aj možnosť zbierať a ukladať údaje na neskoršiu analýzu. Údaje, ktoré sa používajú na vytváranie predpovedí kriminality, pochádzajú z mnohých zdrojov vrátane vlády, miestnych samospráv a súkromných organizácií. Zostavenie, uloženie a ochrana bezpečnosti týchto údajov si vyžaduje investíciu času a zdrojov. Okrem toho sa musí veľká časť informácií, ktoré má polícia k dispozícii, preložiť do užitočnej formy. Záznamy týkajúce sa finančných transakcií, telefónnych hovorov, trestných činov a používania internetu sa často nezhromažďujú a neuchovávajú na účely štatistickej analýzy, a preto musia byť primerane naformátované.

Aký typ údajov je potrebný na vykonanie prediktívnej analýzy? Základné prediktívne modely sa spoliehajú na údaje o minulých zločinoch, ako napríklad typ incidentu, čas výskytu a deň v týždni, môžu byť začlenené do máp kriminality, ktoré ukazujú, kedy a kde boli spáchané trestné činy. Tieto informácie môžu byť užitočné na vizualizáciu trendov a identifikáciu hotspotov zločinu, ale výstup je historickej povahy. Označuje, kde v minulosti došlo k zločinom, ale nezohľadňuje pohyb trestných činov na iné miesta. Informácie o mieste zločinu, počasí a páchateľoch, ktorí majú tendenciu prispievať k výskytu trestného činu, sú súčasťou základnej analýzy poskytnutej polícii. Tieto základné súbory údajov možno ďalej rozdeliť do troch kategórií: priestorové údaje, časové údaje a údaje zo sociálnych sietí.

Tabuľka 8: Údaje potrebné pre modely prediktívnej polície

Priestorové údaje	Časové údaje	Údaje zo sociálnych sietí
Oblasti s potenciálnymi obeťami: nákupné strediská, hotely, demografické údaje o oblasti, hustota obyvateľstva, nestabilita obyvateľov atď.	Obdobie výplaty, denný čas, víkend vs. všedný deň, sezónne počasie, fázy mesiaca, dopravné vzorce, športové a zábavné udalosti ...	Priateľstvo, pridruženie k organizácii, finančné transakcie, páchateľ / obeť
Únikové cesty: diaľnice, mosty, tunely, verejná doprava, železnice		
Výskyt častých trestných činov: bary, autobusové zastávky, parky, štadióny		

Analytické metódy

Nasleduje niekoľko príkladov metód prediktívnej analýzy používaných na vytvorenie predpovedí:

Data mining alebo tiež "hĺbkova analýza údajov" je metóda, ktorá sa pokúša rozpoznať opakujúce sa vzorce v údajoch a použiť ich na vytváranie predpovedí o budúcnosti. Používa rôzne typy algoritmov na zhromažďovanie údajov rôznymi spôsobmi, ktoré závisia od povahy údajov, na ktoré bol prediktívny model špecifikovaný. V britskom Derbyshire sa skupina orgánov činných v trestnom konaní a obecných úradov Safer Derbyshire Partnership snažila identifikovať hotspoty kriminality mladistvých. Používali špecializovaný softvér na kombináciu viacerých diskrétnych súborov údajov, čo viedlo k vytvoreniu podrobných máp a vizualizáciám kriminálnej činnosti vrátane časových a priestorových hotspotov. Výsledkom bolo získanie prehľadu o optimálnom rozmiestnení policajných zdrojov.

Analýza hotspotov a mapovanie zločinu je stratégia, ktorá predpovedá, kde k zločinu pravdepodobne dôjde syntetizáciou historických údajov o zločine. Základným predpokladom je, že k zločinu pravdepodobne dôjde, ak k nemu došlo v minulosti. Využitím mapovania hot spotov môže okrsek konať tak, že zvýši hliadkové jednotky alebo iné zdroje v oblastiach označených za rizikové pre vysokú kriminalitu. Ukázalo sa, že táto metóda obmedzuje trestnú činnosť a nevedie k presunu trestnej činnosti. Táto analýza sa líši od tradičných policajných postupov tým, že umožňuje špecifickosť mapovania v sieťach (*grid mapping*), ktorá nie je možná len pomocou heuristiky.

Podobne ako pri mapovaní hot spotov, aj **analýza rizika v teréne** (*Risk terrain modelling analysis*) sa opiera o historické údaje o trestnej činnosti, ale analyzuje aj ďalšie faktory, ktoré sú užitočné pri predpovedaní trestných činov. Príklady takýchto faktorov zahŕňajú sociálne, fyzické a behaviorálne faktory, ktoré zvyšujú pravdepodobnosť, že niektoré oblasti budú trestnou činnosťou viac postihnuté. Polícia v Morris County použila tento druh analýzy na boj proti násilným zločinom a vlámaniu. Vo svojom modeli zvážili päť ukazovateľov: minulé vlámania, adresy osôb nedávno zatknutých za majetkové trestné činy, blízkosť hlavných diaľnic, geografická koncentrácia mladých mužov a umiestnenie bytových komplexov a hotelov.

Sociálne mapovanie je prediktívna policajná metóda, ktorá je zameraná na jednotlivca a zahŕňa analýzu sociálnych sietí alebo modely regresie, pri ktorých sa používajú rizikové faktory na identifikáciu tých, ktorí s väčšou pravdepodobnosťou spáchajú trestné činy, alebo tých, ktorým hrozí väčšie riziko, že sa stanú obeťou. Sociálne mapovanie môže aj napríkald pomôcť polícii predstaviť si sociálne kruhy členov gangov a predpovedať tých, ktorí môžu byť potenciálnymi budúcimi členmi.

5.4.5 Najlepšia prax

Rôzne polície v Európe experimentujú s vlastným prístupom k prediktívnemu mapovaniu so širokou škálou produktov, z ktorých všetky sa primárne používajú na predpovedanie umiestnenia trestných činov, ako sú lúpeže, krádeže a vlámania. Existujú dva odlišné modely, *near-repeat modeling* a model časopriestoru (*time-space modeling*). Prvý sa predovšetkým spolieha na policajné údaje (druh trestného činu, miesto a čas), aby predpovedal, kde sa s najväčšou pravdepodobnosťou stane v blízkej budúcnosti zločin, druhý model zahŕňa aj premenné, ako sú počasie, sviatky, udalosti a vzdialenosť od diaľnic a podobne. V Nemecku a Švajčiarsku sa niekoľko policajných útvarov obrátilo na nemecký model PreCobs[16], ktorý vyvinul inštitút für musterbasierte Prognosetechnik (IfmPt). PreCobs používa údaje o kriminalite na predpovedanie toho, kde sa s najväčšou pravdepodobnosťou stane zločin. Bavorsko tiež experimentuje s takzvaným „*far repeat approach*“ na predpovedanie trestnej činnosti vo vidieckych oblastiach. Polícia v nemeckom Dolnom Sasku vyvinula podobný prediktívny policajný nástroj pre domáce vlámania zvaný PreMap. Obdobne funguje aj KLB-operativ, čo je interný prediktívny model polície Hessen, ale namiesto toho, aby sa spoliehal iba na údaje o policajnej trestnej činnosti, sa do analýzy zahrnie aj sociálno-ekonomické údaje, ktoré sa potom zobrazujú v aplikácii pre mobilné telefóny.

V Európe je medzi políciou tiež populárna prediktívna identifikácia, ktorá má predpovedať, kto sa s najväčšou pravdepodobnosťou stane potenciálnym páchateľom alebo potenciálnou obeťou trestného činu. Najbežnejšou praxou tohto typu technológie v Európe je modelovanie rizika, pri ktorom sú jednotlivci identifikovaní a klasifikovaní podľa pravdepodobnosti, že sa zapoja do trestnej činnosti alebo násilného konania. V Spojenom kráľovstve existujú tri odlišné prediktívne identifikačné programy v Londýne, Avone a Somersete a na západe Midlands. V mestách Avon a Somerset je cieľom policajného programu Qlik predpovedať dve veci: pravdepodobnosť, že sa niekto dopustí určitého trestného činu, a predpovedanie pravdepodobnosti, že sa niekto stane agresívnym počas policajné kontroly na ceste. Polícia West Midlands vedie projekt Národného analytického riešenia, ktorý financuje ministerstvo vnútra, v spolupráci s ďalšími 8 policajnými zložkami. Systém nazývaný riešenie National Data Analytics Solution (NDAS) využíva kombináciu umelej inteligencie a štatistiky na hodnotenie rizika, že sa niekto

[16] https://en.wikipedia.org/wiki/Precobs

dopustí alebo stane obeťou trestného činu, ako aj pravdepodobnosť, že sa niekto stane obeťou otroctva. V Amsterdame existujú dva odlišné programy modelovania rizika, top 600 a top 400 (ProKid 12). Top 600 sa zameriava na páchateľov, ktorí boli v posledných 5 rokoch zatknutí za trestný čin najmenej dvakrát pre osoby mladšie ako 21 rokov a trikrát pre osoby staršie ako 21 rokov. Top 400 vychádza z ProKid 12, ktorý vyvinul policajný útvar v Gelderlande-Midden na vyhodnotenie pravdepodobnosti, že sa deti do 12 rokov stanú potenciálnymi zločincami. Po identifikácii je zámerom holisticky zabrániť potenciálnym zločincom a odradiť ich od účasti na budúcej trestnej činnosti

5.4.6 Obmedzenia a nevýhody

Problém 1: **Zvýšené profilovanie -** prediktívne policajné metódy sú nástroje, ktoré pomôžu polícii zamerať svoje obmedzené zdroje na oblasti, ktoré sú najviac potrebné. Minority sa však obávajú, že prediktívna analýza môže spracovať neaktuálne, nesprávne alebo skreslené údaje a tím sa môžu stať terčom policajtov, ktorí sú informovaní neobjektívnými alebo chybnými údajmi. Mnohí zástancovia prediktívnej polície sa však domnievajú, že použitie kvantitatívnych údajov na zúženie oblastí s vysokou kriminalitou môže naopak pomôcť znížiť predpojaté zatýkanie. Ďalšie obavy sa týkajú oblastí, ktoré sú vo výsledku označené za oblasti s vysokou kriminalitou, čím sú stigmatizované, čo vedie k odchodu ľudí z oblasti, menšiemu rozvoju a menším investíciám do komunity.

Problém 2: **Ochrana súkromia a bezpečnosť** - Ďalšie obavy vyjadrené v súvislosti s metódami prediktívneho policajného vyšetrovania vyplývajú z čoraz väčšieho množstva údajov, ktoré majú analytici k dispozícii. Dostupnosť údajov, najmä pri nízkych úrovniach analýzy (napr. údaje na individuálnej úrovni), vyvoláva otázky týkajúce sa ochrany súkromia a bezpečnosti. Kto by mal mať prístup k údajom nízkej úrovne? Ako sú údaje zabezpečené proti hackerom? Dátoví vedci sa zhodujú v tom, že samotné zákony nemôžu kompletne zabrániť zneužívaniu údajov a že už školenia musia vniesť silné etické kódexy týkajúce sa používania a zneužívania údajov.

Problém 3: **Prílišná dôvera v technológiu** - Vždy existuje tendencia veriť, že nová technológia vyrieši staré problémy. Prediktívny policajný softvér môže byť schopný analyzovať údaje, ale ľudia musia stále interpretovať výstup spôsobom, ktorý je uskutočniteľný a zrozumiteľný. Zameranie sa na presnosť informácií namiesto ich užitočnosti by mohlo spôsobiť závažné problémy. Prílišné zameranie na technológiu tiež môže odvrátiť pozornosť od dôležitejších častí procesu, ktoré sa spoliehajú na úsudok. Keď napríklad policajti trávia viac času vo svojich hliadkových autách analýzou predpovedí, trávia menej času interakciami s miestnymi obyvateľmi.

5.5 Zvýšenie kvality služieb

Vďaka využitiu predikcií budúcich udalosti a použitiu inteligentných asistentov.

5.5.1 Úvod

Techniky umelej inteligencie (AI), ako sú rôzne druhy strojovej inteligencie, vrátane porozumenia prirodzeného jazyka, robotiky, neurónových sietí a strojového učenia, sa už mnoho rokov intenzívne používajú na podporu a zvyšovanie kvality rozhodovania a riešenia problémov v rôznych odvetviach. Najvýraznejší trend AI v súkromnom sektore sa v súčasnosti týka využívania chatbotov, ktoré interagujú s používateľmi v konverzačnom formáte a napodobňujú ľudskú konverzáciu.

Chatboty sú inteligentné zariadenia alebo aplikácie, ktoré vnímajú svoje prostredie a sú schopné porozumieť reči a používať hlasovú komunikáciu ako užívateľské rozhranie. Skladajú sa zo špecifického

softvéru založeného na AI, ktorý automatizuje komunikáciu a správu transakcií so zákazníkmi. Medzi najznámejšie aplikácie chatbotov v súkromnom sektore patrí implementácia virtuálnych asistentov (napr. Siri, Alexa, Google, Cortana). Prvá generácia chatbotov má obmedzené schopnosti, ktoré im umožňujú odpovedať na jednoduché otázky; avšak vďaka nedávnym pokrokom v oblasti AI a množstvu dostupných údajov môžu virtuálni asistenti vykonávať komplexnejšie úlohy a dokonca dokončiť proaktívne transakcie. Zvýšenie efektívnosti tiež motivovalo aj niektoré vlády po celom svete, ktoré začali zavádzať technológie AI na pomoc pri výrazne zložitých úlohách v rôznych oblastiach, napr. zdravotnctvo, sociálne služby, verejná bezpečnosť, dane alebo vzdelávanie. Nedávna štúdia na Harvardskej univerzite identifikuje päť hlavných typov použitia chatbotov vo verejnom sektore:

- Odpovedanie na sťažnosti a otázky občanov prostredníctvom automatizovaných systémov podpory zákazníkov,
- Prehľadávanie dokumentov (vrátane právnych) a poskytovanie pomoci občanom pri vypĺňaní formulárov,
- Získavaní spätnej väzby občanov a ich smerovaní na zodpovedný úrad verejnej správy,
- Preklad úradných informáci a
- príprava dokumentov s odpoveďami na otázky občanov.

Jednou z hlavných výhod týchto virtuálnych asistentov je to, že sú schopní učiť sa pod dohľadom (*Supervised learning*), čo im umožňuje neustále sa učiť zo svojich interakcií s ľuďmi a zlepšovať presnosť odpovedí, ktoré poskytujú.

Okrem pridanej hodnoty pri poskytovaní verejných služieb môže AI prispieť aj k informovanejšiemu rozhodovaniu. Existujú štyri vzájomne sa nevylučujúce schopnosti umelej inteligencie, ktoré môžu zlepšiť procesy tvorby verejnej politiky: (i.) Prediktívne analýzy; (ii.) Detekcia; (iii.) Počítačové videnie (*Computer Vision*) a (iv.) Spracovanie prirodzeného jazyka (*Natural Language Processing, NLP*). Prediktívne analýzy a Detekcia využívajú metódy strojového učenia na identifikáciu vzorcov v historických údajoch, ktoré sa používajú na prevenciu chorôb, predikciu trestných činov („prediktívna polícia“), odhaľovanie podvodov, ako aj na poskytovanie užitočných poznatkov na riešenie zložitých politických problémov. Spracovanie prirodzeného jazyka (NLP) sa zvyčajne kombinuje s dolovaním údajov (*data mining*) na extrahovanie informácií z neštruktúrovaného textu alebo multimediálneho obsahu a používa sa aj na biometrickú identifikáciu, zatiaľ čo Počítačové videnie sa používa na riadenie dopravy, lekársku diagnostiku, porovnávanie odtlačkov prstov a porovnávanie tváre. Všetky vyššie uvedené možno kombinovať s transformačnými technológiami, ako sú Big Data, IoT, senzory, rozpoznávanie reči atď. a využívať obrovské množstvo údajov, ktoré produkujú. Uplatniteľnosť a úspech všetkých vyššie opísaných prístupov však závisí od viacerých faktorov, ako sú dostupnosť otvorených a nedefinovaných údajov vysokej kvality na zásobovanie systémov AI, existencia právnych rámcov zabezpečujúcich zodpovednosť a transparentnosť výsledkov AI, kapacita (ľudská aj technická) a kultúra zamestnancov vo verejnom sektore na pochopenie aplikácií AI. Nemenej dôležitým faktorom je samozrejme aj dostatočné financovanie

Základné pojmy a koncepty

Virtuálni asistenti sú inteligentné systémy založené na umelých neurónových sieťach podobných mozgu, ktoré sú teoreticky schopné napodobňovať človeka so zmyslovými schopnosťami podobnými človeku. Dokážu porozumieť jazyku, čítať text a rozpoznávať ľudské emócie, čo im dáva obrovský potenciál na zlepšenie poskytovania služieb. Pojmy chatbot a virtuálny pomocník sú takmer vzájomne zameniteľné,

s tým rozdielom, že chatbot je služba založená na umelej inteligencii, s ktorou komunikujete prostredníctvom chatovacieho rozhrania. Odpovede, ktoré poskytuje chatbot, môžu byť na akékoľvek účely, funkčné alebo zábavné. Nájdete ich v ktoromkoľvek významnom produkte chatu (Facebook Messenger, Slack, Telegram, Textové správy atď.). Virtuálny asistent je viacúčelový chatbot, ktorý spolupracuje so službami tretích strán a sídli v hardvérových zariadeniach, ako sú napríklad smartfón alebo osobný počítač (Siri, Google Assistant alebo Cortana), vyhradených hardvérových zariadeniach (Alexa prostredníctvom rodiny Amazon Echo) alebo ako doplnková funkcia vo väčšom zariadení (inteligentná chladnička Samsung, pomocníci v aute). Existujú tri základné typy chatbotov podľa využitia:

- Informačné - ktoré sú najjednoduchším typom a zvyčajne zahŕňajú poskytovanie všeobecných informácií, ako sú odpovede na časté otázky, správy a notifikácie.
- Transakčné - umožňujú používateľom uskutočňovať transakcie a interagovať (napríklad rezervovať hotelovú izbu). Spravidla vyžadujú, aby bol používateľ autentifikovaný do svojho používateľského účtu.
- Poradenstvo - Chatboti s vlastným učením sú najnovším prírastkom do skupiny chatbotov. Môžu sa učiť na základe interakcií so zákazníkmi a určovať vhodné ďalšie kroky.

Kľúčové faktory, ktoré určujú kvalitu a efektivitu u chatbotov, sú: (i.) **Komunikácia**, alebo schopnosť chatbotov efektívne využívať textový alebo hlasový kanál a prispôsobiť sa používateľom; (ii.) **Schopnosť porozumieť** ľudskej komunikácii (získavať kontext, rozpoznávať náladu používateľa, porozumieť smeru konverzácie). Táto základná intuitívna schopnosť je nevyhnutná pre obohatený konverzačný zážitok; (iii.) **Spolupráca** s inými strojmi, zariadeniami a zdrojmi údajov je tiež nevyhnutná pre to, aby sa chatbot neustále učil a poskytoval skutočnú konverzáciu na úrovni expertov. Napríklad, ak chatbot pomáha užívateľovi robiť dôchodkové plány, mal by byť tiež schopný zistiť infláciu a budúce výzvy týkajúce sa životných nákladov. Schopnosť neustále sa učiť zo skúseností je životne dôležitá. V závislosti od úrovne zrelosti vo vyššie uvedených troch oblastiach možno chatboty rozdeliť do nasledujúcich troch kategórií:

- Chatbot základnej úrovne – môže sa zapojiť do jednosmernej komunikácie, ako je presmerovanie používateľov na príslušnú URL. Tento druh nastavenia nevyžaduje pokročilé funkcie, ako je NLP.
- Chatbot strednej úrovne - má vylepšené schopnosti v oblasti komunikácie, porozumenia a spolupráce, ale nedokáže poskytnúť skutočne konverzačnú skúsenosť.
- Pokročilý chatbot - poskytuje zážitok najbližší skutočnej konverzácii. Má najvyšší stupeň schopností, bez problémov konverzuje, rieši chyby a elegantne prekonáva zlyhania.

Obrázok 10: Anatómia chatbota

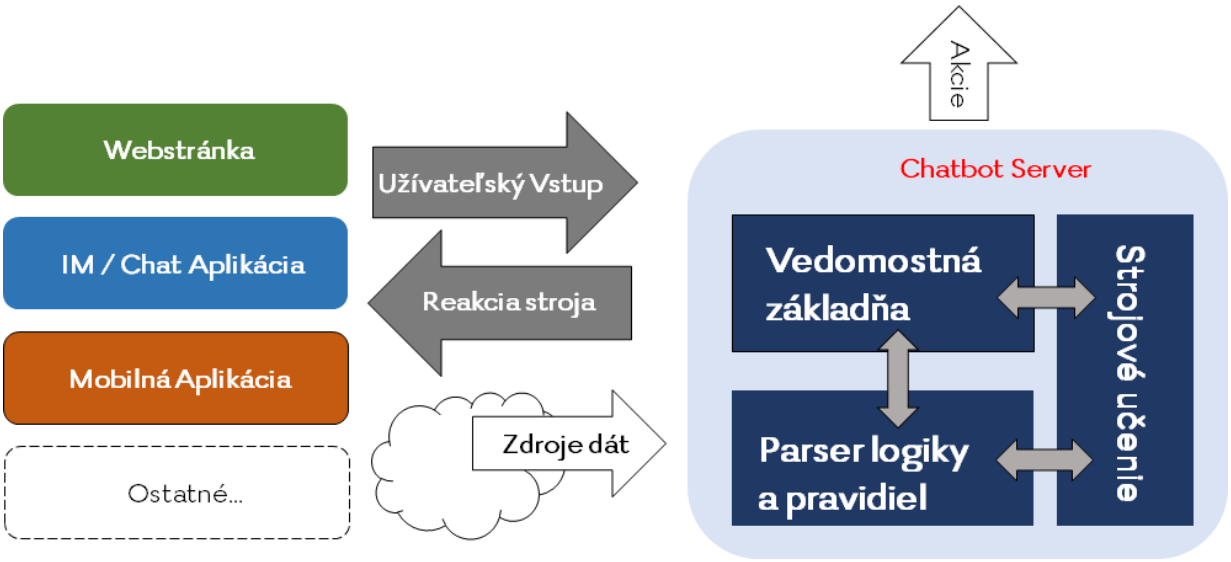

5.5.2 Vízia

S cieľom dosiahnuť, aby sa virtuálni asistenti a chatboti stali nástrojmi, ktoré možno každodenne využívať vo verejnom sektore, predstavujeme cestovnú mapu vývoja z pohľadu používateľa:

- Vlády budú investovať do virtuálnych asistentov na podporu občianskej aj internej angažovanosti. Niektoré vlády už používajú virtuálnych asistentov ako spôsob, ako zapojiť svojich občanov, no nedávny pokrok v technológii AI naznačuje, že tento trend bude naďalej pokračovať a zameranie sa rozšíri nad rámec starostlivosti o zákazníka tak, aby zahŕňala a prepájala všetky online a offline verejné služby. Predpovedáme, že virtuálni asistenti sa stanú preferovaným kanálom občanov pre interakciu s vládami, čím sa zvýši spokojnosť zákazníkov a znížia náklady, keď si zákazníci sami slúžia.
- **Technologické funkcie, ako napríklad dynamický dialóg, umožnia automatizácii zvládnuť pokročilé konverzačné schopnosti**, čo znamená zvýšenie úrovne komplexnosti možných služieb a interakcií. Takéto technologické vylepšenia virtuálnych asistentov im umožnia, aby sa stali všadeprítomnými v našich interakciách s vládnymi službami, čo značne presahuje rámec interakcií zameraných na konkrétne úlohy.
- **Virtuálni asistenti budú proaktívni a budú schopní predpovedať možné výsledky na základe údajov**. Prispôsobenie je kritickým krokom pri vytváraní samoobslužného riešenia. Rôzne vládne organizácie si to uvedomujú a vynakladajú značné investície, aby otvorili svoje údaje, s cieľom zlepšiť užívateľské skúsenosti, ktoré môžu byť kontextovejšie, personalizovanejšie a proaktívnejšie.

5.5.3 Transformácia

Inovatívny virtuálny asistent pre interakciu medzi vládou a občanmi by mal vychádzať z inovatívnej webovej platformy v súlade s kľúčovými prioritami stanovenými v kapitole 1. Na tejto platforme sú prostredníctvom webových služieb zabalené heterogénne (z hľadiska formátu aj obsahu) zdroje údajov a znalostí, ako aj príslušné metodiky a nástroje spracovania, zatiaľ čo ich integrácia sa vykonáva na úrovni služieb. Táto platforma umožňuje plynulú integráciu heterogénnych služieb a zabezpečuje ich

interoperabilitu z hľadiska technického, koncepčného a používateľského rozhrania. Predpokladané riešenie uľahčuje a zvyšuje zmysluplnú interakciu medzi vládou a občanmi vďaka riadnemu využívaniu schopností ľudského a strojového uvažovania a prijíma trojstupňovú architektúru, ktorá plynule integruje nasledujúce tri oblasti, ktoré by sa mali transformovať, za účelom dosiahnutia maximálnej funkcionality:

- **Služby manažmentu údajov (dátová vrstva)**, ktoré umožňujú cielené zisťovanie, zaznamenávanie, archiváciu, zdieľanie a spracovanie sledovateľných rozsiahlych údajov, ktoré existujú v rôznych zdrojoch a formátoch údajov. Veľa pozornosti sa venuje problémom integrácie údajov (prepájanie štruktúrovaných údajov z rôznych zdrojov) a čisteniu údajov (zbavovanie sa nepotrebných záznamov). Služby manažmentu údajov by sa mali sémanticky obohacovať, aby sa efektívne riešili základné problémy s metaúdajmi a ontológiou. Služby patriace do tejto dátovej vrstvy riadia životný cyklus rôznych dátových tokov, ktoré sa majú využívať na budovanie a údržbu vedomostnej základne platformy. Môžu to byť databázy existujúcich (historických) vládnych informačných systémov, ako aj ďalšie údaje, ktoré občania vytvárajú v aplikáciách Web 2.0 pomocou rozšírených súborov metadát. Tieto služby môžu napríklad zhromažďovať údaje z otvorených dátových portálov obsahujúcich geografické údaje týkajúce sa umiestnenia služieb a budov verejnej správy alebo iných „bodov záujmu“ v sektoroch ako kultúra, cestovný ruch, doprava a životné prostredie.
- **Služby spracovania údajov (vedomostná vrstva)**, ktoré využívajú technológie spracovania veľkých dát na ponúkanie funkcií, ako je dolovanie údajov (*data mining*), indexovanie údajov, klasifikácia, zoskupovanie, abstrakcia a interpretácia. Pokročilé techniky dolovania údajov môžu vyššie uvedené zdroje údajov vhodne spracovať, aby odhalili dôležité fragmenty informácií a skryté vzorce a zmysluplne ich spojili so skutočnými potrebami občanov a vládnymi rozhodnutiami. Správne spracovanie údajov môže napríklad odhaliť, ako občania vnímajú minulé vládne rozhodnutia, alebo interpretovať implicitnú spätnú väzbu občanov pri formovaní následných vládnych opatrení. Služby patriace do tejto vedomostnej vrstvy by sa mali budovať tak, aby umožňovali sofistikovaný inferenčný mechanizmus, ktorý lepšie poslúži interakcii medzi vládou a občanmi.
- **Používateľské rozhranie**, ktoré uľahčuje a zvyšuje kvalitu interakcie medzi vládou a občanmi. Táto kategória služieb umožňuje informované rozhodovanie tým, že poskytuje občanom: (i.) ľahký a účinný prostriedok na vyjadrenie, poskytnutie spätnej väzby a zmysluplnú interakciu; (ii.) informácie o pôvode údajov a ich dôveryhodnosti; (iii.) užitočné odporúčania a celkový kontext. Cielom tejto aplikačnej vrstvy by malo byť vytvorenie hybridného prostredia, ktoré môže kombinovať text alebo hlas v prirodzenom jazyku s grafickými prvkami, s možnosťou integrácie do populárnych platforiem poskytovaných tretími stranami, ako sú Messenger, Slack alebo Telegram.

5.5.4 Požiadavky na dáta a analytické nástroje

Hlavné typy vstupných údajov od používateľov sú:

Text a hlas - Používatelia môžu vytvárať údaje rôznymi spôsobmi. Najpoužívanejší vstup pre chatboty je vstup prostredníctvom textu, je tiež možné komunikovať s asistentom pomocou hlasu, čo je obzvlášť

užitočné pre orgány verejnej správy na zvýšenie dostupnosti verejných služieb pre ľudí so zdravotným postihnutím. Pre chatbotov s možnosťou hlasu sú potrebné:

- Technológia rozpoznávanie reči,
- Softvér na prevod reči na text,
- Softvér na prevod textu na reč.

Štruktúrované a neštruktúrované údaje. Chatbot môže poskytnúť množstvo možných odpovedí na otázky zadané pomocou tlačidiel a predvolených možností, ktoré sú spojené so štruktúrovanými údajmi. Konverzačný chatbot používa technológiu NLP na preklad neštruktúrovaného vstupu používateľa do štruktúrovaných údajov.

Autentifikačné údaje. Ideálne samoobslužné riešenie vychádza z personalizácie. S cieľom používať personalizované informácie a poskytovať služby, ktoré sú bezpečné, by chatbots verejnej správy mali zahŕňať metódy overovania. Existuje napríklad riešení eID v Belgicku, kde využívajú mobilnú autentifikačnú aplikáciu prepojenú s eID používateľa (Itsme ®).

Osobné údaje. Zásady ochrany údajov by mali byť prioritou celého životného cyklu chatbotu. Mali by sa automaticky uplatňovať najprísnejšie nastavenia ochrany osobných údajov. Najdôležitejšia zásada je zhromažďovať a spracúvať osobné údaje iba na to, čo je relevantné a nevyhnutne potrebné pre účel, ktorý musí byť špecifikovaný, výslovný a legitímny.

V záujme zabezpečenia optimálnej kvality údajov je potrebné uvážiť postupy zamerané na zmiernenie skreslenia a optimálnu kontrolovateľnosť. Súbor údajov by mal obsahovať komplexný záznam o pôvode údajov, obstarávaní, predbežnom spracovaní, počte riadkov, uchovávaní a bezpečnosti, ako aj kvalitatívny vstup o rozhodnutiach týkajúcich sa reprezentatívnosti údajov, dostatočnosti údajov, integrity zdrojov, včasnosti údajov, relevantnosti údajov a testovania.

5.5.5 Najlepšia prax

Lotyšský virtuálny asistent registra podnikov „UNA[17]“ je prvým virtuálnym asistentom verejnej správy v Lotyšsku. UNA odpovedá písomne a v lotyštine na najčastejšie otázky týkajúce sa registrácie nového subjektu, postupu predložených registračných dokumentov a likvidácie prostredníctvom webovej stránky Registra podnikov, ako aj v aplikácii Facebook Messenger. UNA je efektívny komunikačný nástroj a inovatívne riešenie v oblasti služieb zákazníkom pre služby verejnej správy v Lotyšsku, neustále získavajúce nové poznatky o témach, ktoré sú v záujme klientov. Virtuálny asistent nahrádza návštevu alebo telefónny hovor a poskytuje možnosť získať odpoveď na otázku kedykoľvek počas dňa. Na vytvorenie tohto virtuálneho asistenta sa použila platforma virtuálnych asistentov, neurónové siete a technológie prirodzeného jazyka, čo pomáha zabezpečiť, aby bolo možné s virtuálnym asistentom voľne komunikovať. Virtuálny asistent UNA nahrádza technickú rutinnú prácu zamestnancov a umožňuje im zamerať sa na prácu s vyššou pridanou hodnotou.

Podobné systémy sa objavujú aj vo Veľkej Británii, kde Londýn používa virtuálneho agenta menom Amelia, ktorý je založený na technologickej AI platforme spoločnosti IPsoft. Táto služba má za cieľ

[17] https://oecd-opsi.org/innovations/una-the-first-virtual-assistant-of-public-administration-in-latvia/

pomôcť obyvateľom lokalizovať informácie a dokončiť štandardné aplikácie a zjednodušiť tak niektoré interné procesy. Ďalší prípad použitia je v Poľsku, kde osem miest využíva cloudových virtuálnych agentov na poskytovanie informácií o službách vlády občanom. Program virtuálneho webového chatu vyvinutý spoločnosťou InteliWISE poskytuje informácie o širokej škále služieb, podobne ako v Singapure, kde vyvinuli chatbot Joanne, ktorý je schopný pomôcť s daňovými otázkami.

Fínska vláda zaviedla iný príklad verejnej služby založenej na AI[18] - sieť rôznych inteligentných služieb a aplikácií, ktorá umožňuje verejnej správe lepšie predvídať a poskytovať zdroje na budúce potreby služieb a umožňovať občanom prístup k vysokokvalitným digitálnym službám. Táto služba s názvom „Aurora" nie je jediným servisným bodom; Ide skôr o sieť služieb, v ktorej inteligentné aplikácie môžu ľudí bezpečne a eticky osloviť podľa životných okolností a udalostí. Vďaka Aurora AI môžu verejní a súkromní prevádzkovatelia pripojiť svoje služby k sieti, s cieľom poskytovať cielené služby a proaktívne odporúčania využívaním decentralizovanej otvorenej siete AI a inteligentných riešení, ktoré uľahčujú interakciu medzi službami a vytvárajú plynulé reťazce služieb bezpečným a etickým spôsobom. Táto služba tiež pomáha riešiť neefektívnosť a plytvanie verejnými financiami.

Ďalším úspechom je americká agentúra pre digitálne služby (18F), ktorá začala používať chatbot s názvom „Mrs. Landingham "na orientáciu nových zamestnancov[19]. Tento chatbot, ktorý pracuje v rámci aplikácie Slack, je určený na odosielanie správ a pripomienok novým zamestnancom s informáciami o formách, diskusiách a všadeprítomnom vládnom žargóne.

Medzi najpokročilejších poskytovateľov technológie virtuálnych asistentov v súkromnom sektore patria: 7.ai, Artificial Solutions, boost.ai, Creative Virtual, CX Company, DigitalGenius, eGain, IBM, idAvatars, Inbenta, Interactions, IPsoft, Kore.ai, LogMeIn, Microsoft, noHold, Nuance, OWI, Servicefriend, Verint Next IT.

5.5.6 Obmedzenia a problémy

Vzájomné pôsobenie medzi systémami ľudskej a umelej inteligencie by mohlo viesť k rôznorodému súboru rizík týkajúcich sa bezpečnosti ľudí, súkromia, integrity, dôstojnosti, autonómie a vlastníctva údajov. Podľa Európskeho parlamentu existuje šesť prierezových kľúčových regulačných tém ovplyvňujúcich vývoj v oblasti robotiky a umelej inteligencie: Etické pravidlá; Pravidlá zodpovednosti; Konektivita, duševné vlastníctvo a tok údajov; Štandardizácia, bezpečnosť a ochrana; Vzdelávanie a zamestnanosť; Inštitucionálna koordinácia a dohľad.

Virtuálni asistenti nepredstavujú bezpečnostné problémy, ktoré ešte neboli objavené a náležite zmiernené. Nižšie preto uvádzame hlavné bezpečnostné obavy a stratégie zmierňovania:

- Využívanie verejných komunikačných platforiem - Verejné platformy ako sú Facebook alebo Slack sa stali populárnymi platformami na nasadenie chatbotov. Na týchto platformách však existujú značné obavy týkajúce sa ochrany súkromia. V súčasnosti sa odporúča obmedziť používanie týchto platforiem a presmerovať používateľa na bezpečnejšie rozhranie pri zdieľaní citlivých údajov.

[18] https://vm.fi/en/article/-/asset_publisher/viranomaispalvelut-tekoalyaikaan-esiselvitys-kansallisesta-tekoalyohjelma-aurorasta

[19] https://18f.gsa.gov/2015/12/15/how-bot-named-dolores-landingham-transformed-18fs-onboarding/

- Šifrovanie - Pri prenose údajov by sa mali implementovať šifrovacie protokoly, ako napríklad HTTPS. End-to-end šifrovanie tiež zabezpečuje, že k obsahu konverzácie majú prístup iba dve strany zapojené do konverzácie.
- Overenie - Pred spracovaním akýchkoľvek citlivých informácií sa musí implementovať viacfaktorová autentifikácia. Napríklad, ak robot pracuje na platforme Messenger, autorizácia používateľa prostredníctvom jeho prihlásenia cez Facebook je nedostatočná a mala by sa vynútiť ďalšia vrstva autentifikácie, ako je použitie eID. Po úspešnej autentifikácii sa môžu vygenerovať zabezpečené autentifikačné tokeny na na pevne stanovenú dobu, po uplynutí musí byť používateľ vyzvaný, aby sa znova autentifikoval.
- Útoky v oblasti sociálneho inžinierstva - roboti sú schopní vydávať sa za ľudí a naopak. Používatelia môžu byť oklamaní škodlivými robotmi, ktorí sa vydávajú za úrad a žiadajú citlivé informácie. Kľúčom k zmierneniu tohto rizika sú iniciatívy na zvýšenie informovanosti používateľov. Mali by byť zavedené aj mechanizmy na overenie totožnosti aplikácie, s ktorou užívateľ komunikuje.
- Ukladanie údajov a manipulácia s nimi - Je dôležité zabezpečiť, aby sa zozbierané údaje uchovávali bezpečne a aby sa s nimi zaobchádzalo s náležitou starostlivosťou. Okrem toho musí aplikácia ukladať údaje iba v prípade potreby. Musí sa stanoviť obdobie uchovávania údajov, po uplynutí ktorého sa musia zničiť kópie údajov. Údaje sa musia uchovávať v šifrovanom formáte a prístup k týmto údajom sa musí starostlivo monitorovať. Ak sa tieto údaje používajú na analytické a výskumné účely, totožnosti používateľa musia byť chránené prostredníctvom anonymizácie / pseudonymizácie.

5.6 Využitie umelej Inteligencie pre manažment ľudských zdrojov

5.6.1 Úvod

Ľudia a stroje spolupracujú pri vytváraní stále rastúceho množstva údajov o ľudských zdrojoch a pomocou analýz umelej inteligencie poskytujú lepší prehľad o tom, ako pracovať v rámci organizácie. Úspech akejkoľvek organizácie závisí od toho, ako efektívne a inteligentne kombinuje ľudí, procesy a technológie, aby poskytli transformačnú hodnotu za nízku cenu. Automatizácia a digitalizácia sa tak najčastejšie zapája do procesu komunikácie s potenciálnymi kandidátmi. Predvýber vykonáva umelá inteligencia podľa zadaných parametrov s cieľom určiť na základe empirických dát tých najvhodnejších kandidátov. To, čo by človek čítal a filtroval dni, teraz zvládne AI počas sekúnd. Pátranie sa tak výrazne časovo skracuje. Roboti niekedy dokonca rieši aj priamu komunikáciu - sami cielene oslovujú vybrané kandidáty cez chatovacie aplikácie typu Facebook, Messenger alebo Vıber, niektorí dokážu aj spísať e-mail. Chatbot má na starosti prvotné oslovenie a overenie, či je kandidát skutočne pre firmu vhodný a či má o prácu záujem. Technológia je už na takom stupni vývoja, že chatbot vie odpovedať potenciálnym zamestnancom na základné otázky, vykoná ďalší filter a vybrané ľudí zotriedi do internej databáze. Vo finále ponúkne súpis najlepších kandidátov, ktorí sa na danú pozíciu hodí a prejavili o ňu záujem.

V skratke, AI umožňuje nájsť takých ľudí, ktorí najviac vyhovujú potrebám organizácie, pomocou výkonnostných profilov, ktoré identifikujú behaviorálne, kognitívne a kultúrne vlastnosti žiadateľov a poskytujú údaje o ich výkonnostnom potenciáli.

5.6.2 Vízia

Umelá inteligencia bude vedieť porovnať a vyhodnotiť stovky profilov za jednotku času, s prihliadnutím k najrôznejším parametrom hľadania a vyhodnocovania. Ak jeden zo systémov zlyhá, strojovým učením sa zvolí iný postup.

AI pomôže zaistiť úroveň rozmanitosti na pracovisku prostredníctvom procesov, ako je napríklad slepý nábor - rozhodnutia sa môžu prijímať výlučne na základe údajov, a nie na základe demografických údajov, čím sa odstraňuje akákoľvek zaujatosť z počiatočných štádií náboru.

AI bude personalizovať vzdelávanie a školenie zamestnancov - pedagógovia a školitelia budú schopní vytvoriť bezpečné prostredie vhodné na vzdelávanie. AI môže tiež pomôcť zamestnancom a manažérom sledovať ich pokrok v odbornej príprave.

Zamestnanec bude mať prístup k svojim osobným údajom, napríklad k adrese, núdzovým kontaktom, podrobnostiam organizácie, dovolenkovým dňom, stavu schválenia žiadostí o dovolenku a autorizovaným údajom o ľudských zdrojoch.

5.6.3 Transformácia

Revízia digitálnej kultúry a talentu vo vašej organizácií

Dôležitým východiskovým bodom je audit stavu organizácie tak, ako je („as-is“), čo pomôže to určiť kľúčové oblasti, na ktoré sa treba zamerať, a tiež poskytne dobrý referenčný bod, na základe ktorého sa bude merať pokrok. Audit digitálnej kultúry a talentu by sa mal zamerať na technológiu, kultúrnu pripravenosť, organizačnú štruktúru, zručnosti a vodcovstvo. Cieľom je podporiť nové myslenie, ktoré uznáva zrýchľujúcu sa rýchlosť zmien v digitálnej ére.

Pretvorenie funkcie riadenia ľudských zdrojov

Technickí a digitálni lídri prinesú špecifické znalosti a skúsenosti, aby uľahčili prácu HR. Dôležité je zameranie sa na používanie technológie a nových zručností, ktoré môžu využiť významnú hodnotu a výhodu analytických údajov.

Transformácia organizačnej kultúry

Pracovné miesta a tímy budú pravdepodobne oveľa plynulejšie a zapojené do medzifunkčnej spolupráce. Výzvou pre vedúcich pracovníkov v oblasti ľudských zdrojov bude využitie digitálnej technológie pri vývoji nových spôsobov náboru, riadenia, organizácie, hodnotenia, odmeňovania a udržania talentov potrebných na riadenie digitálne umožnenej organizácie.

Personalizácia prístupu k zamestnancom

Cieľom je pochopenie digitálnych zručností, silných stránok a cieľov zamestnancov. Po získaní potrebného talentu bude začlenená kultúra vzdelávania nevyhnutným predpokladom na zabezpečenie neustáleho zdokonaľovania zručností a znalostí. Online vzdelávacie nástroje a komunity umožňujú zamestnancom riadiť ich vlastný rozvoj, poskytujú prístup k obsahu, odborným znalostiam a online podporným komunitám.

5.6.4 Požiadavky na dáta a analytické nástroje

Lepšie dáta o zamestnancoch, ich výkonnosti a správaní

- Poskytovanie prediktívnych štatistík.
- Spoľahlivejšie meranie návratnosti investícií a efektívnosti.
- Zníženie zaujatosti pri rozhodovaní v oblasti ľudských zdrojov.
- Manažéri môžu naplánovať školenia pre svoj tím na základe hodnotenia medzier v zručnostiach.
- Použitie viacerých zdrojov údajov môže odhaliť nové informácie o profile kandidáta.
- Analytické informácie a informácie o KPI, napríklad štatistiky zamestnancov, najvýkonnejšie subjekty a čakajúce žiadosti o transakcie.

Pretvorenie pracovnej sily

- Automatizácia úloh umožní zamestnancom sústrediť sa na strategickejšiu a hodnotnejšiu prácu.
- Skrátenie času, ktorý odborníci v oblasti HR trávia administratívnymi úlohami.
- Efektívny nábor a udržavanie zamestnancov.

Zvyšovanie spokojnosti zamestnancov a ich motivácie

- Personalizované vzdelávanie a odborná príprava.
- Predvídanie potrieb zamestnancov.
- Prístup k vlastným osobným informáciám zamestnanca.

5.6.5 Najlepšia prax

Oddelenie ľudských zdrojov austrálskej vlády využíva virtuálneho asistenta „Sam“, ktorý môže odpovedať na všeobecné otázky o rodinných záležitostiach alebo hľadaní zamestnania. Ministerstvo tiež zaviedlo interného virtuálneho asistenta s názvom „MelissHR“, ktorý zamestnancom uľahčuje prístup k informáciám o ľudských zdrojoch.

Napríklad spoločnosť súkromného sektora Club Med vyvinula nástroj AI, ktorý analyzuje, ako každý zamestnanec prispieva k organizácii, meria výkon a zároveň zlepšuje školenie na pracovisku s cieľom riešiť medzery alebo zlepšiť služby. Club Med sa tiež zameriava na kľúčové poznatky o spokojnosti zamestnancov, fluktuácii pracovných miest a udržaní najlepších talentov.

Spoločnosť Nvidia vybudovala svoj vlastný systém na predpovedanie, ktorí kandidáti si zaslúžia pohovor. Nástroj sa zameriava na nezvyčajné indície: napríklad kandidáti, ktorí predkladajú mimoriadne dlhé životopisy majú tendenciu pracovať horšie ako ostatní. Hotelový reťazec Hilton dokonca analyzuje videá kandidátov, ktorí odpovedajú na otázky, a pomocou AI posudzuje ich verbálne zručnosti, intonáciu a gestá.

Existujúce aplikačné riešenia: **Arya**, **Avrio**, **Cyra**, **EngageTalent**, **Entelo**, **GoHire**, **JobPal**, **Olivia**, **PocketRecruiter**, **Pomato**, **Scout Technology**, **TalkPush**, **Talla**, **Tara**, **Wirkin**

5.6.6 Obmedzenia a problémy

Technologické výzvy

- **Súkromie**: k dôverným údajom o ľudských zdrojoch sa musí pristupovať bezpečne a mali by byť dostupné iba oprávnenej osobe.
- **Priebežná údržba**: Tak ako pri iných inovatívnych technológiách, si AI vyžaduje hlboké vzdelávanie a pravidelné kontroly a aktualizácie.
- **Interoperabilita dát**: dostupnosť údajov je obmedzená z dôvodu presunu ľudských zdrojov smerom k SAAS (Software as a Service). Kombinácia a analýza multimodálnych údajov tiež predstavuje technickú výzvu súvisiacu s interoperabilitou, strojovým učením a ťažbou.
- **Kvalita údajov**: Keďže zložitosť operácií rastie a nové analytické metódy sa vyvíjajú pomerne rýchlo, môže byť ťažké zaznamenať a pochopiť pôvod údajov, čo zase môže významne.

Ostatné výzvy

- **Kultúra pracoviska** sa považuje za najvyššiu prekážku digitálnej transformácie - súčasná kultúra je skôr zameraná na úlohy než na inovatívne alebo experimentálne riešienia.
- **Nedostatok ľudí** so správnymi (aj digitálnymi) zručnosťami.
- **Etické problémy** - Google napríklad vyvinul samoučiacého robota, ktorý vyhodnocoval životopisy uchádzačov, ten čoskoro prestal do ďalších kôl výberového konania púšťať ženy, pretože mali štatisticky kratšiu dĺžku pracovnej praxe, väčšinou kvôli rodičovskej dovolenke. Organizácie budú musieť zabezpečiť, aby algoritmy boli neustále monitorované.

5.7 Využitie technológie blockchain pre transformáciu evidencie

5.7.1 Úvod

Dôležitou funkciou vlády je udržiavanie dôveryhodných informácií o jednotlivcoch, organizáciách, majetku a činnostiach. Inštitúcie verejnej správy sú poverené vedením záznamov, ktoré zahŕňajú napríklad dátumy narodenia a úmrtia alebo informácie o manželskom stave, licenciách, prevodoch majetku alebo trestnej činnosti. Správa a používanie týchto údajov môže byť komplikované. Niektoré záznamy existujú iba v papierovej podobe a ak je potrebné vykonať zmeny v úradných registroch, občania sa musia často dostaviť osobne, aby tak urobili. Jednotlivé inštitúcie majú tendenciu budovať svoje vlastné silo protokolov správy informácií, čo výrazne komplikuje ich použitie inými inštitúciami verejnej správy. Tieto údaje musia byť samozrejme chránené pred neoprávneným prístupom alebo manipuláciou, a to bez možnosti chýb.

Technológia distribuovanej databázy (Blockchain) by mohla zjednodušiť správu dôveryhodných informácií, čím by inštitúciám verejnej správy uľahčila prístup k kritickým údajom a ich použitie pri súčasnom zachovaní bezpečnosti týchto informácií. Blockchain je kódovaná digitálna kniha, ktorá je uložená na viacerých počítačoch vo verejnej alebo súkromnej sieti. Zahŕňa dátové záznamy alebo „bloky“. Keď sú tieto bloky zhromaždené v reťazci, nemôže ich jeden aktér zmeniť ani vymazať; namiesto toho sa overujú a spravujú pomocou protokolov automatizácie a zdieľanej správy.

5.7.2 Vízia

Decentralizované riešenia, ktoré môžu vzniknúť vďaka technológii decentralizovanej hlavnej knihy alebo aj blockchain majú potenciál disruptovať inštitúcie, ako ich poznáme, vďaka vytváraniu vrstvy dôvery medzi účastníkmi transakcií. Na zabezpečenie dôveryhodnosti transakcií už nie je potrebná dôveryhodná tretia strana. Okrem inštitucionálnej inovácie môže decentralizovaná architektúra prispieť k vytvoreniu spravodlivejšieho internetu, ktorý je viac v súlade s európskymi hodnotami, ako súčasný model. Vo verejnej správe má použitie blockchainu zmysel pre prípady keď:

- do situácie vstupuje veľké množstvo nezávislých subjektov, medzi ktorými nie je explicitná dôvera,
- navrhované riešenie mení fungovanie inštitúcií a obmedzuje zbytočnú vrstvu takzvaného prostredníka (často inštitúciu verejnej správy, banku, burzu),
- v rámci ekosystému vzniká kolobeh hodnoty, ktorý sa v súčasnosti nedarí zachytiť.

5.7.3 Transformácia

Identifikujte oblasť aplikácie

Existuje veľké množstvo možných aplikácií tejto technológie, ktoré riešia rôzne typy problémov. V prvom kroku je potrebné nájsť vhodný problém a určiť, či v jeho prípade má použitie blockchainu zmysel, najmä v porovnaní s využitím klasického informačného systému. Blockchain použite, ak sú potrebujeme vytvoriť systém dôvery medzi veľkým počtom účastníkov v oblasti, ktorú reguluje inštitúcia verejnej správy (napríklad kolobeh odpadov, patentové aplikácie) a v súčasnosti ešte neexistuje efektívny centrálny systém, ktorý by dokázal riešenie pokryť.

Za vhodné oblasti aplikácie blockchainu považujeme:

- systém pre online spracovanie finančných transakcií (takzvaná real-time ekonomika),
- ekosystém pre šetrenie zdrojov v obehovej ekonomike, pre manažment energetických potrieb v mestách a pre riešenie problémov odpadov,
- ekosystém pre spracovanie a dôveryhodné zdieľanie zdravotnej dokumentácie,
- spracovanie zahranično-obchodných transakcií a riešenie colných deklarácií,
- register rozhodnutí vo verejnej správe, najmä v súvislosti so zabezpečením princípu „jeden-krát a dosť“ v rámci krajín EÚ,
- register dosiahnutého vzdelávania,
- riešenie splnomocnení a mechanizmus pre „smart-contracts“,
- zabezpečenie dôveryhodnosti otvorených údajov.

Vypočítajte hodnotu za peniaze takéhoto riešenia a porovnajte ho z klasickým centralizovaným prístupom. Medzi náklady uveďte najmä náklady na prevádzku siete, ale i vytvorenie štandardu a potrebu úpravy zapojených informačných systémov. Medzi prínosmi zvážte odstránenie potreby tretej strany (náklady na zabezpečenie inštitúcie), jednoduchšie riešenie sporov a podobne.

Vyberte ekosystém

Vývoj ponuky ekosystémov je dynamický. Medzi stálice patrí Ethereum s ambíciou vytvoriť univerzálny ekosystém pre dynamické aplikácie a zachytenie akejkoľvek digitálnej hodnoty. K dispozícii sú však aj ďalšie ambiciózne alternatívy, napríklad aj slovenský Decent.

Pri výbere ekosystému je potrebné zvážiť nasledujúce otázky:

- Akú mieru ochrany osobných údajov a súkromia vaša aplikácia vyžaduje?
- Aké je očakávaný plán rastu používania? Škálovateľnosť patrí k hlavným problémom blockchainových technológií a príliš veľký nárast používateľov môže vytvoriť komplikovanú situáciu s vysokou latenciou spracovania transakcií.
- Aká miera latencie je akceptovateľná? Latencia je ovplyvnená aj komplexnosťou zaznamenávaných transakcií a požiadavky na vyhľadávanie v distribuovanej databáze. S touto otázkou súvisí aj spôsob, akým sa na platforme dosahuje konsenzus.
- Chcete využiť verejnú alebo súkromnú sieť?
- Aké programovacie jazyky sú na platforme podporované?
- Aký je cenový model a náklady za transakciu?

Výber platformy a ekosystému patrí medzi strategické rozhodnutia a do veľkej miery určí jeho budúci úspech. Odporúčame výber osvedčenej a stabilnej platformy, kde sa dá predpokladať, že bude dlhodobo dostupná.

Pripravte zmenu legislatívy

Zavedenie blockchainovej aplikácie, ktorá rieši verejný problém a vytvára vrstvu dôvery si vyžaduje úpravu legislatívy, ktorá určí:

- oprávnenosť používania a akceptácie blockchainovej aplikácie v danom prípade použitia,
- garanciu dôveryhodnosti ukladaných údajov a dokumentov a možnosť ich používania v právnych konaniach,
- garanciu dlhodobej prevádzky,
- definíciu tokenov, ktoré sa v riešení používajú a vymedzenie hodnoty,
- spôsob riešenia sporov,
- inštitucionálne úpravy,
- pravidlá transperentnosti, auditovateľnosti a ochrany súkromia.

Napríklad, ak je záujmom zaviesť evidenciu účtovných transakcií v blockchanie je potrebné upraviť účtovné a daňové predpisy, ak je záujmom nahradiť notárske zápisnice pomocou blockchainu je potrebné legislatívne ošetriť, že dokumenty uložené v blockchaine sú právoplatné a dôveryhodné. Vhodným regulačným nástrojom je využitie takzvaných „regulačných sandboxoch“, v rámci ktorých by sa nové pravidlá overili v praxi.

Pripravte reorganizáciu

Blockchainové riešenia nahradzujú potrebu dôveryhodnej tretej strany, čo znamená inštitucionálnu inováciu. Túto inováciu je potrebné zaviesť do praxe:

- zrušiť priamy výkon organizácie, ktorá je nahradená blockchainom,
- vytvoriť regulačnú právomoc pre dozor a dohľad nad distribuovaným systémom, ktorý by riešil: kontrolu správnosti, štandardizáciu, sťažnosti používateľov a propagáciu používania a podobne.

Pripravte štandardy pre spôsob použitia

Ďalším krokom, ktoré je potrebným zvážiť je príprava distribuovaných aplikácií, ktoré budú využívať decentralizované riešenie. V princípe by verejná správa mala určiť:

- štandardizáciu dátových objektov a transakcií, ktoré sa budú zaznamenávať,
- procesný model pre prípad použitia,
- štandardizácia API a funkcií distribuovanej aplikácie,
- bezpečnostné požiadavky a požiadavky na ochranu osobných údajov.

Zapojte komunitu a vytvorte inkubátor

Ako môžu inštitúcie využiť rýchle tempo inovácií v ekosystéme blockchain pri riešení svojich výziev? Jedným zo spôsobov je prijatie prístupu dynamického inkubátora. Znamená to, že môžete vytvoriť malý tím, ktorý skúma príležitosti pre pilotné nasadenie blockchainu a potom vyberie vhodných partnerov na implementáciu. Táto skupina by mohla byť v rámci ústredného vládneho úradu pre digitalizáciu ale aj v rámci jednotlivých inštitúcii verejnej správy.

5.7.4 Požiadavky na dáta a analytické nástroje

Použitie blockchainovej siete si vyžaduje najmä výber vhodnej a efektívnej platformy, ktorá bude využívaná na ukladanie záznamov (dokumentov, transakcií a dát) a na tokenovú ekonomiku. Za základné požiadavky je možné považovať:

- Univerzálnosť použitia,
- Správa a manažment platformy,
- Typ hlavnej knihy,
- Podpora inteligentných zmlúv,
- Spôsob konsenzu,
- Počet používateľov,
- Počet transakcií,
- Latencia pri transakcii,
- Počet transakcií za časovú jednotku.

5.7.5 Najlepšia prax

Počet oblastí, v ktorých verejná správa môže využiť veľký potenciál technológie blockchain sa neustále zvyšuje – od zdravotníctva, dopravy a energetiky cez voľby a digitálnu participáciu až po daňový systém a digitálne meny. Nižšie ponúkame stručný popis úspešných príkladov implementácie technológie blockchain vo verejnej správe a hlavné výsledky tejto implementácie[20]:

- V **Estónsku** tvorí blockchain základ úspešného e-Estonia programu, ktorý prepája verejné služby do jednej digitálnej platformy, ktorá integruje obrovské množstvo dát zo zdravotníctva, súdnictva, bezpečnostných systémov a podnikateľských registrov. Práve aplikácie blockchainu zabezpečujú aby bol celý systém chránený pred kybernetickými útokmi, zneužitím a korupciou.
- **Spojené štáty americké** testujú blockchainové systémy na bezpečné zdieľanie dát o pacientoch v rámci zdravotníckeho systému, ako aj dát zbieraných kamerami a senzormi na hraniciach, čo má v oboch prípadoch zvýšiť bezpečnosť občanov a údajov o nich.
- **Veľká Británia** používa blockchain technológiu na sledovanie distribúcie mäsových výrobkov, čo zlepšilo dodržiavanie prísnych pravidiel v potravinárskom priemysle.
- **Brazília** využíva blockchainové aplikácie na monitorovanie procesu verejného predkladania ponúk na zákazky so štátom čo prinieslo zníženie korupcie a transparentnejšie zmluvy.
- Mesto Zug vo **Švajčiarsku** akceptuje kryptomeny ako platidlo za verejné služby v meste, používa digitalizované ID registrácie založené na blockchaine a testuje elektronické voľby na báze blockchainu. Tieto iniciatívy viedli k skvalitneniu verejných služieb a ich zrýchlenému poskytovaniu pre obyvateľov a návštevníkov mesta.
- **Gruzínsko** používa blockchain na digitalizovanie procesov katastrálneho úradu, čo umožňuje občanom rýchlo, jednoducho a legálnym spôsobom registrovať svoj pozemok či majetok.
- **Singapur** testuje systém na tokenizáciu národnej meny prostredníctvom blockchainových platforiem, čo má zjednodušiť a zrýchliť proces peňažnej výmeny v rôznych menách.

5.7.6 Obmedzenia a problémy

Neoverená technológia a príliš dynamický vývoj ponuky

Inštitúcie verejnej správy, ktoré chcú zaviesť riešenia postavené na blockchainu, sa musia vysporiadať s odvetvím, ktoré sa rýchlo vyvíja. Fondy rizikového kapitálu investovali viac ako 1,2 miliardy dolárov do začínajúcich spoločností blockchain len za posledné dva roky; približne 50 z týchto začínajúcich firiem dostalo každý viac ako 1 milión dolárov.

Takýto rýchly a neprehľadný rast predstavuje výzvy pre vedúcich IT pracovníkov vo verejnom sektore. Po prvé, neexistujú všeobecne akceptované normy pre technológiu blockchainu alebo siete, ktoré ich prevádzkujú. Inštitúcie verejnej správy, ako všetci ostatní, môžu mať preto ťažkosti s posúdením kvality dostupných riešení a určením toho, ako ich najlepšie integrovať do svojho existujúceho IT prostredia. Po druhé, pretože mnohí poskytovatelia blockchainu sú malými začínajúcimi podnikmi, pre oddelenia IT

[20] https://www.lexology.com/library/detail.aspx?g=5ca34bda-7d04-431d-bc79-5c7ff34a1c84

a obstarávania môže byť ťažké identifikovať stabilných partnerov. To znamená, že spoločnosti môžu ponúkať špičkové riešenia, ale nie sú dostatočne stabilné na to, aby mali reálnu skúsenosť s implementáciou projektov pre verejnú správu.

Ochrana súkromia

Riziká ochrany súkromia si zároveň budú vyžadovať neustálu pozornosť. Aj keď by organizácia verejnej správy mohla nasadiť blockchain, ktoré využívajú údaje vo verejných sieťach, stále by museli zabezpečiť, aby metódy šifrovania boli dostatočne silné na zabezpečenie súkromia používateľov. Inštitúcie verejnej správy budú musieť pochopiť právne a regulačné dôsledky blockchainu, medzi nimi: Do akej miery budú inteligentné zmluvy záväzné? Môžu sa audítorské trasy pre blockchain použiť ako dôkaz na súde? Malo by byť používanie blockchainu povinné?

6 Použitá literatúra

Prediktívna polícia

Delloite, 2015. *The Digital Policing Journey: From Concept to Reality* [online]. Deloitte. https://www2.deloitte.com/content/dam/Deloitte/uk/Documents/public-sector/deloitte-uk-digital-police-force.pdf

BRAYNE, S.; ROSENBLAT, A.; BOYD, D., 2015. Predictive Policing. In: *Data & Civil Rights: A New Era of Policing and Justice*. Data & Society. https://datasociety.net/output/data-civil-rights-predictive-policing/

BACHNER, J., 2013. *Predictive Policing: Preventing Crime with Data and Analytics*. IBM Center for The Business of Government. http://www.businessofgovernment.org/sites/default/files/Management%20Predictive%20Policing.pdf

PERRY, W.; MCINNIS, B.; PRICE, C.; SMITH, S.; HOLLYWOOD, J., 2013. *Predictive Policing: The Role of Crime Forecasting in Law Enforcement Operations.* RAND. ISBN: 978-0-8330-8148-3.

FERGUSON, A. G. , 2012. *Predictive Policing and Reasonable Suspicion*. Emory Law Journal 62(2). ISSN 0094-4076.

PAPACHRISTOS, A., 2009. *Murder by Structure: Dominance Relations and the Social Structure of Gang Homicide*. American Journal of Sociology 115(1): 74-128. ISSN: 1537-5390.

MCCUE, C.; PARKER, A., 2003. *Connecting the Dots: Data Mining and Predictive Analytics in Law Enforcement and Intelligence Analysis*. Police Chief, Vol 70(10): 115–24. DOI: 703.836.6767

Virtuálni asistenti

Buzzle. (n.d.). Unbelievably Brilliant Applications of Artificial Intelligence. Retrieved January 8, 2018, from https://www.buzzle.com/articles/applications-of-artificialintelligence.html

Abu Shawar, B., & Atwell, E. (2007). Chatbots: Are they really useful? LDV-Forum: Zeitschrift Für Computerlinguistik Und Sprachtechnologie, 22(1), 29–49 10.1.1.106. 1099.

Business Insider (2017). The chatbots in banking report: how chatbots can transform digital banking. Retrieved January 8, 2018, from http://www.businessinsider.com/ the-chatbots-in-banking-report-how-chatbots-can-transform-digital-banking-2017-1

Mehr, H. (2017). Artificial Intelligence for Citizen Services and Government Artificial Intelligence for Citizen Services and Government artificial intelligence for citizen services and government. Retrieved from https://ash.harvard.edu/files/ash/files/ artificial_intelligence_for_citizen_services.pdf

Centre for Public Impact (2017). Destination unknown: Exploring the impact of Artificial Intelligence on Government. Retrieved from https://publicimpact.blob.core. windows.net/production/2017/09/Destination-Unknown-AI-and-government.pdf

Personalistika

ICT Revue, 2019. *Umělá inteligence ve službách personalistiky. Budou roboty najímat roboti?* https://ictrevue.ihned.cz/c3-66651540-0ICT00_d-66651540-umela-inteligence-ve-sluzbach-personalistiky-budou-roboty-najimat-roboti

ZAMLYNOVÁ, T., 2019. *Umělá inteligence pomáhá hledat firmám nové zaměstnance*. https://tech.instory.cz/792-umela-inteligence-pomaha-hledat-firmam-nove-zamestnance.html

RIORDAN, D., 2018. *Government Leverages Ai For Hr Modernization*. https://www.govloop.com/government-leverages-ai-hr-modernization/

EY, 2018. *The new age: artificial intelligence for human resource opportunities and functions.* https://www.ey.com/Publication/vwLUAssets/EY-the-new-age-artificial-intelligence-for-human-resource-opportunities-and-functions/$FILE/EY-the-new-age-artificial-intelligence-for-human-resource-opportunities-and-functions.pdf

KPMG, 2019. *The future of HR 2019: In the Know or in the No*. https://assets.kpmg/content/dam/kpmg/pl/pdf/2019/05/pl-Raport-KPMG-The-future-of-HR-2019-In-the-Know-or-in-the-No.pdf

The Economist, 2018. *Managing human resources is about to become easier*. https://www.economist.com/special-report/2018/03/28/managing-human-resources-is-about-to-become-easier

Blockchain

McKinsey, 2017. *Using blockchain to improve data management in the public sector.* https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/using-blockchain-to-improve-data-management-in-the-public-sector