



Operačný program
**Efektívna
verejná správa**



Európska únia
Európsky sociálny fond



MINISTERSTVO
INVESTÍCIÍ, REGIONÁLNEHO ROZVOJA
A INFORMATIZÁCIE
SLOVENSKEJ REPUBLIKY

Výstup č. 4.1.1

Vytvorenie príručky: Regulácie 2.0

Zmluva o dielo č. 445/2022

Projekt:

Zlepšenie využívania údajov vo verejnej správe

ITMS kód projektu:

314011S979

Tento projekt je podporený z Európskeho sociálneho fondu.

Obsah

1	Úvod a zhrnutie	5
1.1	Kontext	5
1.2	Štruktúra výstupu	5
1.3	Manažérske zhrnutie	6
2	Východiská.....	9
2.1	Kde sa môžeme dostať.....	9
2.2	Kapacity verejnej správy.....	14
2.2.1	Funkčný pohľad na inštitúciu verejnej správy.....	14
2.2.2	Kapacity vo verejnej správe	15
2.2.3	Kapacita poskytovať služby.....	15
2.2.4	Koordináčna kapacita.....	16
2.2.5	Analytická kapacita.....	16
2.2.6	Regulačná kapacita.....	16
2.3	Prístupy k regulácii.....	17
3	Koncept Regulácie 2.0	21
3.1	Nové pohľady na regulačnú kapacitu	21
3.2	Algoritmická regulácia	24
3.2.1	Definícia algoritmickej regulácie.....	24
3.2.2	Formy algoritmickej regulácie.....	25
3.2.3	Čo prináša algoritmická regulácia	28
3.2.4	Limity a riziká algoritmickej regulácie.....	28
3.3	Zavedenie systému algoritmickej regulácie.....	30
3.3.1	Základné otázky.....	30
3.3.2	Výber vhodných dát	31
3.3.3	Budovanie vhodného modelu regulácie	31
3.3.4	Hodnotenie modelu regulácie.....	32
3.3.5	Implementácia algoritmickej regulácie.....	33
3.3.6	Zhrnutie a záverečné odporúčania	34
4	Návody.....	37
4.1	Posudzovanie vplyvov regulácií pomocou veľkých dát.....	37
4.1.1	Úvod	37
4.1.2	Vízia	38
4.1.3	Transformácia.....	39
4.1.4	Najlepšia prax.....	40
4.1.5	Obmedzenia a problémy.....	41
4.2	Lepší dozor a dohľad nad regulovaním prostredím	42
4.2.1	Úvod	42
4.2.2	Vízia	43
4.2.3	Transformácia.....	44
4.2.4	Najlepšia prax.....	46
4.2.5	Obmedzenia a problémy.....	47
4.3	Inovácie procesov	47
4.3.1	Úvod	48

4.3.2	Vízia	48
4.3.3	Transformácia.....	49
4.3.4	Najlepšia prax.....	50
4.3.5	Obmedzenia a problémy.....	51
5	Agendy.....	53
5.1	Rozhodovacie procesy	53
5.1.1	Obsluha klientov a poskytovanie služieb	53
5.1.2	Vydávanie rozhodnutí v rámci konania (správneho, súdneho)	53
5.1.3	Kontrolná činnosť a štátny dohľad a dozor.....	54
5.1.4	Operatívna alokácia zdrojov.....	56
5.1.5	Plánovanie a predvídanie budúceho dopytu	56
5.2	Návrh konkrétnych riešení pre vybrané agendy	57
5.3	Procesy manažmentu údajov	66
5.3.1	Prioritizácia a zber požiadaviek.....	66
5.3.2	Zber a spracovanie údajov	67
5.3.3	Zdieľanie údajov.....	68
5.3.4	Rozhodovanie na základe údajov.....	68
5.3.5	Tvorba analytických výstupov.....	71
5.3.6	Testovanie dopadov a efektivity politík.....	73
5.3.7	Publikovanie údajov: otvorené údaje a vizualizácia	73
6	Riešenie.....	77
6.1	Dátová fabrika.....	77
6.1.1	Koncept dátovej fabriky	77
6.1.2	Realizácia dátovej fabriky.....	78
6.1.3	Konsolidovaná analytická vrstva	79
6.2	Experimentálny priestor pre dátovú vedu.....	79
6.2.1	Experimentálna organizácia	79
6.2.2	Metódy dátovej vedy	80
6.3	Algoritmy.....	83
6.3.1	Prehľad metód a aplikácií umelej inteligencie	83
6.3.2	Použitie predikčných modelov	86
6.3.3	Použitie klasifikačných modelov	88
6.3.4	Realizácia štrukturovaných digitalizovaných úloh	90
6.3.5	Manipulácia z informáciami.....	92
6.4	Nástroje.....	92
6.4.1	Požiadavky na nástroje.....	93
6.4.2	Kolaboratívne vysoko výkonné nástroje pre analytikov a doménových expertov	94
6.4.3	Prehľad nástrojov a ich funkcionalít, ktoré sú dostupné v BI.	95
6.5	Dáta, dátové zdroje a výstupy.....	97
6.5.1	Výstupy - Dashboardy	100
7	Transformácia.....	104
7.1	Tvorba analytických modelov.....	108
7.2	Tvorba modelov rozhodovania.....	109
7.2.1	Dekompozícia pracovného postupu	110
7.2.2	Modely rozhodovania	111
7.2.3	Rámec pre zlepšenie rozhodovania	112
8	Manažment zmeny.....	115

8.1	Organizácia založená na údajoch	115
8.2	Organizačné zmeny.....	116
8.2.1	Návrh politík a regulácií.....	117
8.2.2	Implementácia zmien a dynamické riadenie	118
8.2.3	Prevádzka a výkon agendy	119
9	<i>Použitá literatúra.....</i>	121

1 Úvod a zhrnutie

1.1 Kontext

Dokument **Vytvorenie príručky: Regulácie 2.0** je aktualizáciou príručky pre inštitúcie verejnej správy, akým spôsobom zlepšiť rozhodovanie prostredníctvom analytického spracovania údajov a využitia metód „Regulácie 2.0“ a nástrojov umelej inteligencie.

Dokument bol pripravený v rámci projektu „Zlepšenie využívania údajov vo verejnej správe“. Tento projekt má ambíciu transformovať fungovanie inštitúcií verejnej správy tak, aby dokázali maximálne efektívne spravovať a zdieľať údaje, využívať údaje pre lepšie rozhodovanie na základe faktov a dôkazov, pre zlepšenie efektivity a adresnosti služieb na základe lepšieho využívania dát.

Projekt Zlepšenie využívania údajov vo verejnej správe realizuje Dátová kancelária verejnej správy ako špeciálna jednotka Ministerstva investícií, regionálneho rozvoja a informatizácie (ďalej aj MIRRI).

V rámci výstupu je navrhnutý rámec pre aplikáciu rozhodovacích modelov/AI, vybrané vhodné oblasti pre inováciu v prostredí verejnej správy. Súčasťou aj navrhovaný manažment zmeny: akými technikami a postupmi by mali verejné inštitúcie nasadiť Regulácie 2.0, tak aby sa dosiahli želané výsledky, adresovali predpokladané problémy a mitigovali identifikované riziká.

Výstup vznikol ako realizácia aktivity číslo 4 Podpora zavádzania analytického spracovania údajov a činnosti „Aktualizácia príručky pre inštitúcie verejnej správy, akým spôsobom zlepšiť rozhodovanie prostredníctvom analytického spracovania údajov a využitia metód „Regulácie 2.0“ a nástrojov umelej inteligencie“.

Ambíciou Dátovej kancelárie verejnej správy je spustiť implementáciu konceptu „Data-driven state“ (teda štátu, ktorý funguje na základe využívania dát) do praxe v podmienkach verejnej správy na Slovensku. Zámer si vyžaduje výrazne zlepšenie využívania a spracovania údajov na analytické účely inštitúciami verejnej správy. Štát bude prijímať rozhodnutia na základe najlepších znalostí, ktoré sú k dispozícii. Takáto transformácia si vyžaduje nastavenie riadenia životného cyklu dát a zmenu spôsobu rozhodovania. Je potrebné zabezpečiť, aby inštitúcie vedeli, ako reálne používať údaje a tiež, aby rozhodovanie na základe údajov bolo možné (a kde sa dá i automatizované).

1.2 Štruktúra výstupu

Tabuľka 1: Prehľad štruktúry výstupu

Kapitola	Požiadavka
Kapitola 2 Východiská	
Kapitola 3 Koncept Regulácie 2.0	— aktualizácia konceptu pre Regulácie 2.0,
Kapitola 4 Návod	— aktualizácia príručiek a návodov
Kapitola 5 Agendy	— výber agend pre Regulácie 2.0 — návrh konkrétnych riešení pre vybrané agendy — návrh postupov ako bude agenda fungovať
Kapitola 6 Riešenie	— výber a implementácia vhodných dátových modelov pre Regulácie 2.0

Kapitola	Požiadavka
Kapitola 7 Transformácia	— návrh postupu transformácie
Kapitola 8 Manažment zmeny	— popis manažmentu zmeny

1.3 Manažérske zhrnutie

Nová paradigma

V 21. storočí môžeme byť vďaka technologickému vývoju svedkami vzniku nového typu verejných inštitúcií, ktoré sú digitálne, inteligentné a prispôsobivé. Ich hlavnou úlohou je zabezpečiť efektívne a spravodlivé fungovanie spoločnosti prostredníctvom využitia umelej inteligencie a digitálnych nástrojov. Vďaka nim sa otvárajú nové možnosti pre rýchlejšie rozhodovanie, lepšiu predikciu a väčšiu transparentnosť v regulačnej kapacite štátu. Je dôležité, aby sme využili tento potenciál a smerovali k moderným, agilným a inteligentným verejným inštitúciám, ktoré sú schopné účinne reagovať na potreby a výzvy 21. storočia.

Zlepšiť rozhodovanie pomocou dát je pomerne komplikovanou misiou, ktorá si vyžaduje úzku a odbornú spoluprácu ľudí s rôznymi zručnosťami: odborníkov na danú agendu, ktorí disponujú znalosťami o vplyve rôznych faktorov na výsledok opatrení, dátových vedcov, ktorí vedú pracovať s komplexnými dátami a najnovšími algoritmi strojového učenia, ale aj špecialistov na dátovú a IT architektúru, ktorí celú snahu vedú podporiť tými najmodernejšími nástrojmi a infraštruktúrou. Zefektívnenie rozhodovania tiež nie je jednorazový projekt, ale ide o zmenu kultúry, ktorá podporuje hľadanie stále nových oblastí, v ktorých by mohlo nastať zlepšenie pomocou využívania dát, experimentovanie s rôznymi prístupmi, a neustále zlepšovanie riešení zavedených do praxe. Až po desiatkach úspešných projektov v oblasti lepšieho rozhodovania si organizácia dokáže vybudovať dostatočnú databázu znalostí a skúseností, aby vedela priniesť aj tú spomínanú dávku „umeleckého remesla“ pri hľadaní riešení na nové problémy, o ktoré sa ešte nik predtým nepokúsil.

Regulácie 2.0

Algoritmická regulácia má potenciál byť oveľa efektívnejším nástrojom ako akékoľvek iné spôsoby regulácie, a to za predpokladu, že sa v procese ich prípravy a používania regulátor vyhne rizikám spojeným s takýmto typom regulácie.

Systémový a legislatívny rámec fungovania inštitúcií verejnej správy je potrebné prispôbiť požiadavkám 21. storočia. Koncepty založené na procedúrach, hierarchickej organizácii, dodržiavaní predpisov a vyhlášok a na zbieraní informácií do spisov je možné modernizovať spôsobom, aby umožnili lepšie fungovať v čase, keď máme informácií nadbytok a keď dokážeme vyhodnocovať kvalitu determinantov ovplyvňujúcich zdravie v reálnom čase.

Sumár najdôležitejších lekcií vychádzajúcich z uskutočnených štúdií vývoja, implementácie a prevádzky systémov algoritmických regulácií:

1. Niektoré zásadné rozhodnutia ohľadom algoritmickkej regulácie by mali byť určite urobené na politickej úrovni, ktorá by mala niesť za tieto rozhodnutia zodpovednosť vzhľadom na nastavenie demokratických inštitúcií. Tieto politické rozhodnutie by mali najmä určiť hranice regulácie, jej intenzitu a ciele.
2. Je životne dôležité, aby sa na vývoji a implementácii podieľali multidisciplinárne tímy zložené z odborníkov na všetky relevantné oblasti. Toto je možno najväčšia výzva, ale bez intenzívnej spolupráce rôznorodých expertov nie možné vytvoriť systém, ktorý má regulovať, navyše

pomocou technológie, komplexné oblasti života spoločnosti tak, aby systém garantoval minimalizáciu vedľajších škôd.

3. Je treba mať na mysli, že rozhodnutia o uvedení algoritmickej regulácie do praxe a jej regulácii majú dynamický charakter. Vývoj systému sa uskutočňuje na základe tréningových dát pochádzajúcich z minulosti rovnako ako spoločnosť a kontext, ktorý sa spustením systému stáva minulým. Túto dynamiku je potrebné implementovať do spravovacích a kontrolných mechanizmov, aby sa systém vyvíjal spolu so spoločnosťou, ktorej časť má regulovať a kontextom, v ktorom sa nachádza.

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 Bolt); od platforiem, ktoré sprostredkovávajú ubytovanie (AirBnB) alebo napríklad od utility 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 so 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).

Koncepčným riešením je zmena operačného modelu inštitúcie na dátovú fabriku

Dátová fabrika predstavuje subjekt, ktorý integruje údaje v rámci určitej entity, pričom táto integrácia umožní vytvárať na dátach založené pracovné toky pre organizovanie pohybu dát vo fungovaní. V prípade entít verejnej správy predstavuje dátová fabrika nástroj, ako transformovať procesy a ich realizáciu tak, že sa dáta a ich spracovanie dostanú do centra všetkých procesov v rámci inštitúcie verejnej správy.

Pre vytvorenie a fungovanie dátovej/AI fabriky sú nevyhnutné štyri komponenty:

- Data pipeline: Tento proces zhromažďuje, vstupuje, čistí, integruje, spracováva a zabezpečuje údaje systematickým, udržateľným a škálovateľným spôsobom
- Experimentálny priestor: Ide o mechanizmus, prostredníctvom ktorého sa testujú hypotézy týkajúce sa nových predikčných a rozhodovacích algoritmov, aby sa zabezpečilo, že navrhované zmeny majú zamýšľaný (príčinný) účinok.

-
- Vývoj algoritmov: Algoritmy generujú predikcie o budúcich stavoch alebo akciách pre verejnú inštitúciu. Tieto algoritmy a predikcie sú srdcom digitálnej organizácie a riadia jej najdôležitejšie činnosti.
 - Softvérová infraštruktúra: nástroje KAV a zabezpečenie prepojenie KAV a agendových systémov.

Inštitúcia verejnej správy, ktorá by sa zmenila na dátovú fabriku, prípadne AI fabriku, by tým pádom výraznou mierou zjednodušila a zefektívnila svoje každodenné interné aktivity a procesy a zároveň zlepšila, zmodernizovala a skvalitnila svoje externé výstupy a služby smerom k občanom. Štátni zamestnanci by boli odbremenení od mnohých (častokrát automatických a nudných) úloh, ktoré by na seba prebrali algoritmy a technológie a namiesto nich by sa mohli venovať dôležitejším a zaujímavejším aktivitám.

Cieľom je skutočná digitálna transformácia

Transformácia na organizáciu založenú na údajoch je proces, ktorý si vyžaduje kultúrnu zmenu a odlišné myslenie, čo sa nedá dosiahnuť zo dňa na deň. Zahŕňa prispôbenie sa novým technológiám, procesom a pracovným postupom, čo si vyžaduje čas a úsilie. Organizácie založené na údajoch si uvedomujú, že úspech sa dosahuje iteratívne a zameriavajú sa na dlhodobé hľadisko.

Odporúčame nasledujúce zmeny modernizácie organizačnej štruktúry:

- Odborné sekcie by mali byť orientované na riešenie problémov a hľadanie agilných riešení. V praxi to znamená posun výkonu verejnej moci smerom k regulácií 2.0, teda sledovanie merateľných ukazovateľov v online čase a zmenu s tým súvisiacich postupov na metodologickej úrovni.
- Odporúčame vytvoriť analytickú jednotku. Takéto jednotky sú už takmer na všetkých ministerstvách a ukazuje sa, že sú kľúčové pre správny návrh politík a stratégií. Ide však len o prvý krok. Funkčnú analytickú jednotku je vhodné doplniť implementačnou jednotkou (takzvaná "Delivery unit") pre zabezpečenie vhodnej a včasnej realizácie navrhnutých opatrení a politík a inovačnou jednotkou, ktorá dokáže realizovať experimenty v praxi a zistiť, čo naozaj funguje a prečo. Verejná správa tak môže prejsť od ideologického návrhu politík k pragmatickejšiemu a empirickejšiemu prístupu.
- Pre manažment dátovej transformácie je nutné posilniť schopnosti v oblasti dát, ideálne keď vznikne interná dátová kancelária s jasne definovanou a silnou rolou CDO - "Chief Data Officer". Dátová kancelária by mala manažovať transformáciu jednotlivých procesov pomocou podpory dátovými nástrojmi, ale i zabezpečenie samotných dát, ktoré sú palivom. Dátová kancelária tak bude poskytovať riešenia na mieru ostatným organizačným útvarom.

2 Východiská

2.1 Kde sa môžeme dostať

Digitálna transformácia vo verejnej správe

V 21. storočí sme svedkami revolučných zmien v spôsobe, akým verejné inštitúcie fungujú a interagujú so spoločnosťou. Digitálna transformácia preniká do každého aspektu verejnej správy a prináša so sebou nové možnosti a výzvy. Jedným z hlavných pilierov tejto transformácie je využitie umelej inteligencie v regulačnej kapacite štátu.

Umeľá inteligencia ponúka nespočetné možnosti pre efektívnejšie a presnejšie vykonávanie regulačných úloh. Je schopná analyzovať obrovské množstvo dát a identifikovať vzory a tendencie, ktoré by boli pre ľudského analytika ťažko odhaliteľné. To umožňuje lepšie monitorovanie, predikciu a prevenciu rizík a nezrovnalostí v rámci verejnej správy.

Digitálna transformácia vytvára aj nové formy interakcie medzi verejnými inštitúciami a občanmi. S využitím umelej inteligencie je možné implementovať chatboty a virtuálne asistentov, ktorí sú schopní poskytovať rýchlu a presnú odpoveď na otázky a problémy občanov. Týmto spôsobom sa zlepšuje prístup k informáciám a zjednodušuje komunikácia medzi verejnými inštitúciami a občanmi.

Verejné inštitúcie sa v 21. storočí transformujú do digitálnych entít, ktoré sú agilné, prístupné a efektívne. Umeľej inteligencii a automatizácii je pridávaná väčšia dôležitosť, aby sa zvýšila kapacita týchto inštitúcií vykonávať svoje regulačné úlohy. To však neznamená, že ľudský faktor je úplne vytlačený. Skôr ide o synergický prístup, kde umeleá inteligencia podporuje a posilňuje ľudské rozhodovanie a schopnosti.

Zároveň je však potrebné, aby digitálna transformácia a využitie umelej inteligencie v regulačnej kapacite štátu prebiehali s primeranou mierou transparentnosti, zodpovednosti a ochrany údajov. Dôvera občanov je nevyhnutná pre úspešné fungovanie týchto nových modelov verejných inštitúcií.

Orientácia na výsledky

Každodenný život súčasných politikov a verejných zamestnancov nie je ľahký. Vedúci predstavitelia verejných inštitúcií sedia medzi dvomi stoličkami - na jednej strane si môžeme predstaviť pohodlie minulej stabilnej éry, keď vládne inštitúcie boli hlavne "strážcami brán", správcami kníh, registrov, evidencií a archívov a distribútormi zdrojov. Na strane druhej, v dnešnej dobe je možné sledovať čím ďalej väčší tlak na lídrov vo verejnej službe, aby sa stali tvorivými, agilnými a odvážnymi experimentátormi, aby tak mohli zostať v tejto novej dynamickej digitálnej ére relevantnými. Okrem toho sú zamestnanci vo verejnej správe veľmi dobre vybavený a vyškolený na reguláciu a optimalizáciu procesov, ale nie sú tak dobre pripravený na digitálnu transformáciu organizácií a na inováciu. Občania požadujú riešenie svojich problémov a rýchle opravy v súlade s možnosťami globálnej ekonomiky. Inštitúcia verejnej správy, ktorá chce uspieť, nemá inú možnosť, než aby sa pokúsila o transformáciu. Ak chce ministerstvo inovovať, dobrou praxou je vytvoriť špecializované tímy mimo riadnych organizačných štruktúr s pracovným prostredím bližšie k jednému v inovatívnej agilnej spoločnosti.

Moderná inštitúcia verejnej správy, ktorá je orientovaná na výsledky, musí prijať potrebné reformy poháňané dátovými a digitálnymi technológiami. Inštitúcia orientovaná na výsledky je flexibilná organizácia s vhodnou stratégiou na dosiahnutie výsledkov a sofistikovanými opatreniami na monitorovanie pokroku pri dosahovaní cieľov. Inštitúcia verejnej správy, ktorá je orientovaná na výsledky môže účinne premeniť svoju kapacitu (celkové zdroje ľudí a peňazí) na výkon, čo znamená, že dokáže svoje úlohy vykonávať aj na základe veľmi obmedzenej kapacity.

Prostriedky na dosiahnutie cieľov

Prístup reformy smerom k organizácii orientovanej na výsledky začína vypracovaním koncepčného dokumentu o reforme (napríklad reformný zámer), ktorý zdôrazňuje súčasné problémy organizácie, hlavné ciele SMART, ktoré chce dosiahnuť s definovanou organizačnou štruktúrou, ako aj základné prostriedky na dosiahnutie cieľov. Prostriedky na dosiahnutie cieľov môžu byť:

- Budovanie kapacít,
- Nová politika alebo program,
- Nové alebo upravené predpisy s konečným cieľom modernizovať regulačný rámec,
- Nové alebo vylepšené interné podnikové procesy vrátane rozhodovania na základe dôkazov,
- Posilnenie postavenia štátnych zamestnancov s väčšou nezávislosťou, technikami riešenia problémov a vysoko kvalitnými a ľahko prístupnými údajmi,
- Nové alebo vylepšené služby pre podniky alebo občanov,
- Prijatie koherentnej IT stratégie, ktorá umožní vláde dosiahnuť vyššie uvedené ciele.

Neexistuje jeden štandardizovaný postupný prístup, ktorý by fungoval pre každú vládnu inštitúciu, ak sa má dosiahnuť skutočná transformácia prostredníctvom digitalizácie. Prístup a výsledky musia byť prispôbené konkrétnej vládnej inštitúcii a jej súčasnému stavu rozvoja a potrieb. V tomto dokumente sa však budeme sústreďovať na budovanie kapacít v oblasti kľúčových schopností (postavených na politike a stratégii, plánovaní, realizácii a monitorovaní) a podporných služieb, ktoré sa často implementujú ako zdieľané služby (o ktorých sa bude diskutovať neskôr). Budeme tiež diskutovať o tom, ako môže byť budovanie kapacít podporované IT systémami a riešeniami, ktoré prinášajú hmatateľnú pridanú hodnotu.

Umelá inteligencia dokáže pomôcť s vytvorením inteligentnej organizácie

Pokrok v oblasti strojového učenia a čoraz inteligentnejšie algoritmy menia množstvo sektorov bezprecedentnou rýchlosťou. Inteligentné stroje poháňané údajmi už porazili ľudí v hrách, ako sú šach, poker a „go“. Pracovné miesta, ktoré zahŕňajú prispôbenie vzorov, rozhodovanie a dodržiavanie pravidiel - od zákazníckych služieb až po lekársku diagnózu - budú čoraz viac vykonávať umelá inteligencia. Doprava bude v našich mestách transformovaná spoločnými fondmi samo poháňaných prepojených vozidiel. Zavedením inteligentných zdravotných asistentov sa zdravotná starostlivosť posunie smerom k personalizovanému riadeniu verejného blaha. Školy zavedú učebné osnovy šité na mieru.

Aj Inštitúcie verejnej správy by sa nemali báť personalizovať svoje digitálne služby pomocou osobných údajov. Musia sa naučiť lepšie využívať údaje pre lepšie politiky, nariadenia a rozhodovanie. Schopnosť ministerstva financií inovovať finančné trhy a vyriešiť ich naliehavé problémy sa zvýši pomocou strojového učenia, ktoré robí podrobnejšie a spoľahlivejšie predpovede o budúcnosti.

Použitie algoritmov vo verejnej správe

V súčasnosti sa algoritmy stávajú stále dôležitejším nástrojom v oblasti verejnej správy, a to nielen pre svoju schopnosť efektívne riadiť a regulovať spoločnosť, ale aj pre ich potenciál prinášať radikálne zmeny vo fungovaní verejných inštitúcií. Využitie algoritmov v regulácii vo verejnej správe prináša nové možnosti a výzvy, ktoré treba preskúmať a porozumieť.

Koncept algoritmického rozhodovania sa využíva v rámci algoritmických regulácií, kde "algoritmické rozhodovanie" znamená využitie algoritmicky generovaných systémov na vykonávanie alebo informovanie rozhodnutí. Aj keď rozsah a význam pojmov "regulácia" a "regulačné riadenie" sú predmetom diskusií, v tomto článku prijímame široké chápanie regulácie ako úmyselného pokusu riadiť

riziká alebo meniť správanie s cieľom dosiahnuť preddefinovaný cieľ. Pretože regulácia je realizovaná ako štátnymi, ale aj nestátnymi aktérmi a organizáciami, algoritmická regulácia je neoddeliteľnou súčasťou tohto procesu.

Algoritmická regulácia prináša niektoré skutočne nové prvky, ktoré sú predmetom skúmania v tejto téme. Jedným z nich je strojové učenie prostredníctvom vysokorychlostného a distribuovaného spracovania informácií, ktoré umožňuje klasifikáciu a odporúčanie systémov a je často používané na profilovanie jednotlivcov s cieľom výpočtovo identifikovať a vyhodnotiť ich osobnostné vlastnosti, záujmy, preferencie a priority v závislosti na vzoroch dát, a nie na základe podliehajúceho kauzálneho odôvodňovania. Zatiaľ čo procesy triedenia, klasifikácie a hodnotenia nie sú nič nové, kvantitatívne a kvalitatívne zmeny v rýchlosti a potenciálnej vzdialenosti medzi tým, kto triedi, a tým, kto je triedený, predstavujú kvalitatívnu zmenu.

Administratívne údaje, teda údaje získané alebo zhromaždené verejnými orgánmi pre účely registrácie, transakcií a záznamov, dlho ponúkajú možnosti pre lepšie porozumenie spoločenských vzorcov, trendov a dopadov politík, ako aj na vývoj inovatívnych produktov a služieb. V súčasnosti sa uplatňuje snaha využiť administratívne údaje na vytváranie modelov s cieľom pomáhať pri každodenných rozhodnutiach a operáciách.

Tieto nové operačné modely sú navrhnuté tak, aby slúžili ako podpora rozhodovania alebo dokonca spúšťali automatické akcie. Systavy sú postavené predovšetkým na technikách strojového učenia: algoritmy, ktoré sa snažia identifikovať vzory v dátových súboroch a spracovať ich do použiteľnej formy.

Dôležité je skúmať, ako sa rozhodnutia a praktiky vedenia verejnej správy na rôznych úrovniach uplatňujú, keď sú implementované riešenia strojového učenia v verejnom sektore. Skúmanie a hodnotenie strojového učenia v verejnom sektore zahŕňa mapovanie, analýzu a hodnotenie toho, ako je strojové učenie vo verejnom sektore rámcovo a štandardizovalo vo vláde s ohľadom na nezamýšľané dôsledky (makroúroveň), ako je navrhované a monitorované v súvislosti s politickými iniciatívami a existujúcimi meraniami výkonnosti verejnej správy, riadenia a mechanizmov hodnotenia rizík (mesoúroveň) a ako je implementované v každodenných praktikách poskytovateľov verejných služieb na prednej čiare (mikroúroveň).

Automatizačné systémy sa snažia zvýšiť množstvo alebo efektivitu rutinných činností v verejnom sektore prostredníctvom výpočtu. Strojové učenie sa tu využíva na umožnenie automatizácie úloh, ktoré majú komplikované prvky, ale zároveň majú jednoduchý a relatívne objektívny výsledok, ako napríklad triedenie telefonátov alebo korešpondencie na správne kontaktné miesta.

Nové technológie, ako napríklad robotická procesná automatizácia, ešte viac zlepšili integráciu prostredníctvom využitia výpočtových techník na automatické pripájanie systémov, ktoré sa prirodzene nespriacujú spolu. Podobne strojové učenie poskytuje vylepšené nástroje, ako napríklad preklad, rozpoznávanie obrazu alebo písania, ktoré je možné "zapojiť" do reťazcov automatizácie pre jednoduché úlohy.

Je však potrebné zdôrazniť, že mnohé administratívne úlohy nie sú jednoduché a ľahko definovateľné. Operatívni rozhodcovia v verejnom sektore sa často stretávajú s úlohami, ktoré sa na prvý pohľad môžu zdať rutinné a "objektívne", no po bližšom preskúmaní obsahujú vysoko subjektívne a politické aspekty. Niektorí výskumníci historicky upozorňovali na podskupinu úloh, ktoré sa preto snažia odolať automatizácii.

Automatizačné systémy vždy prinášajú politizované prvky do verejného sektora, od podpory presunu zodpovednosti a vyhýbania sa viny, cez zvýšenú rigiditu pravidiel, až po druhy prípadov, na ktoré tieto systémy zlyhávajú. Zároveň slúžia na uprednostňovanie niektorých verejných hodnôt, ako je konzistencia a efektivnosť, pred inými.

Nepoľahnutie na tom, že strojové učenie iba lacno a rýchlo uľahčuje rozhodovanie, ale môže ho aj zlepšiť. Akým spôsobom sa rozhodnutie zlepšuje? Je užitočné sa odvolať na definíciu strojového učenia: hovoríme, že stroj sa učí, keď jeho výkon pri určitej úlohe sa zlepšuje s naberaním skúseností. V tomto prípade sú výkon, úloha a skúsenosť zachytené prostredníctvom údajov, ktoré sú určené dizajnéromi. Zlepšenie alebo učenie je možné diskutovať len vtedy, ak sú tieto tri oblasti aspoň presne

implementované. Aby sa to dosiahlo, je potrebné, aby ciele politik boli kvantifikovateľné a kvantifikované, čo je samotnou úlohou plnou hodnôt.

Podstatou analytických kapacít algoritmických systémov je možnosť využívať údaje na zistenie poznatkov, ktoré by verejné orgány nevedeli inak odvodiť. Predstavuje to určité riziká v oblasti nedôverovania, ale výhody spočívajú v lepšom porozumení reálneho stavu vecí, ktoré sú nevyhnutné pre ich riadenie.

Pri implementácii algoritmov vo verejnej správe je nevyhnutné, aby sa využívali etické normy a princípy, aby sa minimalizovali nežiaduce dôsledky a zabezpečila sa spravodlivá a transparentná správa. Dôležité je zabezpečiť prístup k údajom a algoritmom, ktorý umožňuje kontrolovať a overovať ich fungovanie.

Dokáže umelá inteligencia zmeniť prácu úradníkov?

Pri úvahe o dopade zavádzania nových technológií na pracovnú činnosť v rámci inštitúcie 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 2: Prehľad schopností a výhod¹

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
		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.

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

Tabuľka 3: Typy úloh pracovníkov²

Rozdelenie	Typ úlohy	Popis
Repetitívna alebo Variabilná	Repetitívna	Práca je predikovateľná, rutinná, a určená na základe jasných pravidiel. Veľká časť úradníckych postupov, najmä v správnom konaní a pri vybavovaní žiadostí je repetitívna. Repetitívna 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 prispôbiť 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 na 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.

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

2.2 Kapacity verejnej správy

2.2.1 Funkčný pohľad na inštitúciu verejnej správy

Za základné funkcie inštitúcie verejnej správy, ktorá sa zaoberá digitálnou transformáciou považujeme:

- **Návrh politik a regulácií:** formulácia jasnej a zrozumiteľnej vízie, vrátane strategických cieľov a merateľných ukazovateľov. Návrh politik, regulácií, legislatívy a štandardov; ktoré sú orientované na riešenie problémov organizácie.
- **Implementácia:** agilné tímy zodpovedné za dosahovanie nastavených cieľov, koordinujú projekty a ich výstupy.
- **Monitorovanie výsledkov:** monitorovanie stavu jednotlivých oblastí a kľúčových merateľných ukazovateľov. Kontinuálne zlepšovanie služieb a optimalizácia nákladov.

Návrh politik a regulácií

V rámci definície politik musí inštitúcia v prvom rade vybudovať vynikajúce analytické schopnosti, aby mohla formulovať dôležité aspekty mechanizmov v zodpovednosti danej inštitúcie. Musí tiež vychádzať z predpovedania dopadov politik s využitím predchádzajúcich skúseností a údajov, ale aj moderných analytických modelov a nástrojov.

Z hľadiska stratégie a politiky je odvodená regulačná spôsobilosť - je to schopnosť kontrolovať produkciu konkrétnych služieb poskytovaných inými. Napríklad ministerstvo financií vykonáva dohľad nad štátnymi podnikmi a finančnými trhmi, ale v širšom zmysle sa regulácia uplatňuje aj vtedy, keď ministerstvo financií stanovuje finančný rámec.

Realizácia zmien a poskytovania služieb

Väčšina inštitúcií verejnej správy poskytujú istý typ verejných služieb. Je preto možné nastaviť rámec sledovania výkonnosti týchto služieb a porovnávať kvalitu výstupov. Dobre fungujúca organizácia dokáže efektívne realizovať nastavené politiky a zavádzať nové služby na základe zmenených politik, ako i kontinuálne zlepšovať existujúce služby.

Napríklad Ministerstvo financií síce priamo neposkytuje verejné služby, ale každý rok vytvára súbor kľúčových cieľov, najmä úplný rozpočet podľa osobitného kalendára. Existuje aj viac administratívnych úloh, ako je výber daní vo forme rôznych daní a cieľ a riadenie hotovosti, riadenie verejného dlhu a štátnej pokladnice, regulácia ekonomiky a ekonomických činností, správa verejných statkov, dohľad nad štátnymi podnikmi a medzinárodná ekonomická správa. spolupráca, ktorá sa v podstate spolieha na schopnosť produkovať určité výstupy - a často aj financovanie - naprieč vládou. Aj tu je schopnosť organizovať činnosti rôznych aktérov v snahe o dosiahnutie spoločného cieľa. Koordinácia je kritickej schopnosťou ministerstva financií - široká škála politických a realizačných aktivít sa môže spojiť len vtedy, ak ministerstvo financií dokáže zhromažďovať a využívať odborné vstupy od iných ministerstiev a orgánov, ako aj mimovládnych subjektov. Najlepším príkladom je opäť stanovenie fiškálnej politiky, ktorá vyvrcholí tvorbou ročného rozpočtu.

Monitoring výsledkov a kontrola

Monitorovacie schopnosti musia kontrolovať výkonnosť a dosahovanie výsledkov a výsledkov pre samotnú inštitúciu, ako aj pre iné subjekty, ktorých pôsobenie spadá do kompetencie inštitúcie. Monitorovanie veľmi často vykonávajú čiastočne alebo úplne nezávislé subjekty - napríklad analytické jednotky, ktorá dohliadajú na dôkazy odvodené z údajov, alebo kontrolujú, či realizované politiky fungujú. Ďalšou potrebnou kapacitou je možnosť generovať spätnú väzbu na dôkazy z monitorovania k lepšej tvorbe politiky založenej na dôkazoch, a tým uzavrieť slučku neustáleho zlepšovania.

2.2.2 Kapacity vo verejnej správe

V súčasnej dobe sa venuje značná pozornosť inováciám procesov a politik. Oveľa menší záujem sa upriamil na druh kapacít, ktoré sú potrebné na spustenie a udržanie konkrétnych typov inovácií. Táto kapitola sa zaoberá štyrmi typmi kapacity verejnej správy, ktoré sú kľúčové pre akýkoľvek pokus o riešenie problémov, a to kapacitou poskytovať služby, koordinovať, regulovať a analyzovať. Tieto kapacity môžu byť rôzne organizované, financované a personálne obsadené a budú sa líšiť podľa funkčných potrieb a dominancie konkrétnych politických cieľov nad ostatnými. Každá diskusia o kapacite verejnej správy musí brať do úvahy tieto štyri kapacity. Okrem toho si každá politická intervenčná stratégia alebo nástroj vyžaduje pochopenie požadovaných kapacít verejnej správy, ktoré umožnia, aby tieto nástroje dosiahli zamýšľaný účinok.

- **Kapacita poskytovať služby** (*Delivery capacity*): Táto kapacita sa týka schopnosti štátu účinne a efektívne poskytovať verejné služby a riešiť potreby občanov. Kapacita poskytovať služby sa prejavuje schopnosťou plánovať, implementovať a riadiť projekty a programy tak, aby boli dostupné a prístupné pre občanov. Zahrňuje aj schopnosť monitorovať a hodnotiť poskytovanie služieb a zlepšovať ich kvalitu.
- **Koordinačná kapacita** (*Coordination capacity*): Táto kapacita sa týka schopnosti štátu koordinovať rôzne inštitúcie, oddelenia a zainteresované strany s cieľom dosiahnuť synergický a súdržný prístup k riešeniu problémov. Koordinačná kapacita zahŕňa schopnosť vytvoriť spoluprácu a vzájomnú komunikáciu medzi rôznymi aktérmi a zabezpečiť, aby boli zdroje a úsilie efektívne a harmonicky využívané.
- **Regulačná kapacita** (*Regulatory capacity*): Táto kapacita sa vzťahuje na schopnosť štátu vytvárať a uplatňovať pravidlá a normy prostredníctvom regulácie. Regulačná kapacita zahŕňa schopnosť stanoviť a presadzovať právne predpisy, ktoré upravujú rôzne aspekty spoločnosti, ako sú hospodárstvo, životné prostredie, sociálne zabezpečenie a podobne. Regulačná kapacita tiež zahŕňa schopnosť monitorovať a presadzovať dodržiavanie týchto noriem.
- **Analytická kapacita** (*Analytical capacity*): Táto kapacita sa týka schopnosti štátu zhromažďovať, analyzovať a využívať relevantné dáta a informácie na informované rozhodovanie. Analytická kapacita zahŕňa schopnosť využívať analytické nástroje a metódy na pochopenie problémov, vyhodnocovanie politik a predvídanie dôsledkov rozhodnutí. Je dôležitá pre vytváranie dôkazmi podporených politik a efektívne riadenie verejných zdrojov. Analytická kapacita tiež podporuje hodnotenie výkonnosti a monitorovanie účinnosti politik a programov.

2.2.3 Kapacita poskytovať služby

Kapacita poskytovať služby je definovaná ako schopnosť zabezpečiť, aby obyvateľstvo dostávalo služby, aby sa získavali príjmy do štátnej pokladnice a aby sa zachoval verejný poriadok. Problematika kapacity poskytovania služieb sa týka najmä úradníkov, ich zdrojoch a uplatňovania právomocí. Inými slovami, kapacita poskytovať služby nie je len o ľuďoch, ktorí skutočne vykonávajú prácu; Ide aj o zdroje, ktoré sa využívajú na zabezpečenie toho, aby sa určité služby zachovali aspoň vtedy, keď súkromní poskytovatelia zlyhajú alebo sa zistí, že chýbajú. V posledných rokoch sa zmenilo najmä postavenie úradníkov, vzhľadom na vzostup výkonnostného riadenia a iných BI nástrojov.

Dátovú vedu a pokročilé analýzy dát možno využiť na pomoc pri prijímaní efektívnejších a proaktívnejších rozhodnutí pre vládne služby a projekty. To siaha od zjednodušenia administratívnych postupov cez využitie automatizácie až po schopnosť vykonávať prediktívne analýzy pomocou strojového učenia na predpovedanie budúcich trendov a lepšie rozhodovanie o pridelovaní zdrojov a služieb. Techniky vedy o údajoch, ako je spracovanie prirodzeného jazyka, možno použiť na rýchlú analýzu veľkých objemov údajov s cieľom odhaliť poznatky a vzorce, ktoré možno použiť na zlepšenie poskytovania služieb. Umelá inteligencia sa môže použiť aj na zlepšenie presnosti predpovedí o poskytovaní služieb, ako je napríklad predpovedanie objemu ľudí využívajúcich služby alebo optimalizácia trás pre poskytovanie služieb. To umožňuje vládnym agentúram čo najefektívnejšie využívať svoje zdroje, čo im umožňuje čo najlepšie slúžiť svojim občanom.

2.2.4 Koordinačná kapacita

Veľká časť problémov vo VS vzniká najmä v dôsledku zlyhania komunikácie na strane úradov, a z ich neefektívnej koordinácie. Koordinačná kapacita presahuje organizáciu výkonnej moci a oblastí, v ktorých sa má uskutočňovať spoločné riadenie. Koordinačné kapacity sú navyše aj o kompetenciách jednotlivcov. Napríklad literatúra o vodcovstve sa čoraz viac zameriava na dôležitosť prekračovania hraníc, t. j. schopnosť jednotlivcov mať prístup k rôznym sociálnym systémom a spájať tieto rozptýlené a rozmanité formy odborných znalostí a skúseností. Stručne povedané, koordinačná kapacita nie je o schopnosti hierarchicky vnucovať spôsoby spolupráce, ale o nehierarchickej uľahčujúcej úlohe. Okrem toho koordinačná kapacita spočíva v individuálnych schopnostiach pôsobiť v rozptýlených systémoch, pokiaľ ide o to, aby sme boli považovaní za partnerov, ale aj aby sme boli schopní orientovať sa v zložitých otázkach, ktoré vznikajú pri sprostredkovaní konsenzu.

Dátová veda a pokročilé analýzy môžu pomôcť štátu v schopnosti koordinovať zamestnancov a spolupracovať s verejnosťou zefektívnením určitých procesov a poskytnutím prehľadov, ktoré zlepšujú rozhodovanie. Veda o údajoch môže pomôcť efektívnejšie analyzovať údaje o výkonnosti a identifikovať trendy. Umelá inteligencia môže poskytnúť hlbší prehľad o názoroch a správaní verejnosti, ako aj o rozpočtoch a procesoch plánovania. Automatizácia riadená AI môže navyše pomôcť s koordináciou úloh a plánovaním, čo v konečnom dôsledku vedie k zvýšeniu efektivity a spolupráce.

2.2.5 Analytická kapacita

Analytická kapacita sa venuje spôsobu, akým je štát informovaný o budúcich prognózach a súčasnom vývoji. Tradičné zdroje odborných znalostí v oblasti politiky, akými sú štátni úradníci, sú čoraz viac predmetom sporov. Výzvy pri organizovaní analytických kapacít vo výkonných vládach zahŕňajú potrebu priniesť do vlády rôzne zdroje odborných znalostí, zabezpečiť transparentnosť a legitimitu tvárou v tvár všeobecnému skepticizmu, pokiaľ ide o aplikáciu vedomostí, a rastúcej nedôvere voči tradičným zdrojom poradenstva, ako sú štátni úradníci. To viedlo k vzostupu odborných poradcov, think-tankov a poradenských spoločností, ktoré ponúkajú alternatívne zdroje informácií. Spôsob, akým je analytická kapacita organizovaná, financovaná, prístupná a šírená, je empirickou otázkou, ktorú je potrebné riešiť.

Vzostup alternatívnych zdrojov informácií ovplyvnil spôsob, akým vlády pristupujú k informáciám a spracovávajú ich. Hoci tieto zdroje ponúkajú alternatívne perspektívy a odborné znalosti, niektoré môžu mať väčší záujem o zabezpečenie znovuzvolenia ako o poskytovanie objektívnych rád. Dopyt po analytickej kapacite a politike založenej na dôkazoch však vyvoláva otázky, ako by mala byť takáto kapacita organizovaná, ako je financovaná a ako sa získavajú informácie a ako sa šíria.

Najpresvedčivejším riešením je riadiť sa údajmi a využívať zistenia extrahované z veľkých údajov na vytvorenie základu založeného na dôkazoch. Zainteresované strany verejného sektora potrebujú podporu, aby mohli využiť túto príležitosť. Dôkladná analýza neustále sa meniacich veľkých dát si vyžaduje citlivú informačnú a komunikačnú infraštruktúru a osvedčeného partnera, ktorý poskytuje rady a usmernenia.

2.2.6 Regulačná kapacita

Rozširovanie orgánov dohľadu viedol k vzostupu regulačnej kapacity štátu, ktorá v súčasnej dobe čelí výzvam:

- Internacionalizácia obchodných aktivít a zložitost' výrobných procesov urobili z regulácie podnikania kritickú súčasť konkurenčnej výhody štátov. Internacionalizácia obchodných aktivít však predstavuje aj výzvy pre regulačnú kapacitu štátu, najmä pokiaľ ide o problém záväzkov v regulácii a problém úradov pri kontrole regulovaných činností. Zložitost' výrobných procesov znižuje schopnosť odhaliť zdroje kontaminácie a vynútiť dohľad.
- Spôsob, akým možno regulované činnosti kontrolovať, sa stal v dôsledku zložitosti regulačného procesu.

-
- Problém udržania regulačných pracovníkov a odborných znalostí vo veku, keď je medzinárodný obchod schopný zlákať regulačných pracovníkov a keď majú regulačné orgány problém udržať si inštitucionálnu pamäť a odborné znalosti.
 - Inherentné rozptýlenie funkcií a kompetencií vyvolalo problémy, ktoré presahujú hranice, pokiaľ ide o to, ako rôzne regulačné orgány vykonávajú svoje úlohy.

Objavili sa tiež diskusie o vhodnej organizácii regulačných kapacít, ktoré zdôrazňovali dôležitosť nezávislosti, pričom často kontrastovali hodnotu nezávislosti s požiadavkou na väčšiu zodpovednosť. Regulačnú kapacitu ovplyvnila aj finančná kríza, ktorá vyvolala obavy z nezávislosti a samoregulácie. Kríza poukázala na to, že súkromné organizácie, ako napríklad banky, neboli schopné kontrolovať svoje veľmi zložité operácie. To viedlo k prehodnoteniu regulačných stratégií a potrebe lepšej regulácie vzhľadom na rastúcu zložitosť a rozptýlenie regulačných funkcií.

Dátová veda a pokročilé analýzy môžu byť použité na pomoc štátu lepšie monitorovať podniky a zabezpečiť súlad s nariadeniami. Umelá inteligencia môže byť použitá na odhalenie nezrovnalostí v správach, identifikáciu trendov v obchodných operáciách a odhalenie potenciálnych oblastí nesúladu. Dátovú vedu možno použiť aj na zlepšenie presnosti a účinnosti existujúcich predpisov, ako aj na poskytnutie potrebných informácií na navrhnutie nových regulačných politík.

2.3 Prístupy k regulácii

V dnešnom dynamickom svete je regulácia vo verejnej správe kľúčovým faktorom pre zabezpečenie spravodlivosti, bezpečnosti a efektívneho fungovania spoločnosti. Prístupy k regulácii sa však neustále menia a vyvíjajú, aby sa prispôbili novým výzvam a potrebám. Od tradičných modelov až po inovatívne a technologicky podporované riešenia, existuje mnoho spôsobov, ako regulovať a dohliadať na rôzne oblasti verejného života. Každý prístup má svoje výhody a obmedzenia, a preto je dôležité skúmať ich rôznorodosť a prispôbiť ich konkrétnym kontextom a potrebám verejnej správy. Od zákonodarcov po regulačné orgány a úradníkov, všetci majú úlohu v tvorbe a implementácii regulácie, ktorá je spravodlivá, transparentná a efektívna.

Regulácia založená na pravidlách

Prístup regulácie založenej na pravidlách (*Rule-based regulation*) sa zameriava na vytvorenie presných pravidiel, predpisov a noriem, ktoré subjekty musia dodržiavať. Súčasný trendy v oblasti regulácií 2.0 sa v tomto prístupe orientujú na poskytovanie nástrojov, ktoré regulačným orgánom umožňujú včasne reagovať a zabezpečiť, aby regulácie zostali relevantné a vyhovovali účelu. Príkladom sú **regulačné sandboxy**, ktoré možno chápať ako priestor zriadený na obmedzený čas, pokrývajúci obmedzenú oblasť, v ktorom možno testovať inovatívne technológie a obchodné modely. Inovatívne technológie a obchodné modely v mnohých prípadoch nie sú úplne v súlade so súčasnými pravidlami a nariadeniami jednoducho preto, že ľudia, ktorí zaviedli právne predpisy, si nový vývoj nikdy nedokázali predstaviť. Pozornosť nie je zameraná len na inovácie, ale aj na otázku, čo sa môže tvorca regulácií naučiť pre budúce fungovanie. Regulačné sandboxy budú viesť k lepšej regulácii len vtedy, ak budú zahŕňať proces tzv. regulačného objavovania.

Regulácia založená na princípoch

Regulácia založená na princípoch (*Principles-based regulation*) sa zameriava na stanovenie všeobecných princípov a hodnôt, ktoré subjekty musia dodržiavať. Na rozdiel od presných pravidiel v prípade rule-based regulácie, principles-based regulácia umožňuje väčšiu flexibilitu pri dosahovaní stanovených cieľov.

Regulácia založená na princípoch je formou regulácie 2.0 alebo „inteligentnej“ regulačnej stratégie, ktorá zdôrazňuje dôležitosť zodpovedných a sebazporujúčich sa organizácií pri dosahovaní požadovaných výsledkov. Regulačný orgán spolupracuje s regulovanou firmou zapájaním sa do stimulujúcich a opakovaných rozhovorov, ktoré pomáhajú lepšie porozumieť pravidlám a zabezpečiť ich dodržiavanie. Má tiež tú výhodu, že prekonáva problémy so škálovateľnosťou, čo umožňuje prechod od všeobecných

nariadení ku konkrétnym implementáciám na miestnej úrovni. Všetky tieto aspekty regulácie založenej na princípoch pomáhajú vytvárať lepšie regulačné prostredie a zároveň chrániť verejný záujem. Príkladom je GDPR nariadenie, ktoré je definované ako všeobecne stanovené pravidlá na vysokej úrovni alebo princípy na stanovenie štandardov, podľa ktorých musia regulované firmy podnikat'. Toto je v protiklade s normatívnymi a podrobnými nariadeniami založenými na pravidlách, ktoré sa môžu rýchlo stať nepoužiteľnými v dynamickom kontexte. Prístup založený na princípoch umožňuje, aby GDPR fungovalo flexibilne v rôznych sektoroch, situáciách a technológiách.

Samoregulácia

Prístup samoregulácie (Self-regulation) sa opiera o to, že samotné odvetvie alebo profesijné združenie stanovuje pravidlá a normy pre svojich členov. Subjekty v rámci odvetvia majú zodpovednosť sami regulovať svoje správanie a dodržiavať stanovené pravidlá.

Spoločným znakom subjektov, ktorí prispievajú k samoregulácii podnikania, je, že tvoria „medzisektorové organizácie“, teda organizácie, ktorých členmi sú samotné organizácie. Napríklad normy ako ISO tiež tvoria medzisektorové organizácie, ktoré svojou povahou fungujú inak ako organizácie jednotlivcov a zvyčajne im chýba hierarchia. Fungujú horizontálne a spoliehajú sa na konsenzus pri prijímaní kolektívnych rozhodnutí kvôli dôležitosti identít členských organizácií a individuálnych programov. Inými slovami, medzisektorovú organizáciu možno chápať ako „čiastočnú organizáciu“: spoločensky rozhodnutý poriadok, ktorému chýbajú určité organizačné prvky, ako je hierarchia alebo monitorovanie. Samoregulácia odvetvia prostredníctvom takej organizácie môže nielen podporiť vlastný záujem odvetvia, ale aj zvýšiť sociálne vedomie firiem, pričom poskytuje to, čo sa v literatúre nazýva „politický“ obrat spoločenskej zodpovednosti podnikov, teda konceptualizáciu firmy ako prevzatia novej zodpovednosti. Z tohto pohľadu samoregulácia prostredníctvom medzisektorovej organizácie presahuje jednoduchú pozitivistickú tradíciu spoločenskej zodpovednosti podnikov. Táto nová politická úloha firiem sa premieta do dynamiky kolektívneho riadenia vo svete, kde sa zodpovednosť čoraz viac delí naprieč spoločnosťou.

Trendom v samoregulácii je v poslednej dobe samoregulácia kryptomien a použitie technológie **blockchain** na zvýšenie transparentnosti. Samoregulácia v kontexte blockchainu v podstate znamená vytvorenie kódexu správania, ako aj usmernení pre účastníkov v rámci daného ekosystému na uľahčenie bezproblémových operácií. Tieto usmernenia sú formulované tak, aby zabezpečili transparentnosť a bezpečnosť daného systému. Na druhej strane zavádzajú prvok dôvery pre používateľov, ktorí pracujú v dôvere, že sa nenechajú oklamať podvodnými alebo škodlivými prvkami v systéme alebo mimo neho.

Technológia blockchain umožňuje samoreguláciu pomocou systému distribuovaných záznamov (*ledger*), ktorý zabezpečuje informácie, distribuuje ich medzi používateľov a neustále ich synchronizuje, aby sa zabezpečila nemennosť a redundancia. Ponúka tiež transparentnosť tým, že účastníkom zviditeľní všetky bloky, čím poskytuje jediný zdroj pravdy pre všetkých účastníkov. Technológia blockchain má navyše rámec zodpovednosti, ktorý riadi konanie účastníkov, ktorý zmierňuje zlé správanie a podnecuje dobré správanie.

Napríklad odvetvie nákladnej dopravy je jedným z odvetví, ktoré už profitujú zo samoregulácie prostredníctvom blockchainu. Otvorený systém distribuovaných záznamov technológie blockchain odbúrava existujúce prekážky v prístupe k informáciám a umožňuje využívať údaje na informované rozhodovanie na spravodlivom trhu. Tento samoregulačný potenciál technológie blockchain poskytuje odpoveď na väčšinu problémov spojených s priemyslom nákladnej dopravy. Potenciálne výhody samoregulácie prostredníctvom technológie blockchain však skúmajú aj iné odvetvia, ako sú financie, zdravotníctvo a riadenie dodávateľského reťazca. Potenciálne dlhodobé dôsledky samoregulácie v digitálnej revolúcii sú rozsiahle a rôznorodé. Samoregulácia prostredníctvom technológie blockchain má potenciál spôsobiť revolúciu prakticky v každom odvetví a nanovo definovať svet od základov. Samoregulácia môže navyše znížiť potrebu ústredných orgánov a sprostredkovateľov, čo môže viesť k úsporám nákladov pre podniky aj spotrebiteľov. Existujú však aj obavy z potenciálnych rizík spojených so samoreguláciou, ako sú bezpečnostné slabiny a nedostatok dohľadu. Celkovo budú dlhodobé dôsledky samoregulácie v digitálnej revolúcii závisieť od spôsobu jej implementácie.

Spoluregulácia

Prístup Spoluregulácie (*Co-regulation*) kombinuje prvky regulácie z verejnej strany a samoregulácie. Verejná regulácia sa kombinuje s aktívnou účasťou odvetvia alebo profesijných združení pri stanovovaní a vymáhaní pravidiel a noriem.

Spoluregulácia (tiež "spoločná regulácia") je metóda alebo stratégia regulácie, ktorá zahŕňa súkromných aj verejných aktérov, ktorí spolupracujú na dosiahnutí špecifických záujmov a cieľov, ako je napríklad zvýšenie predpisov o bezpečnosti potravín. Spoločná regulácia spája samoreguláciu a legislatívne opatrenia tak, že sa navzájom posilňujú, a zároveň pomáha rozširovať režimy bezpečnosti potravín v rámci hodnotového reťazca v rozvinutých aj rozvojových krajinách. Hlavnou výhodou koregulácie je to, že umožňuje súkromnému aj verejnému sektoru spoločne podnikat kroky smerom k situácii, ktorá bude prospešná pre obe strany, a vedie k zvýšenej flexibilitě pre regulované podniky, zlepšeniu monitorovacej úlohy súkromných orgánov, lepšiemu dodržiavaniu pravidiel a znižovaniu vládnych nákladov. V Európskej únii si koregulácia získava obnovenú pozornosť od prijatia programu lepšej regulácie EÚ v roku 2002. Prostredníctvom účinnej implementácie možno koreguláciu využiť na vytvorenie prostredia, v ktorom môžu súkromní aj verejní aktéri spolupracovať a profitovať z navzájom.

Regulačný systém EÚ pre bezpečnosť potravín je dobrým príkladom spoločnej regulácie implementácie požiadaviek na bezpečnosť potravín. Podľa všeobecného zákona o potravinách sú všetci prevádzkovatelia potravinárskych podnikov zodpovední za riadenie bezpečnosti potravín v rámci svojho vlastného podnikania. Ďalším príkladom je kontrola a riadenie bezpečnosti potravín v Spojenom kráľovstve, ktorá sa dosahuje prostredníctvom partnerstiev medzi verejným a súkromným sektorom. Medzi hlavné zainteresované strany patrí národná vláda, mimovládny sektor, špeciálne záujmové skupiny a aktéri hodnotového reťazca. Regulačné orgány mimovládneho súkromného sektora zahŕňajú International Standards Organization (ISO), United Kingdom Accreditation Service (UKAS), British Retail Consortium (BRC), zatiaľ čo aktéri hodnotového reťazca zahŕňajú maloobchodníkov, veľkoobchodníkov, výrobcov, dodávateľov a poskytovateľov logistiky. Zabezpečenie bezpečnosti potravín v Spojenom kráľovstve sa dosahuje prostredníctvom súkromnej regulácie aj zákonnej regulácie potravinárskeho priemyslu.

Regulácia pomocou podnetov

Regulácia pomocou podnetov (*Nudge regulation*) sa snaží ovplyvniť správanie subjektov prostredníctvom neinvažných podnetov, ktoré ich smerujú k požadovanému správaniu. Namiesto prísnych predpisov sa využívajú stimuly a informácie na podporu správania zlučiteľného s cieľmi regulácie. Tento prístup sa zameriava na zlepšenie výsledkov bez použitia tradičných mechanizmov velenia a kontroly tým, že umožňuje občanom a podnikom ponechať si voľbu, ale jemne ich posúvať konkrétnym smerom. Thaler a Sunstein (2008) vyvinuli rámec toho, ako môžu vlády manipulovať s „architektúrou výberu“, aby zmenili správanie bez toho, aby sa znížila možnosť výberu. Architektúra výberu je založená na pochopení, že automatické a inštinktívne správanie môže prevážiť nad racionálnejším uvažovaním pri určovaní mnohých možností. Ďalej predkladá myšlienku, že vládna politika a regulácia môžu „postrčiť“ správanie (prostredníctvom použitia štandardných možností a doložiek „opt-in“) smerom k racionálnejšiemu a efektívnejšiemu výsledkom. Výberová architektúra a regulácia pomocou podnetov môžu byť obzvlášť sľubné pri riešení politických problémov, kde sú možnosti klasickej regulácie a kontroly menej životaschopné, ako napríklad úprava životného štýlu, aby sa znížil vplyv na chronické problémy verejného zdravia.

Príkladom regulácie pomocou podnetov je požiadavka TCA v rámci kampane proti fajčeniu mladistvých, podľa ktorej reklamy na tabakové výrobky, vrátane reklám na mieste predaja, musia byť iba čierne a zvýrazní škodlivé účinky užívania tabaku.

Regulácia založená na rizikách

Regulácia založená na rizikách (Risk-based regulation) sa zameriava na identifikáciu a riadenie rizík spojených s konkrétnymi činnosťami alebo odvetvami. Regulačné opatrenia sú prispôbené na základe hodnotenia rizík a ich dôsledkov. V porovnaní s tradičným prístupom, ktorý je založený na predpisoch a prísnych pravidlách pre všetky subjekty, regulácia založená na rizikách sa snaží prispôsobiť reguláciu na

základe skutočného rizika spojeného s danou činnosťou. Prístup regulácie založenej na rizikách sa zakladá na nasledovných princípoch:

- Identifikácia rizík: Hlavným prvkom je identifikácia potenciálnych rizík spojených s danou činnosťou, procesom alebo odvetvím. Tieto riziká môžu zahŕňať zdravotné a bezpečnostné riziká, environmentálne riziká, finančné riziká a podobne.
- Hodnotenie rizík: Riziká sa hodnotia na základe ich pravdepodobnosti výskytu a závažnosti ich dôsledkov. Toto hodnotenie umožňuje určiť, ktoré riziká sú najdôležitejšie a vyžadujú väčšiu pozornosť a reguláciu.
- Prispôbená regulácia: Regulačné opatrenia a požiadavky sa navrhujú a uplatňujú na základe identifikovaných rizík. Tieto opatrenia sa môžu líšiť pre rôzne subjekty alebo odvetvia v závislosti od úrovne rizika, ktoré predstavujú. Subjekty s vyšším rizikom môžu podliehať prísnejšej regulácii, zatiaľ čo subjekty s nižším rizikom môžu mať väčšiu flexibilitu.
- Monitorovanie a revízia: Regulácia založená na rizikách si vyžaduje pravidelné monitorovanie a revíziu rizík, aby sa zabezpečilo, že regulačné opatrenia sú stále účinné a primerané. V prípade potreby môžu byť opatrenia aktualizované alebo upravené na základe nových informácií alebo zistení.

Cieľom regulácie založenej na rizikách je dosiahnuť vyvážený prístup, ktorý zabezpečuje ochranu verejného záujmu a minimalizuje zbytočné administratívne zaťaženie pre regulované subjekty. Tento prístup sa často uplatňuje v oblastiach ako regulácia finančného sektora, potravinárskej bezpečnosti, environmentálnej ochrany a mnohých ďalších. Napríklad pandémia COVID-19 poukázala na riziko keď regulácie nie sú úmerné riziku – a výsledkom sú zaťažujúce pravidlá s malým pozitívnym vplyvom na zdravie a bezpečnosť. Nové technológie však môžu pomôcť zlepšiť reguláciu založenú na riziku. Lepšia dostupnosť údajov a IT nástrojov znamená, že je jednoduchšie posúdiť a zamerať sa na konkrétne riziká. Regulácie založené na rizikách po vypuknutí pandémie vytvárali napríklad vo Fínsku, kde úrad pre bezpečnosť a chemikálie testoval rôzne typy inšpekcií, ako napríklad inšpekcie cez Skype.

3 Koncept Regulácie 2.0

- aktualizácia konceptu pre Regulácie 2.0

Je potrebné nanovo premyslieť, ako funguje inštitúcia verejná správa

3.1 Nové pohľady na regulačnú kapacitu

Transformácia inštitúcií verejnej správy by mala sledovať takzvané princípy Regulácie 2.0. Ide o nový prístup k výkonu verejnej správy, ktorého princípom je využívanie analytických údajov na podporu rozhodovania (najmä použitie analýza rizík, odhaľovanie problémov a nesúladu s reguláciami v dátach a podobne). Prístup vedie tiež postavený na dynamickej interpretácii opatrení na základe sledovania dosahovanie cieľov regulácie (vyhodnocovanie na základe analýzy údajov regulovaného prostredia). V optimalizovaných procesoch je príklon od udeľovania povolení k prevencii a predchádzaniu problémov. Systém postavený na princípoch Regulácie 2.0 je tak otvorenejší, flexibilnejší a má nižšiu administratívnu záťaž.

Byrokracia a regulácie 1.0

Fungovanie verejnej správy si podvedome spájame s pojmom byrokracia a zbytočná administratívna záťaž. Keď sa však zamyslíme nad procesmi, ktoré sa v skutočnosti inštitúcie vykonávajú, zistíme, že majú zmysel a vďaka nim dokázali štátne inštitúcie relatívne dôkladne manažovať práva a povinnosti občanov pri registrácii majetku, obchodných spoločností, pri výbere daní a podobne. Inštitúcie verejnej správy sú optimalizované na fungovanie v papierovom svete, v čase takzvaného informačného nedostatku. Ak sa vydáva povolenie, byrokrat potrebuje zhromaždiť na jednom mieste všetky potrebné dokumenty a založiť ich do spisu, aby jeho následné rozhodnutie bolo auditovateľné. Funkcie verejnej správy, súdna moc, archívy boli nastavené, aby takýto systém podporovali. Nazvime ho systém regulácie 1.0.

Systém regulácie 1.0 je charakteristický:

- Hierarchiou medzi pracovníkmi verejnej správy ako i organizačnými zložkami a jednotlivými inštitúciami verejnej správy.
- Presne stanovenými procesmi, ktoré definujú administratívne procedúry. Tieto procesy vychádzajú z legislatívy.
- Na základe splnenia požiadaviek sa vydávajú rozhodnutia, ako sú povolenia a licencie.

Systém regulácie 1.0 však nespĺňa už požiadavky dnešnej doby, najmä s porovnaním so službami, ktoré dokážu ponúknuť súkromné spoločnosti, ako internetové firmy Amazon a Google, ale i tradičnejšie spoločnosti, ako sú banky. Snahy o digitalizáciu verejnej správy sa väčšinou skončili neúspechom aj pre to, že sa digitalizoval pôvodný proces zberu informácií a dokumentov na jednom mieste. Pri nedokonalom UI takéto riešenie je administratívne náročnejšie, ako použitie papiera. Zároveň v rámci procesu nie je možné využiť nové možnosti, ktoré prináša dátová doba, či už na strane služby a jej adresnosti, alebo na strane procesu vo vnútri inštitúcie.

Nové možnosti fungovania

V dobe veľkých dát však môže verejná správa fungovať inak. O oblasti, ktorej sa inštitúcia venuje (napríklad verejné zdravotníctvo, životné prostredie, trh práce, dopravná situácia) sú k dispozícii dáta, ktoré sú ukryté v informačných systémoch subjektov na trhu alebo je ich možné získať monitorovaním transakcií alebo využitím nových technológií ako sú senzory IoT. Na základe spracovania veľkých dát je možné v reálnom čase sledovať situáciu a voliť najlepšie možné opatrenia. Zároveň sú výrazne zlepšia možnosti predpovedať budúci vývoj a riešiť problémy už v zárodku, alebo pred tým, ako reálne nastali.

Systém postavený na princípoch Regulácie 2.0 je vhodný pre dobu informačného nadbytku a je ho možné charakterizovať:

- Orientáciou na ciele a kreatívne riešenie problémov,
- Možnosťou inovácie, keďže presná procedúra riešenia nie je stanovaná, ale hľadá sa najlepší postup, ako dosiahnuť príslušné ciele,
- Otvorené systémy a spolupráca zapojených aktérov, bez jasne určenej hierarchie.

Prechod na Reguláciu 2.0 tak znamená nižšiu administratívnu záťaž pre subjekty, ale i požiadavky na integráciu dát a analytické schopnosti inštitúcií verejnej správy.

Princípy pre Regulácie 2.0

Nasledujúci zoznam princípov je vhodné aplikovať:

- **Princíp 1 - jasne stanovené ciele a ukazovatele:** pre oblasť, ktorú má verejná inštitúcia v kompetencii sú stanovené ciele, v akých parametroch máme záujem, aby sa realita pohybovala. Napríklad kvalita ovzdušia v prípade životného prostredia, miera očkovania v prípade verejného zdravotníctva, čakacie doby u lekára v prípade regulácie poskytovateľov zdravotnej starostlivosti. Systém cieľov by mal obsahovať vhodný počet výsledkov a výstupových ukazovateľov. Systém cieľov musí obsahovať aj kritické hodnoty a identifikovať javy, ktoré nesmú v praxi nastávať. Jasne stanovené ciele je potrebné verejne zdieľať.
- **Princíp 2 - monitoring regulovaného prostredia:** parametre o regulovanom systéme je potrebné sledovať a vyhodnocovať v reálnom čase. Znamená to, že sú v praxi zavedené účinné nástroje pre zber dát a ich interpretáciu, či už s využitím API pre prístup do informačných systémov aktérov na trhu (taxi služby, finančné inštitúcie, účtovné systémy), s využitím automatizovaného zberu dát cez senzory (hluková situácia) alebo vďaka zapojeniu komunity do monitorovania (crowdsourcing). Výsledky online monitoringu je potrebné verejne zdieľať.
- **Princíp 3 - analytický model reality:** verejná inštitúcia má k dispozícii model, na základe ktorej dokáže chápať problém, ktorý rieši, vrátane vzťahov medzi príčinami a následkami. Model zvyčajne používa analytické metódy, ako je deduktívne uvažovanie a kritická analýza, aby sa komplexné pozorovania o skutočnom svete zmenili na zjednodušené vysvetlenia. Vo výkone verejnej správy sa bežne používa Analýza nákladov a výnosov (*Cost-Benefit Analysis, CBA*), Analýza rizika (*Risk Analysis*), Kvantitatívna analýza (*Quantitative Analysis*) a Modelovanie dynamiky systému (*System Dynamics Modelling*):
 - Analýza nákladov a výnosov: Tento model sa používa na vyhodnotenie nákladov a prínosov navrhovaných iniciatív a projektov. Používa sa na určenie, či je navrhované rozhodnutie alebo projekt prínosom pre spoločnosť, a ako maximalizovať potenciálne výhody z neho.
 - Analýza rizika: Tento model sa používa na vyhodnotenie a kvantifikáciu rizika spojeného s akýmkoľvek potenciálnym opatrením. Umožňuje určiť pravdepodobnosť a dôsledky, ktoré sú možné pre rôzne scenáre.
 - Kvantitatívna analýza: Tento model sa používa na meranie vplyvu rôznych zmien v prostredí alebo činnostiach na vládne programy a služby. Kvantitatívna analýza sa môže použiť na predpovedanie výsledkov určitých vzorcov správania alebo podmienok.
 - Modelovanie dynamiky systému: Tento model sa používa na simuláciu vzájomných závislostí medzi rôznymi časťami systému a určenie toho, ako rôzne faktory alebo udalosti ovplyvňujú celok. Modelovanie dynamiky systému je užitočným nástrojom pre tvorcov politik na vyhodnotenie vplyvu navrhovaných opatrení na celý systém. V súčasnosti sa čoraz viac preferuje vytváranie komplexných modelov vo virtuálnom prostredí na testovanie politik, označované tiež ako digitálne dvojča (*Digital Twin*).

-
- **Princíp 4 - nastavené procedúry pre riešenie regulačných udalostí:** ak sa na základe monitoringu ukáže problém, inštitúcia dokáže mobilizovať zdroje a má jasný plán, ako postupovať. Tieto postupy vo všeobecnosti zahŕňajú súbor krokov, ktoré sa musia dodržiavať, aby sa splnili všetky požiadavky regulátora. To môže zahŕňať kroky, ako je nahlásenie udalosti alebo problému regulátorovi, prijatie potrebných opatrení na vyriešenie udalosti a aktualizácia príslušnej dokumentácie. Koncept prednastavených postupov pomáha zabezpečiť súlad so zákonmi, nariadeniami a inými regulačnými požiadavkami. Príkladom je aj systém rýchleho varovania pre potraviny a krmivá (RASFF), ktorý je oznamovací systém prevádzkovaný Európskou komisiou a slúži na výmenu informácií o zistených bezpečnostných rizikách medzi členskými štátmi, pokiaľ ide o potraviny, materiály prichádzajúce do styku s potravinami a krmivá pre zvieratá. Systém je navrhnutý tak, aby konal rýchlo a kooperatívne, aby sa predišlo potenciálnym bezpečnostným rizikám – akonáhle sa zistí ohrozenie, spustí sa rýchle varovania, spolupráca a vzájomná výmena informácií.
 - **Princíp 5 - participatívny model:** aktéri regulovaného trhu dokážu spolupracovať s verejnou inštitúciou na základe participatívneho modelu. Participatívny model možno vnímať ako prax, pri ktorej regulačné úrady pozývajú spoločnosti a spotrebiteľov, aby sa podieľali na rozhodovaní, ako aj na dialógu medzi regulačnými orgánmi a aktérmi na vytvorenie vhodných politík. Participatívny model je potrebný na to, aby sa zabezpečilo, že regulácie budú jasne definovať úlohu, povinnosti a práva každého účastníka. V modeli by mal by existovať:
 - rovnaký a transparentný prístup všetkých zainteresovaných strán k dialógu;
 - prezentácia konkrétnych riešení založených na dôkazoch od zainteresovaných strán a regulovaných firiem;
 - verejné rozhodnutia regulátora, ktoré obsahujú hodnotenia navrhovaných riešení s usmerneniami na objasnenie pravidiel; a
 - opatrenia na zabezpečenie súladu navrhnuté regulovanou spoločnosťou v súlade s usmerneniami.

Model by mal poskytnúť rámec hodnotenia pre navrhované riešenia, aby sa určili tie najúčinnnejšie. Hodnotenie by sa malo opierať o zásadu proporcionality, aby sa posúdilo, či je navrhované opatrenie na dosiahnutie súladu primerané, aby sa zabezpečila účinnosť nariadenia.

- **Princíp 6 - kontinuálne zlepšovanie:** prechod na Regulácie 2.0 je vždy postupný, po menších krokoch. Princípom neustáleho zlepšovania je myšlienka snažiť sa časom zlepšovať svoje procesy a služby. To znamená, že organizácie by mali neustále pracovať na hľadaní lepších spôsobov plnenia úloh a zabezpečenia lepších používateľských skúseností. Dá sa to urobiť mnohými spôsobmi, napríklad experimentovaním, analýzou údajov, aktualizáciou technológie, počúvaním spätnej väzby od konzumentov služieb a vykonávaním úprav založených na dátach.
- **Princíp 7 - benchmarking:** informácie o porušení pravidiel a spôsobení problémov jednotlivými aktérmi sú zverejňované, čím je zvýraznené reputačné riziko. Prejavom tohto prístupu je čoraz častejšie využívanie regulačných techník zverejňovania, čiže pomenovania a zahanbovania, ktorých cieľom je zvýšiť transparentnosť trhov a vyvolať reputačné mechanizmy. Zverejňovanie výsledkov inšpekcií má za cieľ lepšie informovať spotrebiteľov v očakávaní, že pri rozhodovaní o obchodovaní s určitou spoločnosťou zväžia stav dodržiavania predpisov spoločností. Ide teda o pokus vyvolať trhové sledovanie verejných sankcií a zvýšiť vplyv verejných sankcií na reputáciu spoločnosti. Dôležitým dôvodom je, že tieto sankcie sa považujú za účinnejšie ako tradičné sankcie pri odrádzaní od regulačných deliktov alebo pri stimulácii dodržiavania predpisov. Dôsledky poškodenia dobrého mena firmy môžu potenciálne presiahnuť účinok maximálnej pokuty, ktorú môže súd uložiť. Spoločnosť, ktorá aj na krátky čas stratí svoju povesť, môže utpieť značné škody na dôvere spotrebiteľov, podiele na trhu a hodnote vlastného imania. Hrozba tohto typu sankcie môže podnietiť firmy, ktoré uvažujú o nedodržaní regulačných cieľov, aby prehodnotili, aj keď by ich nedodržanie prinieslo významný finančný prospech. Napríklad V Dánsku aj v Spojenom

kráľovstve „skóre na dverách“ reštaurácií ukazuje, do akej miery reštaurácia spĺňa hygienické normy. Pozitívny smajlík označuje súlad, negatívny smajlík označuje nezrovnalosti.

Praktické dôsledky

Zavedenie Regulácie 2.0 do praxe znamená zmenu celého prístupu k výkonu verejnej správy. Znamená to prechod od modelu "získaj naše povolenie a následne postupuj" na "rieš, čo uznáš za vhodné, ale my to budeme sledovať a v prípade problémov budeš znášať reputačné riziko".

Prístup založený na Reguláciách 2.0 je tiež vhodný pre regulovanie nových digitálnych platforiem, ako sú Uber alebo Airbnb. Jeho úspešná implementácia čelí prekážkam na oboch stranách: platformy nechcú umožniť prístup k svojim dátam a inštitúcie verejnej správy sa nechcú vzdať výsady udeľovať povolenia.

3.2 Algoritmická regulácia

Po industriálnej revolúcii z 19. storočia sa svet opäť nachádza v situácii generujúcej obrovské zmeny s doslova disruptívnym potenciálom, ktoré pravdepodobne zásadným spôsobom menia spoločnosti, štáty aj život všetkých ľudí.

Tieto zmeny sú súčasťou revolúcie veľkých dát, ktorá spočíva v technológiách umožňujúcich spracovávať obrovské množstvá rozmanitých dát v extrémne rýchlom čase, pričom použité algoritmické procesy sú v rámci týchto dát schopné identifikovať vzorce alebo vzájomné vzťahy a tieto pretaviť do predikčných analýz, ktoré je možné využiť pre vytvorenie nových dát. Dôležitou poznámkou je, že takéto vzorce alebo korelácie sú na takej úrovni, že ľudský mozog ich nie schopný spracovať alebo vidieť resp. odhaliť.

Algoritmická regulácia má potenciál byť oveľa efektívnejším nástrojom ako akékoľvek iné spôsoby regulácie, a to za predpokladu, že sa v procese ich prípravy a používania regulátor vyhne rizikám spojeným s takýmto typom regulácie. Detailné informácie o rôznych rizikách vyplývajúcich z regulácie pomocou algoritmov sú uvedené nižšie.

3.2.1 Definícia algoritmickej regulácie

V prvom rade je potrebné odlíšiť pojem algoritmická regulácia od pojmu regulácia algoritmov. Pri regulácii algoritmov ide o stanovovanie pravidiel a opatrení, ktoré majú za cieľ kontrolovať, riadiť alebo obmedzovať používanie algoritmov, aby sa obmedzili alebo minimalizovali prípadné negatívne dôsledky používania algoritmov, alebo napríklad aby sa pri využívaní algoritmov sledovali nielen záujmy jednotlivcov ale aj celej spoločnosti alebo štátu.

Naproti tomu algoritmická regulácia využíva algoritmy na riadenie, ovplyvňovanie alebo koordináciu aktivít regulovaných subjektov v rôznych oblastiach, pričom tento typ regulácie sa využíva tak vo verejnom ako aj v súkromnom sektore.

Ďalším používaným pojmom je algoritmické rozhodovanie (z angl. algorithmic decision-making – ADM) a tiež algoritmické vládnutie (z angl. algorithmic governance). Oba tieto pojmy sa do veľkej miery prekrývajú s pojmom algoritmická regulácia. Treba pripomenúť, že tak ako sa vyvíjajú algoritmické systémy, tak sa v čase vyvíjajú aj súvisiace pojmy. Zjednodušene sa dá povedať, že regulácia pomocou algoritmov sa zhmotní do systému algoritmického vládnutia využívajúceho algoritmické rozhodovanie, ktoré používa algoritmicky generovaný systém pre výkon alebo oznamovanie rozhodnutí.

Algoritmická regulácia je komplexným socio-technickým systémom. Veľké technické systémy sa nachádzajú uprostred širších, integrovaných sociálnych a technických systémov. Tieto systémy vykonávajú štandardizované operácie, ktoré sa spoliehajú na integráciu s ostatnými sociálnymi procesmi a ich prevádzka je legitimizovaná ich neosobnou a objektívnou racionalitou.

Tak ako veľké technické systémy usmerňujú pozornosť, usporadúvajú rozhodovacie procesy a generujú efekty naprieč mnohými prostrediami a časom, to isté vykonáva aj algoritmická regulácia, ale rýchlosťou svetla, s oveľa väčším rozlíšením a cínením, teda oveľa presnejšie.

Algoritmická regulácia usmerňuje, podporuje ale aj vynucuje interakcie a vzťahy medzi osobami a ich sociálnymi a ekonomickými životmi. Algoritmickému regulácii boli na základe doterajšieho vývoja a výskumu priradené nasledovné charakteristiky:

- Ide o nový spôsob realizovania **spoločenskej objednávky** odlišnej od trhovej alebo byrokratickej formy spoločenskej objednávky,
- Ide o techniku kontroly založenú na **architektúre a dizajne**, do ktorých sa premietajú štandardy, pravidlá a ciele konkrétnej regulácie,
- Najviac sa používa v rámci globálnych **digitálnych platforiem** v rámci súkromného sektoru a vo verejnom sektore je zatiaľ využívaná v menšej miere.

Algoritmická regulácia je teda systém algoritmického rozhodovania, ktorý reguluje určitú oblasť alebo aktivitu z dôvodu manažovania rizika alebo dosiahnutia želaného správania prostredníctvom znalostí, ktoré sú kontinuálne generované počítačmi z dát zbieraných a získavaných v reálnom čase z mnohých zložiek vzťahujúcich sa k regulovanému prostrediu za účelom určenia a prípadne vylepšenia systémových činností tak, aby bol dosiahnutý vopred špecifikovaný cieľ regulácie (Yeung, 2018).

Algoritmická regulácia je regulácia využívajúca algoritmy, ktoré môžeme popísať ako digitálne príkazy artikulované pomocou matematického vzorca, ktorý obsahuje normatívnu vložku vloženú do jeho kódu. Algoritmy jednak generujú predpovede týkajúce sa budúceho správania na základe analýzy signifikantného množstva dát. Na druhej strane, algoritmy relatívne autonómne vykonávajú rozhodnutia, ktoré sa spoliehajú na vyššie uvedené predpovede.

Podľa starších očakávaní by algoritmická regulácia mala byť bezproblémovo efektívny, automatizovaný a na dátach založený prístup, ktorý nám umožní vyriešiť problémy so spoločenskou koordináciou s technologickou zdatnosťou vyhľadávača Google (O'Reilly, 2013).

Algoritmické vládnutie je forma spoločenskej objednávky, ktorá sa spolieha na koordináciu účastníkov určitých vzťahov, je založené na pravidlách a obsahuje najmä komplexné znalostné počítačové procesy (Katzenbach a Ulbricht, 2019).

Algoritmickú reguláciu môžeme rozdeliť do dvoch typov:

- **Regulácia poháňaná kódmi** (code-driven regulation), v rámci ktorej sa v automatizovaných algoritmoch integruje nastavovanie štandardov s modifikáciou správania.
- **Regulácia poháňaná dátami** (data-driven regulation), v rámci ktorej prediktívne algoritmy poskytujú podporu pre rozhodnutia navrhovaním štandardov pre monitorovanie, predpovedanie a ovplyvňovanie správania.

3.2.2 Formy algoritmickému regulácie

Algoritmická regulácia závisí od kontinuálneho zbierania a analýzy primárnych dát kombinovaných s metadátami systémom, ktorý zaznamenáva frekvenciu, čas a trvanie ich používania a ktorý pomocou priamej komunikácie medzi prístrojmi (machine-to-machine communication) a cez digitálne siete, umožňuje, aby boli tieto kombinované dáta algoritmicky získavané za účelom spustenia automatickej odpovede (Morozov, 2014).

Ak chápeme algoritmickú reguláciu ako kybernetický proces zahŕňajúci tri základné zložky akéhokoľvek systému kontroly, teda že ide o spôsoby:

- stanovovania štandardov (napríklad správania) a cieľov,
- získavania informácií a dát,

- vynučovania štandardov (v prípade odchýlenia sa od týchto štandardov) v záujme zaistenia zmeny správania tak, aby bolo v súlade so stanovenými štandardami,

tak môžeme identifikovať niekoľko foriem algoritmickej regulácie. Nasledovná tabuľka ukazuje taxonómiu foriem algoritmických regulácií podľa Karen Yeung:

Tabuľka 4: Formy algoritmickej regulácie

	Nastavenie štandardu	Monitorovanie	Vynútenie/sankcia	Popis
1.	Fixné	Reaktívna detekcia porušenia pravidiel v reálnom čase	Automatická	Jednoduchý administratívny systém založený na sankciách ukladaných v reálnom čase
2.	Fixné	Reaktívna detekcia porušenia pravidiel v reálnom čase	Odporúčací systém	Jednoduchý systém varovaní uskutočňovaných v reálnom čase
3.	Fixné	Preventívne predvídanie porušenia pravidiel	Automatická	Jednoduchý administratívny systém udeľujúci preventívne sankcie
4.	Fixné	Preventívne predvídanie porušenia pravidiel	Odporúčací systém	Jednoduchý predvídajúci systém poskytujúci odporúčania
5.	Adaptívne	Reaktívna detekcia porušenia pravidiel v reálnom čase	Automatická	Komplexný administratívny systém udeľujúci sankcie
6.	Adaptívne	Reaktívna detekcia porušenia pravidiel v reálnom čase	Odporúčací systém	Komplexný hierarchický systém reagujúci v reálnom čase
7.	Adaptívne	Preventívne predvídanie porušenia pravidiel	Automatická	Komplexný predvídajúci systém udeľujúci sankcie
8.	Adaptívne	Preventívne predvídanie porušenia pravidiel	Odporúčací systém	Komplexný predvídajúci systém poskytujúci odporúčania

Fixný štandard

V rámci určenia štandardov môže byť norma správania, ktorú má systém vynučovať, jednoduchým (fixným alebo pevným) štandardom správania. To je základná forma algoritmickej intervencie, ktorá môže byť v systéme stanovená napríklad v podobe používania ochrany heslom pred neautorizovaným prístupom k digitálnemu obsahu, ktorý sa nachádza v danom systéme.

Adaptívny štandard

Alternatívou k fixnému štandardu správania môže byť adaptívny (prispôsobiteľný) štandard správania, ktorý umožní dospieť k akémukoľvek pevnému systémovému cieľu, pre ktorý bol systém dizajnovaný a optimalizovaný, aby dosahoval stabilitu systému.

Príkladom takéhoto adaptívneho systému sú inteligentné prepravné systémy, ktorý sa navzájom efektívne učia ako identifikovať najspoľahlivejší spôsob predvídania plynutia prepravy prostredníctvom procesov strojového učenia, ktoré využívajú systém "pokús - omyl" pre poskytovanie kontinuálne aktualizovaných dopravných dát, a to v reálnom čase.

Reaktívny prístup

V rámci monitoringu a získavania informácií môže systém fungovať na reaktívnej báze konfigurovaný automaticky získavať historické dáta v reálnom čase, aby identifikoval porušenia štandardov. Jednoduchým systémom v rámci tejto formy je napríklad systém zahŕňajúci automatickú detekciu vozidiel, ktoré prekročili stanovenú povolenú rýchlosť, a to prostredníctvom kamier schopných merať rýchlosť a poskytnúť v reálnom čase identifikáciu vozidiel.

Príkladom komplexného reaktívneho systému je systém pre detekciu podvodov s použitím kreditných kariet, ktorý využíva techniky strojového učenia, aby profiloval vzorce míňania držiteľov kreditných kariet a zároveň identifikoval podozrivé transakcie, ak sa také objavia a následne na ne upozornil poskytovateľov a držiteľov kreditných kariet, ktorí tak môžu vykonať okamžité opatrenia pre zablokovanie ďalších transakcií a predídenie vzniku ďalších škôd.

Preventívny prístup

Algoritmické systémy môžu byť tiež konfigurované, aby boli schopné identifikovať porušenie stanovených štandardov alebo pravidiel aj na preventívnej báze, teda skôr ako sa reálne udejú, a to použitím algoritmov ovládajúcich strojové učenie na historické dáta, aby z nich odvodili, a teda vlastne predpovedali budúce správanie.

Jednoduché systémy schopné predvídať zahŕňajú digitálne systémy, ktoré vedia dokončiť slová alebo vety. Komplexné systémy schopné predvídať sa využívajú napríklad v rámci personalizovanej cenotvorby, a to tak, že algoritmus ovládajúci strojové učenie sa aplikuje na dáta zozbierané o osobe v rámci sledovania jej online činnosti a na meranie celkového online správania tejto osoby, vďaka čomu sa vytvorí spotrebiteľský profil tejto osoby. Tento profil poskytne predajcovi informácie o tom, aké sú pravdepodobné platobné schopnosti tejto osoby alebo jej vôľa platiť a na základe toho jej ponúkne personalizovanú cenu za daný tovar alebo službu, ktorú jej chce predat'.

Automatické reakcie

V rámci vynucovania alebo zmeny určitého správania poznáme systémy, ktoré bez ľudského zásahu uložia sankciu alebo urobia rozhodnutie automaticky. Takéto jednoduché systémy sa využívajú napríklad v prípade automatického zablokovania prístupu k obsahu na webovej stránke, čo je obvyčajne dôsledkom nezaplatenia poplatku za ich využívanie alebo aj v prípade zadania neplatného hesla.

Tieto systémy môžu operovať aj na preventívnej báze, a to napríklad v prípade systémov, ktoré automaticky vyhodnocujú prihlášky od jednotlivcov hľadajúcich prístup k službám ako sú pôžičky, poistenie alebo pracovné príležitosti. Tieto systémy fungujú tak, že algoritmy predpovedajú budúce správanie osôb, ktoré prihlášky podali a na základe toho prichádza automatické rozhodnutie o ďalšom postupe, teda prijatí alebo odmietnutí prihlášky.

Odporúčacie reakcie

Vyššie uvedené jednoduché aj komplexné systémy môžu byť nakonfigurované aj tak, že nebudú konať alebo rozhodovať automaticky, ale budú poskytovať len odporúčania alebo asistenciu človeku, ktorý bude oprávnený rozhodnúť alebo konať.

3.2.3 Čo prináša algoritmická regulácia

Algoritmická regulácia vzhľadom na obrovský technologický rozvoj prináša regulátorom úplne nové možnosti regulácie vychádzajúce z hlbšieho poznania reality a možností oveľa presnejšie zasahovať do toho čo sa verejnom priestore deje. Medzi takéto konkrétne možnosti patrí napríklad:

- kapacita generovať presné predpovede správania
- preventívne intervencie založené na dôkazoch
- presné informácie o oblastiach alebo problémoch, ktoré vyžadujú pozornosť alebo zásah vrátane ich predpovedania.

Okrem nových možností však algoritmická regulácia prináša aj mnohé obavy, ktoré sa týkajú porušovania ľudských práv, zákazu diskriminácie alebo nakladania s osobnými údajmi.

3.2.4 Limity a riziká algoritmickej regulácie

Vyhodnotenie zámeru implementovať v rámci regulácie určité algoritmické rozhodovacie procesy je kľúčové pre efektivitu systému a úspešnosť samotnej regulácie a tak ako bolo uvedené vyššie, môže tiež viesť k záveru, že algoritmické rozhodovanie nebude možné v rámci regulácie využiť vôbec. Preto je nutné vyhodnotiť riziká a limity použitia algoritmického rozhodovania najmä v nasledovných oblastiach:

- Spoľahlivosť a kvalita dát,
- Dodržiavanie etických princípov,
- Ústavné hranice.

Tieto oblasti vytvárajú rôznorodé hranice pre implementáciu systémov pre algoritmické rozhodovacie procesy do praxe.

Dáta

V niektorých oblastiach dáta, ktoré sú k dispozícii, jednoducho nie sú vhodné pre ich využitie v rámci algoritmického rozhodovania, pretože testovacie dáta, z ktorých sa má systém učiť, obsahujú také odchýlky, ktoré by vo výstupoch systému spôsobovali neprípustné skreslenia. Ďalším dôvodom nepoužiteľnosti dát môžu byť nejaké známe systémové nedostatky, na základe ktorých vieme, že dáta, ktoré sú k dispozícii, by nezaručovali, že systém bude po ich použití pracovať s objektívnymi skutočnosťami. Napríklad v prípade reportovania trestných činov je známe, že majetkové trestné činy alebo násilné trestné činy spáchané na verejnosti bývajú zaznamenané, vyšetrované a uvedené v štatistikách v oveľa väčšej miere ako napríklad trestné činy domáceho násillia. Kvôli tomu sa dá predpokladať, že celkové dáta, ktorými štát v tejto oblasti disponuje, môžu byť oproti realite značne skreslené.

Ďalším problematickým aspektom v tejto oblasti je hrozba asymetrickej spätnej väzby. Tento problém sa v minulosti objavil v prípadoch, kedy mal algoritmický rozhodovací systém v rámci justície predvídať

pravdepodobnosť recidívy páchatel'ov alebo podozrivých pokiaľ išlo o rozhodovanie, či budú vzatí do väzby alebo či by im mal byť uložený podmienený alebo nepodmienený trest odňatia slobody. Takýto systém nemôže za súčasných podmienok fungovať, pretože nie je schopný spoľahlivo vyhodnotiť, či niekto opätovne spácha trestný čin alebo nie. Aj ak by sme pre účely vytvorenia algoritmickeho rozhodovania takýchto prípadov vykonali experiment spočívajúci v tom, že by sme všetkých páchatel'ov prepustili na slobodu a potom by sme niekoľko rokov monitorovali, ktorí z nich sa dopustili recidívy, ani vtedy by sme neboli schopní vytvoriť a implementovať systém, ktorý by dokázal spoľahlivo predvídať opätovné páchanie trestnej činnosti. Ide totiž o príliš komplexnú otázku, ktorej odpoveď môže závisieť napríklad aj od množstva náhodných udalostí v živote danej osoby, ktoré nemožno vôbec predvídať.

Etické princípy

Ďalším kľúčovým pilierom algoritmickeho rozhodovania je dodržiavanie etických princíпов, preto systémy využívajúce takéto rozhodnutie musia vo svojej podstate obsahovať etické normy vychádzajúce z hodnôt demokracie a ľudských práv. Systém napríklad nesmie obsahovať štatistickú diskrimináciu, ktorá by negatívne zasiahla voči znevýhodneným skupinám osôb trpiacim v niektorých spoločnostiach štruktúrnymi znevýhodneniami. Ak by tieto štruktúrne znevýhodnenia boli súčasťou systému algoritmickeho rozhodovania, je takmer isté, že tento systém by tieto znevýhodnenia nielen reprodukoval ale dosť pravdepodobne aj prehľboval. Tento problém sa môže prehľbovať obzvlášť v prípade, že je systém založený na osobných charakteristikách, ak tieto charakteristiky nemajú hodnoverné a priame kauzálne spojenie s predvídaným výstupom. Takisto záleží aj na oblasti aplikácie algoritmickej regulácie. Ak má mať takéto regulácia alebo rozhodovanie vážny dopad na životné príležitosti osôb, diskriminácia sa prejaví ešte výraznejšie ako v oblastiach, v ktorých sú dôsledky regulácie na život osôb prirodzene menšie.

Napríklad v oblasti trestného práva sú potenciálne zásahy do života osôb na úrovni zásahov do základných ľudských práv. Systémy musia brať do úvahy a vyvažovať zásahy tak, aby boli primerané a založené na rovnakom zaobchádzaní, ktoré má vyššiu spoločenskú a najmä morálnu hodnotu, ako napríklad efektívnosť nejakej časti verejných procesov, a preto musí byť pri vytváraní algoritmickeho rozhodovacieho procesu prioritizovaná. Takisto platí, že jednotlivci musia byť posudzovaní výhradne vzhľadom na zákonné aspekty ich správania, čo vytvára nielen pre algoritmicke regulácie ďalšie hranice, ktoré nesmú byť systémom prekročené.

Právna úprava

Je ťažko predstaviteľné, že z dôvodu implementácie určitej algoritmickej regulácie bude prichádzať k zmenám ústavy. Preto je pri vymedzovaní priestoru, v ktorom bude regulácia pôsobiť, zásadné rešpektovať hranice dané ústavou a ústavnými zákonmi, a to špeciálne v nasledujúcich oblastiach:

- *Transparentnosť a zodpovednosť* - v tejto oblasti je rizikom, že algoritmicke procesy môžu byť neprehľadné a pre bežného užívateľa nezrozumiteľné, alebo ak jednotlivci nevedia o existencii automatizovaných procesov, prípadne v ešte horšom prípade ani netušia, aké správanie alebo charakteristika môže mať kvôli algoritmicke rozhodovaniu priamy alebo nepriamy vplyv na ich život.
- *Právo na súkromie a základné ľudské práva* - riziká vytvárané algoritmicke reguláciou v tejto oblasti môžu vo všeobecnosti znamenať hrozbu pre slobodnú vôľu jednotlivcov a ich autonómne rozhodovanie. Miera ohrozenia súkromia jednotlivcov závisí predovšetkým od kvality bezpečnosti údajov a integrity informačných systémov. V rámci ochrany práva na súkromie a práva na ochranu osobných údajov je potrebné dodržiavať napríklad nariadenie o ochrane osobných údajov (GDPR), ktoré reguluje automatizované rozhodovanie vykonávané bez ľudských zásahov, ako aj zákon o ochrane osobných údajov, občiansky zákonník a ostatné súvisiace právne predpisy.
- *Právo na spravodlivý proces vrátane práva na odvolanie a právo na náhradu škody* - aj algoritmicke rozhodovanie musí spĺňať uvedené požiadavky na spravodlivý proces a možnosť odškodnenia, ktoré vychádzajú z princíпов právneho štátu. V prípade, že tieto požiadavky nie sú v systémoch zabezpečené, zvyšuje sa riziko, že štátna moc bude využívať svoje možnosti spôsobmi, ktoré

nebude možné zvrátiť a ktoré budú znamenať generovanie nespravodlivosti a tým aj znižovanie dôvery voči štátnym inštitúciám.

- Rovnosť v zaobchádzaní - riziko spočíva v nedostatočnej kapacite alebo schopnosti algoritmických regulačných systémov pôsobiť nediskriminačne voči historicky marginalizovaným skupinám osôb. V minulosti sa ukázalo, že mnoho technológií pracujúcich s dátami sú z povahy diskriminačné. Bolo tomu tak aj kvôli tomu, že sa aspekty ako rovnosť, férovosť alebo spravodlivosť pri vytváraní dizajnu systému nebrali do úvahy, pričom takýto prístup je pre budúcnosť neprijateľný.

3.3 Zavedenie systému algoritmickej regulácie

Zavedenie systému algoritmickej regulácie je extrémne náročná úloha, a to hlavne ak má fungovať kvalitne a bez zásadnejších chýb, ktoré môžu mať za určitých okolností veľmi závažné dôsledky nielen pre štát ale najmä pre osoby, na ktorých sa takáto regulácia vzťahuje. Ako bolo uvedené vyššie, algoritmická regulácia má určité limity a riziká týkajúce sa vo všeobecnosti kvality dát, etických princípov, ako aj právneho a ústavného rámca.

Táto podkapitola obsahuje jednak možnosti ako sa vyrovnáť s týmito limitmi, ale aj spôsoby ako pristúpiť k vývoju a dizajnu systému algoritmickej regulácie prostredníctvom nájdenia správneho modelu regulácie, a tiež spôsoby, ktoré zvýšia šancu, že implementácia a prevádzka takéhoto systému splní stanovené ciele algoritmickej regulácie, a to pri minimalizácii negatívnych dôsledkov

3.3.1 Základné otázky

Aj vzhľadom k obmedzeným skúsenostiam s takouto formou regulácie, je pred rozhodnutím o použití algoritmickej regulácie, resp. algoritmických rozhodovacích procesov, nevyhnutné venovať dostatočný čas expertnej diskusii o nasledujúcich základných otázkach:

- Aké sú ciele zavedenia algoritmickej regulácie? Zásadným a prvým krokom pre úspešnosť systému algoritmickej regulácie je definovanie jasných, zrozumiteľných a realistických cieľov, ktoré má štát pomocou algoritmickej regulácie dosiahnuť.
- *Je celkovo vhodné použiť algoritmickú reguláciu pre danú oblasť, ktorú chceme regulovať?* V rámci odpovede na túto otázku je potrebné nakresliť hranice spojené s etickými, technickými a právnymi podmienkami, ktoré sú v danej oblasti aplikované, a ktoré nesmú byť algoritmickou reguláciou prekročené. Napríklad v prípade, že dáta, ktoré sú v tejto oblasti k dispozícii nie sú kvalitné alebo nie sú vôbec k dispozícii v takom stave, aby boli použité aspoň na kvalitné testovanie systému, len ťažko sa dá uvažovať o použití algoritmickej regulácie.
- *Aký má byť právny rámec a obmedzenia algoritmického rozhodovacieho procesu?* Výsledkom diskusie o týchto otázkach by mali byť jasné usmernenia obsahujúce pravidlá pre implementáciu algoritmického regulačného systému, napríklad aké kompetencie majú mať osoby, ktoré majú interpretovať výstupy zo systému alebo či budú oprávnení korigovať výstupy algoritmického rozhodovania, alebo tiež či nemajú byť niektoré skupiny osôb spod plánovanej regulácie vyňatí. Úprava podmienok implementácie závisí od vyhodnotenia toho, ako osoby s rozhodovacími právomocami interagujú so systémom algoritmického rozhodovania a regulačnými rozhodnutiami týkajúcich sa technických otázok týkajúcich sa informovania o výkonnosti systému pre určité kategórie dát.
- *Aký má byť optimálny dizajn systému pre algoritmické rozhodovanie?* Systém by mal obsahovať kvalitatívne indikátory, na základe ktorých sa bude vyhodnocovať napríklad od akej miery je systém schopný predvídať. Takisto by mal systém obsahovať aj indikátory férovosti. Keďže systémy často rozdeľujú osoby na základe ich charakteristík do rôznych skupín, je nevyhnutné zabezpečiť, že algoritmické rozhodovanie nebude voči niektorým skupinám pôsobiť neférovou alebo dokonca diskriminačne.

-
- *Ako by mala vyzerat implementacia systému algoritmickeho rozhodovania v socio-technickom prostredí? Nemenej dôležité ako vytvorenie systému, je tiež jeho implementacia a využívanie v praxi, pretože aj takmer dokonalý systém, ktorý je ľuďmi nesprávne používaný, bude generovať nesprávne alebo nepresné rozhodnutia alebo výstupy. Detailné odpovede na túto otázku by mali byť obsiahnuté v socio-technickej hodnotiacej štúdii, ktorá pomôže zlepšiť samotnú implementáciu, ale príslušným spôsobom aj upraviť právny a regulačný rámec.*

3.3.2 Výber vhodných dát

Ešte predtým ako môže začať budovanie vhodného modelu, je potrebné preskúmať:

- aké tréningové dáta budú použité pre budovanie algoritmu?
- sú tréningové dáta primerané kontextu, v ktorom sa systém vytvára a v ktorom bude aplikovaný?
- aká je kvalita tréningových dát, resp. je kvalita týchto dát dostatočná pre budovanie algoritmu?

Pokiaľ ide o kontext, vo svete sú známe prípady pokusov o zavedenie algoritmickej regulácie, v rámci ktorých boli ako tréningové dáta použité dáta pochádzajúcej z inej krajiny, ktorá bola z viacerých hľadísk odlišná od krajiny, kde sa tréningové dáta použili. Následne museli byť tieto dáta opravené a použité také, ktoré zodpovedali kontextu, v ktorom sa algoritmickej regulácii mala aplikovať. Počas testovania sa zistilo, že pôvodné dáta neboli schopné zabezpečiť, aby boli dosiahnuté ciele vytýčené na začiatku celého procesu prípravy regulácie.

Rovnako ako kontext je dôležitá kvalita použitých tréningových dát. V rámci prípravy algoritmickej regulácie je preto nevyhnutné vyhodnotiť, či:

- nechýbajú potrebné dátové body (dátový bod je jednotlivá informácia odvodená z merania alebo z výskumu, označuje sa aj ako dátová položka)
- spoľahlivosť a validita dát nie je nejasná alebo pochybná (vzhľadom na to ako a odkiaľ boli dáta generované).

Ako príklad môžeme v tomto prípade použiť reportovanie trestnej činnosti, ktoré ako je známe, nie je zďaleka presné vzhľadom na reálne páchanú trestnú činnosť. Do štatistík sa dostáva len časť reálne spáchaných trestných činov, pričom z výskumov vyplýva napríklad to, že trestné činy majetkové sú reportované v číslach, ktoré sú realite bližšie a naproti tomu, trestné činy spojené s domácim násilím, sú reportované oveľa menej ako sa v skutočnosti dejú.

Vzhľadom k tomu, je nutné brať tieto špecifiká týkajúce sa kvality a spoľahlivosti dát pri príprave algoritmickej regulácie do úvahy, pretože použitie neobjektívnych tréningových dát bez zohľadnenia tohto aspektu, bude mať s najväčšou pravdepodobnosťou negatívny dopad na fungovanie a výsledky algoritmickej regulácie.

3.3.3 Budovanie vhodného modelu regulácie

V rámci budovania modelu algoritmickej regulácie dátoví vedci prispôbujú rôzne modely, aby predvídali želaný výsledok na základe tréningových data-setov. Tento proces by mal byť sprevádzaný viacerými dôležitými rozhodnutiami týkajúcich sa oblastí, ktoré môžeme rozdeliť do nasledujúcich štyroch skupín:

- *Etické dilemy* týkajúce sa premenných veličín, ktoré majú byť použité pre budovanie modelu algoritmickej regulácie. Napríklad "priamo diskriminačné" veličiny týkajúce sa rasy alebo etnicity. Je neprípustné, aby bola s osobou zaobchádzané horšie na základe rodu, etnicity alebo rodinného zázemia. Ak by tomu tak bolo, došlo by k narušeniu princípu rovnosti a zároveň by podkopávalo dôveryhodnosť a rešpekt k regulácii.
- *Štrukturálne znevýhodnenia*, ktorých prítomnosť v systéme algoritmickej regulácie by u zraniteľných skupín osôb mohli spôsobovať reprodukciu znevýhodnení a prehlbovanie ich

zraniteľnosti. Toto sa môže stať špeciálne v spoločnostiach, ktorých súčasťou sú štrukturálne znevýhodnené skupiny ľudí, kde títo ľudia čelia znevýhodneniam naprieč rôznymi sociálnymi sférami (Esser, 2019). Algoritmy musia byť vybudované tak, aby boli férové a preto musia byť do ich vytvárania zapojení experti na etiku a politické diskusie na túto tému musia brať do úvahy postavenie a možnosti zraniteľných skupín.

- *Otázka kauzality* je ďalším aspektom, ktorý musí byť zvažovaný. Vo viacerých oblastiach, v ktorých môže byť použitá algoritmická regulácia alebo algoritmické rozhodovanie existujú mnohoročné empirické výskumy. Takisto existujú solídne empirické zistenia obsahujúce možné vysvetlenia určitých javov, teda prečo alebo ako tieto javy vznikli, ako sa v čase vyvíjali a čo spôsobovalo ich prípadné zmeny. Tieto výskumy a zistenia by mali byť využité v rámci budovania algoritmov. Tieto vysvetlenia by mali byť priamo zabudované do algoritmov, prípadne by dátoví vedci mali jednoducho hľadať vzorce v dostupných dátach, a to tak aby našli korelácie, ktoré budú následne využité pri budovaní modelu pre systém algoritmickej regulácie.
- *Výber metódy pre budovanie modelu*, v rámci ktorého je dôležitou otázkou povaha predpokladaného výsledku, teda či má byť povaha výsledku binárna (napríklad “áno-nie”), ordinálny (usporiadaný do poradia ale bez určenia hodnôt jednotlivých možností) alebo metrický (merateľný, obsahujúci hodnotu, obsahujúci hodnotu vyjadrenú napríklad v číslach). Aj v prípade, že úroveň zisťovania určitého výsledku je vopred známa, väčšinou môže byť použitých niekoľko metód, ktoré je potrebné zvážiť, pretože každá metóda má svoje výhody aj nevýhody, ktoré môžu mať pre rôzne zámery alebo ciele rôzne následky, ktoré môžu mať rôzny vplyv na dosiahnutie cieľov regulácie.

3.3.4 Hodnotenie modelu regulácie

Štvrtou fázou budovania prípravy algoritmickej regulácie a budovania jej modelu je hodnotenie modelu pred jeho spustením a prevádzkou, pričom táto fáza by mala byť zameraná na dva nasledujúce aspekty:

- A) **Zhodnotenie kvality a výkonnosti systému**, teda ako dokáže systém doručiť želané výsledky algoritmickej regulácie

V súčasnosti existujú viaceré druhy kvalitatívneho merania, ktoré sú spôsobilé vyhodnotiť vhodnosť navrhovaného modelu, ako napríklad precision (presnosť systému), recall (kvantitatívny údaj o počte správnych pozitívnych predikcií z celkového počtu pozitívnych predikcií), alebo ROC AUC (krivka ukazujúca výkonnosť klasifikačného modelu na všetkých klasifikačných hodnotách).

Je dôležité vybrať adekvátny model s prihliadnutím na klasifikačný model. Prvé kritérium je balans alebo rovnováha dát. Toto je veľmi dôležité, lebo v prípade, že data-setsy nie sú vybalansované, niektoré meradlá kvality, napríklad presnosť, nedokážu reflektovať skutočnú kvalitu systému.

Pre meranie kvality je dôležité brať úvahy aj to, v akej forme má systém dodávať výsledky, teda či majú byť tieto výsledky binárnej povahy alebo vo forme určenia poradia. Určenie poradia môže byť transformované do binárnej formy, ale dochádza k strate určitých informácií.

V prípade, že systém používa binárne klasifikačné označenia, najdôležitejšie je rozhodnutie, či sú viac problematické falošne pozitívne (FP) alebo falošne negatívne (FN) chyby. Tieto otázky by mali diskutované vo väčších zmiešaných tímoch zložených z dátových vedcov a expertov na etiku a vytváranie verejných politík, pretože rozhodnutie či minimalizovať falošne pozitívne chyby alebo falošne negatívne chyby reflektuje na kvalitatívne meradlá, ktoré majú byť nakoniec vybrané.

- B) **Zhodnotenie férovosti systému**, a to najmä pokiaľ ide o klasifikáciu jednotlivcov na základe skupinových charakteristík

Aj systém algoritmickej regulácie, ktorý spĺňa kvalitatívne požiadavky alebo kritériá, môže byť zároveň neférový. Aj pre zhodnotenie férovosti systému existujú spôsoby merania, problém je, že väčšina z nich je matematicky navzájom v konflikte, pretože pracujú s rôznymi definíciami férovosti. To znamená, že nie je uskutočniteľné, aby systém spĺňal všetky matematické kritériá férovosti súčasne dosahoval vysoké hodnoty férovosti vo všetkých druhoch meraní.

Preto je dôležité vybrať také spôsoby merania férovosti, ktoré sú správne pre určitý kontext. Pre takéto rozhodnutie by mali byť zodpovedané nasledujúce otázky:

- Na akej úrovni (skupinová alebo individuálna) by mala byť férovosť hodnotená?
- Je k dispozícii objektívna pravda?
- Na ktorej úrovni je dôležitá parita?
- Ktoré páry jednotlivcov by mali dostať podobný výsledok?

Na tieto otázky by dať odpoveď multidisciplinárne tímy zložené z odborníkov na rôzne oblasti relevantné pre daný systém.

Skupinové kritéria férovosti zaisťujú nejakú mieru distributívnej parity pre členov rozličných relevantných sociálnych skupín a individuálne kritéria férovosti zabezpečujú, aby s akýmkoľvek párom jednotlivcov, ktorí sú podobní, systém zaobchádzal podobne.

Ak je rozhodnuté, že sa na zhodnotenie férovosti systému algoritmickej regulácie sa vykoná na skupinovej úrovni, výber spôsobu merania férovosti bude závisieť najmä od toho, či je k dispozícii "objektívna pravda". Väčšina spôsobov merania férovosti je založená na myšlienke porovnať kvalitatívne kritériá naprieč rozličnými senzitívnymi skupinami, čo je procedúra, na vykonanie ktorej je potrebná objektívna pravda. Túto procedúru totiž nie je možné efektívne vykonať len na základe domnienok.

V prípade, že sa bude férovosť systému hodnotiť na individuálnej úrovni, mali by byť použité individuálne spôsoby merania férovosti. Kľúčovou otázkou v tomto prípade potom bude, ktorý pár jednotlivcov by mal dostať podobný výsledok. Na tejto úrovni sú dve hlavné kategórie spôsobov merania férovosti:

- Individuálne meranie férovosti, ktoré indikuje, či je výsledok systému rovnaký pre rovnakých jednotlivcov. Toto meranie zvažuje páry rovnakých alebo podobných jednotlivcov a kontroluje, či je pre nich výsledok systému rovnaký. Pre tento typ merania sa vyžaduje aj meranie podobnosti, aby sa mohli najskôr identifikovať podobní jednotlivci, ktorý vytvoria pár.
- Kontrafaktuálne meranie férovosti, je také, v ktorom bude výsledok systému pre akéhokoľvek člena senzitívnej skupiny (na základe rasy, etnicity, sexuálnej orientácie alebo rodu) taký istý, ako keby bol z inej skupiny. Pre vykonanie kontrafaktuálneho merania férovosti sa použije bežný graf prívlastkov alebo vlastností jednotlivca, na základe ktorého sa vyberie pár jednotlivcov. Jeden z tohto páru bude mať určité prívlastky alebo vlastnosti a druhý bude mať v rámci senzitívnych prívlastkov opačné hodnoty, ale v ostatných prívlastkoch bude podobný alebo rovnaký. Na základe tejto párovacej procedúry by malo meranie ukázať, či systém ako je navrhnutý nenarušuje princíp rovnosti.

3.3.5 Implementácia algoritmickej regulácie

Finálnou fázou prípravy systému algoritmickej regulácie je jeho implementácia a uvedenie do praxe. V rámci tejto fázy je potrebné vykonať nasledovné kroky:

A) Overenie, či nová algoritmickej regulácia prináša zvýšenie efektivity procesov a rozhodnutia vo vyššej kvalite ako ľudia

Táto otázka, resp. odpoveď na ňu je najdôležitejšou zo všetkých, keďže úspešnosť systému bude hodnotená najmä podľa toho, či systém dokáže naplňať zadané ciele, a to vo vyššej kvalite a efektívnejšie, ako tomu bolo doteraz. Odpoveď na túto otázku zároveň môže ovplyvniť rozhodnutia týkajúce sa ďalších krokov, najmä ak by výstupy systému boli menej kvalitné ako výstupy pochádzajúce od ľudí.

Preverenie kvality môže byť vykonané prostredníctvom empirickej štúdie, teda porovnávaním výstupov z minulosti, s to najmä pokiaľ sa skúma kvalita a férovosť systému. Pokiaľ ide skúmanie výkonnosti

systemu, je možné jednoducho porovnávať celkové súčty výstupov v jednotlivých podoblastiach alebo celkovo za daný čas.

Treba zdôrazniť, že je dôležité, aby nový systém spĺňal stanovené štandardy vo všetkých oblastiach, teda aj pokiaľ ide o výkonnosť, efektívnosť, aj v oblasti kvality a v neposlednom rade aj pokiaľ ide o zabezpečenie vysokej férovosti systému.

B) Zhodnotenie, či funguje interakcia medzi technológiou a ľuďmi, ktorí s ňou majú pracovať

Do tohto kroku by mali byť určite priamo zapojení pracovníci toho úseku verejnej správy, ktorí budú so systémom pracovať alebo budú prichádzať do kontaktu s algoritmickej reguláciou v rámci plnenia svojich pracovných kompetencií. Tento krok je ešte dôležitejší v prípade, že systém bude hrať podpornú úlohu v rámci rozhodovania vykonávaného ľuďmi, napríklad vo forme tzv. informovania rozhodnutí, kedy systém pomocou algoritmov pripraví podklad alebo návrh rozhodnutia a pracovník pri svojom rozhodovaní vezme do úvahy a vyhodnotí jednak vstupy poskytnuté systémom a jednak svoje vlastné skúsenosti, vedomosti a úsudok.

V tejto súvislosti treba uviesť aj riziko, ktoré by malo byť vhodne manažované a ktorým je prílišné spoliehanie sa na výstupy systému, a to aj v prípade, že systém má plniť len podpornú funkciu a naopak, rizikom je aj možnosť, že pracovníci nebudú z nejakého dôvodu brať do úvahy vstupy a podklady vygenerované systémom.

Takýmito dôvodmi pre neadekvátne využívanie systému môžu byť napríklad nedostatočný tréning pracovníkov pre prácu so systémom, obavy rozhodnúť inak ako navrhuje systém a prevziať za to zodpovednosť, nedostatky v dizajne alebo v užívateľskej priateľskosti systému a podobne.

Vykonanie tohto kroku tak dáva príležitosť vykonať úpravy systému alebo zmeny v príprave pracovníkov na prácu so systémom.

C) Kontrola, či sú pravidlá pre fungovanie systému správne nastavené a či je systém pripravený na implementáciu a spustenie

Pravidlá, podľa ktorých má fungovať systém aj pracovníci, musia byť otestované, či spĺňajú požiadavky vzhľadom na ciele regulácie, ako ja na citlivosť oblasti, ktorá má byť systémom regulovaná.

Táto miera citlivosti môže byť určená tým, do akých práv a do akej miery môže regulácia ovplyvňovať ľudí alebo iné regulované subjekty. Ďalšou možnosťou zistenia miery citlivosti je zhodnotenie skupín ľudí a toho či trpia štrukturálnymi znevýhodneniami. V takom prípade, musia byť kritériá prísnejšie a opatrnosť pri spustení vyššia.

Takisto je dôležité skontrolovať plán implementácie, uvedenia systému so prevádzky a prípravu samotnej prevádzky systému, ako aj zabezpečenie ľudských zdrojov a ich kompetencií pri prevádzke systému.

3.3.6 Zhrnutie a záverečné odporúčania

Na záver je potrebné pripomenúť a zdôrazniť, že vo všeobecnej rovine je pri vytváraní systému algoritmickej regulácie tak, ako pri akejkoľvek inej regulácii, nevyhnutné konceptualizovať jej použitie ako mnohvrstevného systému, ktorý zahŕňa cyklické procesy.

Takýto systém je výsledkom nielen politických a administratívnych rozhodnutí, ale tiež rozhodnutí technického a technologického charakteru. Vývoj systému algoritmickej regulácie je ovplyvnený hodnotením jeho výkonnosti, ktoré by následne malo viesť k zmenám systému, resp. ku kontinuálnym úpravám, ktoré by mali priebežne zlepšovať nielen výkon, ale najmä kvalitu systému a jeho výstupov.

Súčasťou tohto cyklického procesu priebežného hodnotenia by mal byť aj proces experimentovania, a to pred implementáciou aj po implementácii systému a na oboch úrovniach, socio-technickej aj technickej.

Tieto cyklické procesy hodnotenia a experimentovania by mali dať správne podklady pre finálne rozhodnutie o implementácii a spustení systému algoritmickej regulácie, resp. o tom ako by mal byť samotný systém regulovaný. Okrem toho tieto procesy umožňujú zainteresovaným osobám v rámci

verejnej správy ale aj verejnosti, aby boli zahrnutí do vývoja systému, čo je obzvlášť dôležité pri reguláciách, ktoré sa týkajú citlivých oblastí alebo znevýhodnených osôb.

Tabuľka 5: Usmernenia pre rozhodnutie o zavedení systému algoritmickej regulácie (M. A. Haeri et al., 2021)

Fáza	Usmernenia
<i>Všetky fázy</i>	<p>Vykonávať cyklické experimentovanie a hodnotenie systému.</p> <p>Hodnotenie vykonávať prostredníctvom nezávislého tímu expertov.</p> <p>Nehodnotiť len technické aspekty dizajnu, ale aj z hľadiska implementácie systému.</p>
<i>Rozhodnutie o implementácii algoritmickej regulácie</i>	<p>Definovať hranice z hľadiska kvality dát, etických princípov a právneho rámca.</p> <p>Využívať vstupy expertov z rôznych oblastí (etika, právo, príprava verejných politík atď.)</p> <p>Zahrnúť do procesu prípravy občanov a hráčov s demokratickou legitimitou.</p>
<i>Rozhodovanie o spravovaní algoritmickej regulácie</i>	<p>Zhodnotiť intenzitu regulácie a zásahy regulácie do života jednotlivých osôb a skupín ľudí.</p> <p>Zahrnúť do procesu tvorcov verejných politík, osoby zasiahnuté reguláciou (najmä ak ide o znevýhodnené osoby)</p> <p>Zaviesť proces dynamickej spätnej väzby v rámci experimentálnych procesov, a to aj po uvedení systému do praxe.</p> <p>Získať rozhodnutie príslušného orgánu/inštitúcie s demokratickou legitimitou.</p>
<i>Dizajn a vývoj algoritmickej regulácie</i>	<p>Diskutovať o problémoch s dátami, budovaním modelu regulácie a hodnotením modelu.</p> <p>Spolupracovať s expertmi na etiku a dátovými vedcami pri výbere alternatív v rámci budovania modelu regulácie a otázok týkajúcich sa diskriminácie.</p> <p>Vytvoriť multidisciplinárne tímy pre zhodnotenie opatrení pre zabezpečenie férovosti a kvality systému.</p> <p>Získať rozhodnutie príslušného orgánu/inštitúcie s demokratickou legitimitou o opatreniach pre zabezpečenie férovosti a kvality systému.</p>

<i>Implementácia algoritmickej regulácie</i>	<p>Zhodnotiť interakciu medzi technológiou a človekom v reálnom kontexte.</p> <p>Na základe empirickej analýzy zhodnotiť, či použitie algoritmickej regulácie zaistí lepšie rozhodnutia.</p> <p>Zaznamenať ako nová algoritmickej regulácia zmení rozhodovacie procesy.</p> <p>Zabezpečiť kvalitný kontinuálny tréning pracovníkov, ktorí pracujú so systémom.</p> <p>Zpracovať spätnú väzbu k vykonaniu implementačnej fázy do rozhodnutí ohľadom rámca pre spravovanie systému jednak v experimentálnej fáze a tiež po uvedení systému do prevádzky pre kontinuálne zlepšovanie systému.</p>

4 Návody

— aktualizácia príručiek a návodov

Tabuľka 6: Prehľad oblastí vo verejnej správe, kde je možné zlepšiť rozhodovanie

Oblasť	Použitie	Príklady aplikácie v praxi
Lepší návrh politik a regulácií	Posudzovanie vplyvov regulácií pomocou veľkých dát: vďaka online posudzovaniu vplyvov a využitiu údajov na simulácie dopadov a testovanie účinnosti politik.	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


4.1 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 politik.

4.1.1 Úvod

Základným konceptom, ktorým sa budeme zaoberať v tejto kapitole je regulačná funkcia štátu. Regulácia je nevyhnutná pri naplňaní 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 1: 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 transparentnému 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.

4.1.2 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 prehľadnosť 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 prístupíť 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.

4.1.3 Transformácia

Ak máte záujem modernizovať posudzovanie vplyvov vo vašej inštitúcii, 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.

- **Zavedte 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 aspoň minimalizovať,
- **Zavedte 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.
- **Zavedte 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 vymožitelnosti práva – zúčtovateľnosti vlády. Začnite z už platnými predpismi a postupne eliminujte všetky predpisy, ktorých vplyv je negatívny.

4.1.4 Najlepšia prax

Platforma vTaiwan pre konštruktívnu participáciu pri návrhu politik a regulácií na Taiwane³

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

³ <https://www.technologyreview.com/s/611816/the-simple-but-ingenious-system-taiwan-uses-to-crowdsource-its-laws/>

tvorcom politik 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 ankieta. 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 počínom, ktorý sa vďaka svojmu inštitucionálnemu rozmeru a aspektom teší čoraz väčšej popularite a pozornosti doma aj v zahraničí.

4.1.5 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 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 priniesť 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 preparametrizované

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

4.2 Lepší dozor a dohľad nad regulovaným 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.

4.2.1 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 správajú,
- o tom, aké sú spoločenské a ekonomické dôsledky takéhoto správania,
- 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.

4.2.2 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 Bolt); od platforiem, ktoré sprostredkovávajú ubytovanie (AirBnB) alebo napríklad od utilityných 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 nedodržiavaním 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 prístupu 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.

4.2.3 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 regulácii. 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 predstavovať 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 subjektov. Výrazne tým znížite administratívnu záťaž pre subjekty a podporíte rast konkurencieschopnosti.
- V prípade potreby sledovať toky hodnoty (tovary, služby a ich certifikácia), zväžte 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 tréning 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 počítat 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.

Zaved'te do praxe systematický zber údajov

Aby mohol model predikovať budúci stav regulovanej oblasti potrebuje k dispozícii tréningovú množinu dát ako i aktuálny tok údajov, s ktorého sa dá vyvodit 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 navrhnuť kvalitné API (rozhrania), dostatočne 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 riad'te 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 dostupnú klientsku podporu (pozri aj časť 7.5 venovanú zvyšovaniu kvality služieb vďaka využitiu inteligentných asistentov) a digitalizácia všetkých aspektov služby. Pri dizajne služby využite 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 počítat 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 vybavení 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, navigácii 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.

4.2.4 Najlepšia prax

Inteligentné spôsoby monitorovania solárnej energie v Holandsku⁴

Slnecná 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 slnecnej energie.

⁴ <https://www.cbs.nl/en-gb/our-services/innovation/project/automatically-detect-solar-panels-with-aerial-photos>

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.

4.2.5 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 pozeráť 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 pozícií 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.

4.3 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.

4.3.1 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 algoritmy (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	— Rýchlosť
— Improvizácia	— Presnosť
— Úsudok	— Predpovedanie budúceho stavu
— Obratnosť	— Škálovateľnosť
— Sociálne a líderske schopnosti	

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.

4.3.2 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 so 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 najlepšimi rozhodnutiami bude potrebné trénovať a budú sa zlepšovať postupne. Pôjde o dynamickú skúsenosť. Tieto nástroje nepovedú len k automatizácii 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).

4.3.3 Transformácia

Vytvorte tím pre zber údajov a tréning algoritmov

Aby dokázali nástroje postavené na umelej inteligencii pomôcť v úlohách a rozhodovaní, je potrebné zabezpečiť neustály zber údajov pre vylepšovanie a tréning algoritmu. Ide o úplne novú rolu (ktorú by mala zastrešiť napríklad rezortná Dátová kancelária), o ktorej sa v tradičnej organizácii 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 datasey 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)⁵.

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 skrátí čas. Úradník sa tak môže sústrediť na činnosti, kde potrebuje 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:

⁵ <https://medium.com/intel-student-ambassadors/local-interpretable-model-agnostic-explanations-lime-the-eli5-way-b4fd61363a5e>

-
- ktoré kroky je možné automatizovať (pomocou automatizácie spracovania, pomocou získania informácií cez dátovú integráciu, pomocou získania informácií 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,
 - navrhnete plánovanú cestovnú mapu modernizácie procesov vo vašej organizácii.

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 politik, ktoré budú navrhované so zapojením verejnosti,
- nasadzte nástroje pre kolaboráciu verejnosti,
- zorganizujte podujatia, ako hackathony, fokusové skupiny a iné formy občianskej participácie.

4.3.4 Najlepšia prax

Nasadenie umelej inteligencie v súdnictve v Spojených štátoch⁶

V Spojených štátoch amerických momentálne prebieha vážna diskusia⁷ medzi právnikmi, expertmi na technológie a aktivistami o správnom využívaní 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.

⁶ <https://obamawhitehouse.archives.gov/the-press-office/2016/06/30/fact-sheet-launching-data-driven-justice-initiative-disrupting-cycle>

⁷ <https://medium.com/legal-design-and-innovation/ai-goes-to-court-the-growing-landscape-of-ai-for-access-to-justice-3f58aca4306f>

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 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 prehĺbuje 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.

4.3.5 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 havárii 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 Agendy

- výber agend pre Regulácie 2.0,
- návrh postupov ako bude agenda fungovať a
- návrh konkrétnych riešení pre vybrané agendy.

5.1 Rozhodovacie procesy

V nasledujúcej kapitole je prehľad, akým spôsobom môžeme vylepšiť jednotlivé typy rozhodovacích procesov cez dátové riešenia. Zámerom je pokryť základné procesy fungovania agendy inštitúcie, ktorá sa venuje regulácií a navrhnúť, ako by mohli fungovať:

- Obsluha klientov a poskytovanie služieb,
- Vydávanie rozhodnutí v rámci konania (správneho, súdneho),
- Kontrolná činnosť a štátny dohľad a dozor,
- Operatívna alokácia zdrojov,
- Plánovanie a predvídanie budúceho dopytu po verejných službách.

5.1.1 Obsluha klientov a poskytovanie služieb

Front-office procesy môžu byť zásadne zlepšené a zjednodušené zavádzaním inteligentných agentov ako osobných asistentov, pre riešenie životných situácií, ale i právne poradenstvo a podobne. Za základné aplikácie pri poskytovaní služieb je možné považovať:

- hlasová asistencia,
- "chatboti" pre zjednodušenie vzťahu
- navigácia cez životné situácie,
- personalizované služby a proaktívna identifikácia nárokov a povinností pre klientov,
- automatizované spracovanie žiadostí a online digitálne služby,
- podpora pracovníkov kontaktných centier a front-office pri vybavovaní klientov.

S využitím týchto nástrojov dokážeme premeniť vzťah klienta a inštitúcie verejnej správy: výrazne zvýšiť efektivitu obsluhy a používateľský zážitok s digitálnou službou. Modernizácia front-office procesov má zmysel pre inštitúcie všetkých veľkostí, konkrétna architektúra kanálov obsluhy bude závisieť od objemu a charakteru obsluhy. Trendom je prechod na digitálny kanál s maximálnou mierou personalizácie, čomu môže zodpovedať zníženie počtu pobočiek.

5.1.2 Vydávanie rozhodnutí v rámci konania (správneho, súdneho)

V prípade vydávania rozhodovania je prvým krokom expertný systém, snaha o návrh vhodného rozhodnutia algoritmom. Pravidlá verejnej správy často umožňujú vytvoriť priamo expertný systém, ak je k dispozícii viacero dát, dá sa navrhnuť i riešenie, ktoré predpovedá rozhodnutie úradníka, čo má zmysel najmä pre spracovanie neštruktúrovaných údajov. V mnohých prípadoch je úplná automatizácia príliš

citlivá (napríklad v zdravotníctve alebo v prípade súdnych rozhodnutí) a odporúčame ponechať človeka v rámci rozhodovacieho cyklu ako poslednú autoritu.

V rámci správnych a súdnych konaní je možné pomocou umelej inteligencie posilniť respektíve automatizovať nasledujúce procesy:

- Identifikácia súladu s pravidlami a procesmi, identifikácia chýbajúcich náležitostí.
- Expertné posúdenie zhody so súborom pravidiel (napríklad stavebné alebo hygienické predpisy).
- Analýza predchádzajúcich prípadov a výsledkov.
- Predikcia rizika v danom prípade.
- Pred-vyplnenie rozhodnutia.
- Posúdenie odvolania.

5.1.3 Kontrolná činnosť a štátny dohľad a dozor

Kontrolná činnosť zohráva dôležitú úlohu v rámci regulačnej kapacity verejnej správy. Jej hlavným cieľom je monitorovať a hodnotiť dodržiavanie predpisov, noriem a politík v rôznych oblastiach a odvetviach. Vykonávaním kontroly sú identifikované možné nedostatky, porušenia a nezrovnalosti, ktoré sa následne riešia a sankcionujú. Generický procesný model pre kontrolnú činnosť je možné definovať ako:

- Evidovanie regulovaných subjektov a udalostí.
- Zber a spracovanie informácií.
- Plánovanie kontrolnej činnosti.
- Výkon kontrolnej činnosti.
- Udeľovanie sankcií.
- Riešenie nápravných opatrení.

Jednotlivé procesy je možné podporiť pomocou algoritmických nástrojov a výrazne tak zlepšiť kontrolu dodržiavania regulácií.

Evidovanie regulovaných subjektov a udalostí

Pre efektívne vykonanie inšpekcie alebo kontroly musia mať orgány dohľadu a dozoru k dispozícii všetky potrebné a aktuálne údaje, ktoré budú synchronizované s ostatnými agendovými systémami. Je preto potrebné evidovať kontrolovateľné objekty a evidencia objektov, skutočností a udalostí. Tieto registre a evidencie môžu slúžiť na plánovanie a vykonávanie jednotlivých inšpekcií. V podstate ide o vybudovanie a rozvoj klasického informačného systému verejnej správy, ktorý je však integrovaný cez centrálnu integračnú platformu s ostatnými administratívnymi zdrojmi údajov a tak dokáže zabezpečiť prístup k aktuálnymi údajom o subjektoch.

Podľa charakteru evidovanej oblasti je potrebné vytvoriť štandardizovaný register vydaných osvedčení a licencií, udelených certifikátov a vykonaných skúšok. Odporúčaným formátom sú overiteľné dôkazy podľa štandardu popísaného v dokumente 1.1.2. *Štandardizácia pre modelovanie údajov*.

Kontrolované subjekty by mali disponovať svojim profilom s relevantnými informáciami o minulých, prebiehajúcich a plánovaných kontrolách. Profil subjektu vzniká pri jeho prvej registrácii k podnikateľskej činnosti. Tento profil a všetky súvisiace údaje by mal byť dostupné cez služby Manažmentu osobných údajov.

Zber a spracovanie informácií

Procesy zberu a spracovania informácií sú podrobne popísané v časti Procesy manažmentu údajov. Z pohľadu výkonu agendy je vhodné, aby boli digitálne podporované a čiastočne automatizované činnosti, ako: vyhodnotenie dostupných informácií z monitoringu regulovaného prostredia, analyzovanie rizík a vyhodnotenie skúseností z plánovania. Zavedie sa tak do celého procesu mechanizmus spätnej väzby a bude možné:

- Učiť sa realizovať kontrolnú činnosť lepšie. Vďaka sledovaniu minulých období bude možné identifikovať nedostatky a navrhnúť tak nápravné opatrenia pre danú oblasť.
- Sledovať vhodnosť regulácie. Z informácií bude možné tiež zistiť užitočnosť navrhovaných či platných pravidiel inšpekcií a kontrol.

Plánovanie kontrolnej činnosti

Vďaka nasadeniu dátových riešení je možné výrazne zvýšiť úspešnosť kontrol a pravdepodobnosť, že nebude dochádzať ku kontrole správnych riešení, alebo že podvodné alebo nesprávne riešenia uniknú kontrole. Výsledkom bude precízne kontrolovanie problematických transakcií a subjektov a zníženie záťaže pre subjekty, ktoré nepodvádzajú. Využitie nástrojov dátovej vedy sa odporúča inštitúciám ako je ÚVO, Finančná správa, NKÚ.

V rámci plánovania kontrol je možné zlepšiť nasledujúce procesy:

- Identifikácia podozrivých prípadov na základe minulosti v celej škále prípadov (ad-hoc, na základe aktuálnej situácie).
- Návrh optimálneho plánu kontrol z cieľom eliminácia možných problémov.
- Ex-post hľadanie chýb.
- Ex-ante posudzovanie návrhov, projektov a obstarávaní a identifikácia rizík.

Mechanizmus plánovania: Dôležitou činnosťou je vytváranie plánov kontrolnej činnosti (dozoru a dohľadu) a ich aktualizácia na základe definovaných požiadaviek v zásobníku a ako i na základe spracovania údajov o regulovanom prostredí a analýzy rizík. Na základe plánu môžu byť automatizovane pridelované konkrétne úlohy jednotlivým úradníkom. Pre definované aktivity kontrolovaných subjektov sa sledujú termíny. Pri ich nedodržaní sa automaticky dostávajú do zásobníka. Po naplánovaní by malo byť možné zobrazíť denné aktivity a úlohy ako napríklad zoznam elektronických dokumentov ku kontrole alebo k schváleniu.

Výkon kontrolnej činnosti

Tento proces je zameraný na vykonanie naplánovanej kontrolnej činnosti (dohľadu alebo dozoru):

- realizáciu počiatkovej alebo priebežnej inšpekcie alebo
- overovanie odbornej a etickej spôsobilosti.

Je potrebné realizovať nasledujúce činnosti: oznámenie kontroly, vykonanie definovaného postupu inšpekcie alebo overenia, identifikáciu a doručenie zistených nedostatkov a zaevidovanie zozbieraných dôkazov.

Oznámenie kontroly je vhodné vykonávať elektronicky a to prostredníctvom notifikácie subjektu či prostredníctvom elektronickej schránky (pokiaľ nejde o neplánovaný typ kontroly, ktorý sa neoznamuje). Oznámenie kontroly je možné generovať automatizovane, na základe nastavených pravidiel na základe plánov kontrolnej činnosti.

V priebehu dozoru alebo dohľadu pracuje kontrolór s interaktívnym protokolom, pričom môže využívať aj informácie z minulých kontrol. Interaktívny protokol zoskupuje automatizované a manuálne kroky a je generovaný personalizovane pre daný prípad. Pri zistení nedostatkov (platí len pre tie, ktoré nebolo možné odstrániť počas kontroly) podnikateľ dostane zoznam a popis nedostatkov vygenerovaný z protokolu kontroly doručený aj elektronicky. Súčasne sa vygeneruje termín v pláne dozoru a dohľadu pre kontrolu nápravy. Aby bolo možné vykonávanie kontrolných činností v teréne, riešenie by malo byť prístupné cez mobilné zariadenie.

Riešenia umelej inteligencie je možné použiť na dokumentovanie dozoru a dohľadu: publikovanie informácie o kontrolách, tvorbu výstupných správ a generovanie štatistických prehľadov. V správach by bolo vhodné umiestňovať aj interaktívne prvky (napríklad grafy).

Udeľovanie sankcií

Proces je zameraný na presadzovanie dodržiavania pravidiel regulovaného prostredia prostredníctvom sankcií a na definovanie úhrad za spoplatnené výkony verejnej správy. Na základe analýzy protokolu je možné automatizované:

- vytvorenie podkladov pre udelenie sankcie.
- vyrubenie poplatku.

Orgány dozoru a dohľadu vypracovávajú podklady pre pokuty a to aj od externých kontrolných orgánov (napríklad pokuta od stavebného úradu alebo od obchodnej inšpekcie). V extrémnom prípade môže dôjsť až k trestnoprávnemu postihu a možnosti náhrady škody.

Riešenie nápravných opatrení

Po ukončení kontroly je možné podávať námietky k zisteným nedostatkom a riešiť rozhodovanie na vyššom stupni. Zodpovedný orgán vypracuje stanovisko k námietke, ktorú pošle kontrolovanému subjektu digitálne.

Kontrolovaný subjekt môže preukazovať splnenie povinností vyplývajúcich z kontroly, ideálne digitálne a automaticky. Po odstránení nedostatkov je možné uzavretie protokolu o kontrole.

5.1.4 Operatívna alokácia zdrojov

Vo väčšine prípadov pracujeme vo verejnej správe z obmedzenými zdrojmi. Preto každé zlepšenie efektivity využitia zdrojov môže výrazne pomôcť výkonnosti verejného sektora. Prvé aplikácie umelej inteligencie sa týkali práve oblastí, ako manažment zásob alebo podobne. V prípade verejnej správy je možné podporiť operačné centrá a centrálnie riadiť použitie zdrojov:

- Verejné obstarávanie.
- Plánovanie pracovných rozvrhov (napríklad policajných hliadok).
- Plánovanie údržby a využitia zariadení v správe organizácie.
- Skladové hospodárstvo.
- Operatívna alokácia zdrojov v krízovej situácií.

5.1.5 Plánovanie a predvídanie budúceho dopytu

Nástroje dátovej vedy umožňujú predvídať dopyt po budúcich verejných službách aj v dlhodobom horizonte a optimalizovať tak sieť verejných služieb, ako sú napríklad sieť a kapacita škôlok a základných škôl, rozsah služieb nemocníc a podobne. V oblasti verejného zdravotníctva môžeme modelovať budúci

zdravotný stav populácie alebo predikovať vývoj inflácie vo vzťahu k budúcej štátnej pomoci. Za základné aplikácie považujeme:

- Odhadovanie potrieb dopytu po jednotlivých verejných službách.
- Odhadovanie vývoja príjmov, ako i dopadov rozpočtových opatrení.
- Tento prístup je možné využiť aj na individuálne prípady a odhadovať pravdepodobnosť budúcich intervencií (v zdravotníctve pre pacienta, v sociálnej starostlivosti o deti, vo vzdelávaní).
- Predikcia budúcich krízových situácií.

Ak dokážeme odhadnúť, ako dopadne budúcnosť, môžeme lepšie presunúť zdroje tam, kde sú potrebné.

5.2 Návrh konkrétnych riešení pre vybrané agendy

Verejná správa realizuje regulačnú kapacitu v širokej škále agend a oblastí. Niektoré z hlavných agend, v ktorých sa vykonáva regulačná činnosť, zahŕňajú napríklad:

- Finančná regulácia: Verejné inštitúcie, ako napríklad centrálné banky a finančné orgány, majú za úlohu regulovať a dohliadať na finančný sektor. To zahŕňa dohľad nad bankami, poisťovňami, kapitálovými trhmi a ďalšími finančnými inštitúciami, s cieľom zabezpečiť stabilitu a transparentnosť finančného systému.
- Regulácia priemyslu a obchodu: Regulačná kapacita verejnej správy sa uplatňuje aj v oblasti regulácie priemyslu a obchodu. Úrady a agentúry zabezpečujú dodržiavanie noriem a predpisov týkajúcich sa bezpečnosti produktov, práv spotrebiteľov, hospodárskej súťaže a ďalších aspektov podnikania.
- Regulácia životného prostredia: Verejné orgány majú za úlohu regulovať ochranu životného prostredia a udržateľného rozvoja. To zahŕňa monitorovanie a uplatňovanie environmentálnych noriem a predpisov, správu a ochranu vodných zdrojov, riadenie odpadov, reguláciu emisií a ochranu prírodného dedičstva.
- Regulácia v oblasti zdravotníctva: V oblasti zdravotníctva vykonáva verejná správa reguláciu zdravotných služieb, liekov a farmaceutických produktov. Zabezpečuje sa dodržiavanie noriem kvality a bezpečnosti zdravotníckych zariadení, monitorovanie a kontroly liečiv a terapeutických postupov, a taktiež regulácia zdravotného poistenia a zdravotnej starostlivosti.
- Regulácia v oblasti telekomunikácií a informačných technológií: Verejná správa má tiež úlohu v regulácii telekomunikácií a informačných technológií. Regulácia zahŕňa pridelenie frekvencií, monitorovanie a dohľad nad telekomunikačnými operátormi, ochranu súkromia a bezpečnosť elektronických komunikácií, a podporu rozvoja digitálnej infraštruktúry a informačných technológií.

V nasledujúcej tabuľke je výber regulovaných oblastí a agend, v ktorých je možné aplikovať dátové riešenia (podľa kapitoly 6). Pre každú agendu je určený zodpovedná inštitúcia verejnej správy (regulačný orgán) a platná legislatíva, podľa ktorej sa v postupuje v súčasnom stave.

Tabuľka 8: Návrh konkrétnych riešení pre vybrané agendy

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
Ministerstvo Dopravy SR (MD SR)	Kvalita pozemných komunikácií	Regulácia výstavby, užívanie a ochranu pozemných komunikácií, práva a povinnosti vlastníkov a správcov pozemných komunikácií a ich užívateľov	Identifikácia výmoľov a iných defektov v danej geografickej oblasti. Analýzou zhromaždených údajov môže pokročilá analýza údajov ponúknuť prediktívne riešenia na efektívnejšie riadenie preventívnej a nápravnej údržby ciest, čo vedie k zlepšeniu a trvalej fyzickej kvalite ciest.	Zákon č. 135/1961Zb. o pozemných komunikáciách (cestný zákon)
VÚC, Obce		Regulácia výstavby, užívania a ochrany pozemných komunikácií, práva a povinnosti vlastníkov a správcov pozemných komunikácií a ich užívateľov		Zákon č. 135/1961Zb. o pozemných komunikáciách (cestný zákon)
Ministerstvo Dopravy SR (MD SR)	Právny štát a bezpečnosť	Regulácia, dozor a kontrola vykonávania letov lietadiel vo vzdušnom priestore SR podľa pravidiel lietania platných pre civilné letectvo, spôsobilosť a oprávnenia členov leteckého personálu, spôsobilosť lietadiel a iných výrobkov leteckej techniky, vedenie registra lietadiel, zriaďovanie a prevádzkovanie letísk a leteckých pozemných zariadení, vykonávanie leteckej dopravy, leteckých prác a iného podnikania v civilnom letectve	Použitie technológie počítačového videnia, ako je napríklad algoritmus detekcie objektov založený na hlbokom učení. Ide o typ algoritmu strojového učenia, ktorý dokáže identifikovať objekty na obrázkoch, ako sú rôzne tvary dronov. Kombináciou týchto údajov s geopriestorovými údajmi možno drony rýchlo a presne identifikovať a lokalizovať v obmedzenom vzdušnom priestore.	Zákon č. 143/1998 Z. z. o civilnom letectve (letecký zákon) a o zmene a doplnení niektorých zákonov
Ministerstvo Dopravy SR (MD SR)	Efektívna štátna správa	Kontrola dokumentácie o kvalite verejnej práce, hodnotenie verejnej práce a overuje, či sa verejné investície vynaložené na verejnú prácu použili v súlade so stavebným zámerom a protokolom, ak bol vydaný	HD mapovanie a drony môžu orgánom pre dohľad uľahčiť kontrolu a správu infraštruktúry nákladovo efektívnym spôsobom. Pomocou obrázkov s vysokým rozlíšením a 3D modelov, ktoré pochádzajú z HD mapovania, môžu orgány pre dohľad kontrolovať problémy, plánovať opravy a spravovať činnosti údržby rýchlejšie a presnejšie. Využitím flexibility dronov môžu navyše monitorovať a kontrolovať aj tie najťažšie dostupné oblasti, čo im umožňuje včas odhaliť potenciálne hrozby a rýchlo na ne reagovať.	Zákon č. 254/1998 Z. z. o verejných prácach
Ministerstvo Dopravy SR (MD SR)	Vnútrozemská vodná doprava	Určenie koncepciu rozvoja vnútrozemskej plavby, prístavov a vodných ciest	Prediktívny model založený na strojovom učení možno použiť na zohľadnenie faktorov, ktoré by mohli ovplyvniť intenzitu vnútrozemskej vodnej dopravy. Model sa potom môže použiť na vypracovanie presnej, krátkodobej predpovede vodnej dopravy. Táto predpoveď sa potom môže použiť na plánovanie prístavných operácií, manažmentu vodnej infraštruktúry, zdrojov a iných činností, ktoré závisia od úrovne riečnej dopravy.	Zákon č. 338/2000 Z. z. o vnútrozemskej plavbe a o zmene a doplnení niektorých zákonov
		Kontrola vývoja ponuky kapacity plavidiel určených na prepravu tovarov vo vodnej doprave, zapísaných v registri plavidiel		
		Vyhodnotenie intenzity vodnej dopravy vo vzťahu ku kapacite plavidiel, priepustnosti vodných ciest a ich stavu		
		Dozor nad prevádzkou plavidiel a požičovní plavidiel na vodných cestách a v prístavoch		
		Odborné vyšetrovanie plavebných nehôd	Identifikácia vysoko rizikových ciest a časov dňa pre lodnú dopravu. Pokročilá analýza údajov by sa mohla použiť aj na analýzu údajov z minulých incidentov s cieľom identifikovať vzory a trendy, ktoré by mohli viesť k proaktívnym opatreniam na zabránenie výskytu budúcich incidentov.	
Ministerstvo Dopravy SR (MD SR)	Poštové služby	Návrh štátnej poštovej politiky a koncepcie rozvoja poštových služieb	Predpovedanie, kedy sa objemy balíkov zvýšia a efektívnejšie plánovanie trasy, pochopenie dopytu zákazníkov po rôznych službách s cieľom optimalizovať trasy doručenia a automatizácia rozhodnutí týkajúcich sa personálu a vybavenia.	Zákon č. 507/2001 Z. z. o poštových službách
Ministerstvo Dopravy SR (MD SR)	Železničná doprava	Návrh železničných tratí železničného systému alebo nových železničných tratí vo výstavbe, ktoré majú byť súčasťou systému transeurópskych železníc	Predpovedanie optimálnej kombinácie veličín (trate, rýchlostné obmedzenia a miesta zastávok) s cieľom zlepšiť celkovú železničnú prevádzku a výkonnosť. Model môže tiež lepšie porozumieť vzorcom a objemom premávky, aby sa minimalizovali oneskorenia, zlepšila bezpečnosť, skrátili sa časy jazdy a znížili náklady. Môže tiež pomôcť odhaliť a predvídať potenciálne poruchy a automaticky oddeliť určité kritické body trate, aby sa zvýšila bezpečnosť.	Zákon č. 513/2009 Z. z. o dráhach a o zmene a doplnení niektorých zákonov
Ministerstvo Dopravy SR (MD SR)	Ochrana životného prostredia	Povoľovanie zriadenia stanice technickej kontroly, emisnej kontroly, kontroly originality a montáže plynových zariadení, rozhodovanie o udelení, zmene, pozastavení alebo zrušení oprávnení na vykonávanie týchto činností a vedenie evidencie oprávnených osôb	Predpovedanie množstva emisií, ktoré auto alebo iné vozidlo vyprodukuje za určitých podmienok a okolností. Tieto informácie môžu byť použité na konštrukciu účinnejších systémov regulácie emisií, čo im umožňuje dynamicky vyladiť optimálny výkon v rôznych podmienkach. Okrem toho je možné prediktívne	Zákon č. 725/2004 Z. z. o podmienkach prevádzky vozidiel v premávke na pozemných komunikáciách a o zmene a doplnení niektorých zákonov

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
			modelovanie použit' na vývoj stratégií na optimalizáciu spotreby paliva, čo môže z dlhodobého hľadiska viesť k nižším emisiám.	
Ministerstvo Dopravy SR (MD SR)	Bezpečnosť výrobkov	Uvádzanie stavebných výrobkov na trh, metódy kontroly zhody vlastností stavebných výrobkov a systémy preukazovania zhody	Zlepšenie systémov preukazovania zhody vlastností stavebných výrobkov prostredníctvom implementácie počítačového videnia. Algoritmy počítačového videnia možno použiť na meranie fyzikálnych vlastností stavebných výrobkov, ako je tvar, povrchová úprava a textúra, aby sa presne zistili akékoľvek chyby alebo nedokonalosti.	Zákon č. 90/1998 Z. z. o stavebných výrobkoch
Ministerstvo Dopravy SR (MD SR) - Štátna stavebná správa	Efektívnosť verejnej správy	Riadenie a kontrola výkonu prenesenej štátnej správy vykonávanej obcami ako stavebnými úradmi	Identifikácia vysokorizikových stavebných projektov, ktoré majú najvyšší potenciál meškania alebo prekročenia nákladov. To môže dozorným orgánom umožniť podniknúť proaktívne kroky na minimalizáciu rizík.	Zákon č. 608/2003 Z. z. o štátnej správe pre územné plánovanie, stavebný poriadok a bývanie a o zmene a doplnení zákona č. 50/1976 Zb. o územnom plánovaní a stavebnom poriadku (stavebný zákon) v znení neskorších predpisov
Ministerstvo Financí SR (MF SR)	Dohľad nad poskytovaním verejných zdrojov	Dozor nad dodržiavaním podmienok poskytovania štátnej prémie	Monitorovanie údajov o podmienkach poskytovania štátnej prémie a vytváranie použiteľných poznatkov o tom, ako podmienky pre kontrolu upraviť a zlepšiť. To by pomohlo zabezpečiť čo najpresnejšie podmienky oprávnenosti, ktoré zodpovedajú potrebám štátu.	Zákon č. 310/1992 Z. z. o stavebnom sporení
Ministerstvo Financí SR (MF SR)		Hospodárenie s prostriedkami fondu a dodržiavanie ustanovení zákona o výške podpory, podmienkach a postupe pri poskytovaní podpory	Identifikácia podvodných žiadostí, analýza veľkého množstva údajov z minulých žiadostí na vývoj prediktívnych modelov, ktoré označujú vysokorizikových žiadateľov, a na zistenie potenciálneho prekročenia rozpočtu alebo nesprávneho vyplatenia, aby sa zabezpečila efektívna vládna kontrola finančných prostriedkov.	Zákon č. 607/2003 Z. z. o Štátnom fonde rozvoja bývania
VÚC, Obce		Kontrola dodržiavania zmluvných podmienok a čerpania podpory poskytnutej z fondu pred jej úhradou bankou		Zákon č. 607/2003 Z. z. o Štátnom fonde rozvoja bývania
Ministerstvo Financí SR (MF SR) - Colný úrad	Ochrana spotrebiteľa	Regulácia voľného obehu výrobkov, ktoré majú byť prepustené do colného režimu	Prediktívne modelovanie možno použiť na efektívne odhaľovanie potenciálnych podvodov alebo pašovania produktov počas colného režimu analýzou colných údajov a ich porovnaním so zavedenými vzormi správania. Model dokáže presne určiť typ tovaru, ktorý by mal byť viacero kontrolovaný, čím pomáha zabezpečiť dodržiavanie nariadení a znižuje riziko právnych dôsledkov.	Zákon č. 634/1992 Z. z. o ochrane spotrebiteľa
Ministerstvo Financí SR (MF SR) - Finančné riaditeľstvo SR, daňové úrady, colné úrady	Ochrana spotrebiteľa	Prevádzkovanie hazardných hier, propagovanie hazardných hier a súvisiace činnosti	Automatizácia monitorovania online hazardných hier v reálnom čase, aby sa odhalili príznaky nezodpovedného hrania, ako je nadmerné míňanie na hry, a podľa potreby upovedomili hráča alebo vládne orgány. Prístup by mohol pomôcť ochrániť zraniteľné osoby pred tým, aby sa stali obeťami rizikového hrania hazardných hier a umožniť úradom rýchlejšie a efektívnejšie identifikovať a zastaviť hazardné stránky, ktoré porušujú vládne nariadenia.	Zákon č. 171/2005 Z. z. o hazardných hrách a o zmene a doplnení niektorých zákonov
Ministerstvo Hospodárstva SR (MH SR)	Ochrana životného prostredia	Regulácia podmienok vykonávania banskej činnosti a činnosti vykonávanej bankovým spôsobom, dohľad nad dodržiavaním zásad ochrany a využitia nerastného bohatstva, racionálneho využívania ložísk nerastov, bezpečnosti práce a ochrany pracovného prostredia	Identifikácia neefektívnosti a anomálií vo využívaní a správe nerastného bohatstva pomocou analýzy súborov údajov o ťažbe nerastov, výnosoch a iných relevantných údajových bodoch. Táto analýza môže pomôcť identifikovať potenciálne oblasti využívania zdrojov organizáciami, ktoré nedodržiavajú zásady ochrany a využívania nerastného bohatstva, a môže pomôcť pri rozhodovaní o predchádzaní zlému hospodáreniu so zdrojmi.	Zákon č. 51/1988 Z. z. o banskej činnosti, výbušnách a o štátnej banskej správe
Ministerstvo Hospodárstva SR (MH SR) - Slovenská obchodná inšpekcia	Ochrana spotrebiteľa	Kontrola predaja výrobkov a poskytovanie služieb spotrebiteľom na vnútornom trhu, štátny dozor a kontrola nad podnikaním v energetike	Analýza veľkých objemov dát o vzorcach správania spotrebiteľov a ich výdavkov. To môže pomôcť zabezpečiť, aby sa orgánom pre reguláciu a dohľad poskytovali najlepšie informácie, čím sa zlepší celkový proces kontroly.	Zákon č. 128/2002 Z. z. o štátnej kontrole vnútorného trhu vo veciach ochrany spotrebiteľa
Ministerstvo Hospodárstva SR (MH SR), Slovenská obchodná inšpekcia (SOI)	Bezpečnosť výrobkov	Kontrola uvedenia biocídnych výrobkov na trh	Pokročilá analýza údajov môže pomôcť kontrolným orgánom optimalizovať proces testovania a schvaľovania biocídnych výrobkov pred uvedením výrobku na trh. Tieto modely by sa mohli použiť na identifikáciu oblastí potenciálneho nesúladu, odhad úrovni znečisťujúcich látok v životnom prostredí a predpovedanie environmentálneho vplyvu produktu na voľne žijúce zvieratá a ekosystémy. To by výrobcovi umožnilo prijímať informovanejšie	Zákon č. 217/2003 Z. z. o podmienkach uvedenia biocídnych výrobkov na trh a o zmene a doplnení niektorých zákonov

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
			rozhodnutia o zavádzaní biocídnych výrobkov a pomohlo by to zabezpečiť, aby spĺňali požiadavky súčasných predpisov.	
Ministerstvo Hospodárstva SR (MH SR), Slovenská obchodná inšpekcia (SOI)	Regulácia cien	Regulácia podnikania v tepelnej energetike a vykonávanie cenovej regulácie vo výrobe, distribúcii a dodávke tepla	Zhromažďovanie údajov od energetických spoločností na identifikáciu trendov v spotrebe energie, trhových cenách, technologických zmenách. a spotrebiteľskom správaní. Tieto údaje sa potom môžu použiť na vývoj dynamických cenových stratégií, ktoré optimalizujú úspory nákladov a zároveň spĺňajú potreby spotrebiteľov a regulačné požiadavky	Zákon č. 657/2004 Z. z. o tepelnej energetike
Ministerstvo Kultúry SR (MK SR)	Efektívna štátna správa	Založenie a činnosť cirkví alebo náboženských spoločností	Analýza príspevkov a rekcií cirkví alebo náboženských spoločností na sociálnych sieťach na zhromažďovanie údajov o ich podpore. Údaje môžu slúžiť ako doplnok oficiálnej štatistiky ŠÚ SR a ako podklad pre registráciu novej cirkve alebo náboženskej spoločnosti.	Zákon č. 308/1991 Z. z. o slobode náboženskej viery a postavení cirkví a náboženských spoločností
Ministerstvo Kultúry SR (MK SR)	Efektívna štátna správa	Dohľad nad stavom kultúrnych pamiatok a nad dodržiavaním podmienok ochrany kultúrnych pamiatok a pamiatkových území	Pomocou algoritmov strojového učenia by sa AI mohla použiť na analýzu súborov údajov, ako sú geografické súradnice, typy prostredia v mieste kultúrnych pamiatok, poveternostné podmienky a ďalšie faktory v priebehu času. Tento typ analýzy by umožnil odborníkom na kultúrne dedičstvo ľahšie identifikovať rizikové faktory poškodenia pamiatok a prijať proaktívne opatrenia na ich ochranu. Zozbierané údaje by sa mohli použiť aj na vytváranie správ a upozornení, čím sa zabezpečí efektívnejšia a efektívnejšia správa ochrany.	Zákon č. 49/2002 Z. z. o ochrane pamiatkového fondu
Ministerstvo pôdohospodárstva a rozvoja vidieka SR - Regionálna veterinárna a potravinová správa	Bezpečnosť výrobkov	Vykonávanie kontroly sprievodných certifikátov medikovaných krmív a kontrola evidencie, skladovania a používania medikovaných krmív v chovoch zvierat	Meranie a analýzu účinnosti medikovaného krmiva pri kontrole symptómov choroby zvierat. Údaje o množstve krmiva, type choroby a jej symptómoch možno získať z chovov a preniesť ich cez prediktívny model. Model potom môže prijímať informované rozhodnutia o najlepšom krmive a znižovať riziko nadmernej medikácie.	Zákon č. 39/2007 Z. z. o veterinárnej starostlivosti
Ministerstvo pôdohospodárstva a rozvoja vidieka SR - Ústav štátnej kontroly veterinárnych biopreparátov a liečiv		Kontrola prípravy a používania medikovaných krmív		
Ministerstvo pôdohospodárstva a rozvoja vidieka SR - Štátna veterinárna a potravinová správa	Bezpečnosť výrobkov	Dodržiavanie predpisov týkajúcich sa potravín a poľnohospodárskych produktov s chráneným označením pôvodu, chráneným zemepisným označením, označením zaručenej tradičnej špeciality alebo liehovín so zemepisným označením	Automatické rozpoznanie a detekcia chránených označení pôvodu, keď vstúpia do dodávateľského reťazca. To by mohlo znížiť bremeno manuálnych kontrol, ako aj znížiť náklady na dodržiavanie predpisov. Využitím algoritmov by sa navyše mohla zlepšiť presnosť procesu overovania medzi pravými a falošnými chránenými označeniami pôvodu.	Zákon č. 152/1995 Z. z. o potravinách
Ministerstvo pôdohospodárstva a rozvoja vidieka SR - Ústredný kontrolný a skúšobný ústav poľnohospodársky	Bezpečnosť výrobkov	Kontrola pestovania geneticky modifikovaných rastlín v poľnohospodárskej výrobe Vedenie evidencie pestovateľov a pestovateľských plôch	Zdieľanie údajov počas fázy vývoja geneticky modifikovaných odrôd rastlín, čo môže zlepšiť presnosť zberu údajov, čo vedie k efektívnejšej štátnej kontrole pestovania GM rastlín.	Zákon č. 184/2006 Z. z. o pestovaní geneticky modifikovaných rastlín v poľnohospodárskej výrobe
Ministerstvo pôdohospodárstva a rozvoja vidieka SR - Ústredný kontrolný a skúšobný ústav poľnohospodársky	Bezpečnosť výrobkov	Vydávanie súhlasu na dovoz produktov ekologickej poľnohospodárskej výroby dovozcomi	Identifikácia a analýza vzorcov v údajoch o aplikáciách dovozu produktov ekologickej poľnohospodárskej výroby s cieľom navrhnúť, ktoré aplikácie pravdepodobne štát schváli. To umožní štátu rýchlejšie analyzovať a schvaľovať žiadosti, skrátiť čas spracovania a zlepšiť zákaznícku skúsenosť na strane dovozcu.	Zákon č. 189/2009 Z. z. o ekologickej poľnohospodárskej výrobe
Ministerstvo pôdohospodárstva a rozvoja vidieka SR - Ústredný kontrolný a skúšobný ústav poľnohospodársky	Bezpečnosť výrobkov	Registrácia a uvádzanie množiteľského materiálu pestovaných rastlín na trh	Analýzu veľkých údajov súvisiacich s využívaním pôdy, produkciou plodín a inými poľnohospodárskymi aktivitami možno použiť na zistenie akýchkoľvek potenciálnych zmien alebo vzorcov, ktoré by naznačovali nezrovnalosti vo výrobe alebo distribúcii pestovaných rastlín. To pomáha štátom rýchlo identifikovať akékoľvek nezrovnalosti a prijať vhodné opatrenia na vyriešenie problému.	Zákon č. 597/2006 Z. z. o pôsobnosti orgánov štátnej správy v oblasti registrácie odrôd pestovaných rastlín a uvádzaní množiteľského materiálu pestovaných rastlín na trh
Ministerstvo Práce, Sociálnych Vecí a Rodiny SR (MPSVR SR)	Dohľad nad poskytovaním verejných zdrojov	Vedenie evidencie v informačnom systéme sociálnych služieb	Technológie spracovania prirodzeného jazyka dokážu automatizovať proces posudzovania žiadostí o finančný príspevok. Dokážu vyhodnotiť informácie v aplikáciách rýchlejšie a presnejšie ako manuálna činnosť a odporučiť ďalšie kroky. Táto technológia	Zákon č. 448/2008 Z. z. o sociálnych službách a o zmene a doplnení zákona č. 455/1991 Zb. o živnostenskom podnikaní (živnostenský zákon) v znení neskorších predpisov

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
		Posudzovanie žiadostí o poskytnutie finančného príspevku	tiež uľahčuje zachytenie nezrovnalostí a podvodných žiadostí pred odoslaním akýchkoľvek finančných príspevkov, čo pomáha šetriť peniaze a zabezpečuje efektívne pridelovanie zdrojov.	
Ministerstvo Práce, Sociálnych Vecí a Rodiny SR (MPSVR SR) - Národný inšpektorát práce	Ochrana zdravia	Dodržiavanie pracovnoprávných predpisov a zabezpečenie bezpečnosti a ochrany zdravia pri práci	Monitorovanie a identifikácia správania na pracovisku, ktoré by mohlo viesť k rizikám pre bezpečnosť a zdravie, ako sú rizikové pracovné pozície, dlhý pracovný čas alebo nebezpečné výrobné postupy. Tieto modely môžu byť navrhnuté tak, aby rýchlo odhalili prípady porušenia a upozornili zamestnávateľov, aby mohli prijať nápravné opatrenia na zaistenie bezpečnosti a zdravia svojich zamestnancov.	Zákon č. 125/2006 Z. z. o inšpekcii práce a o zmene a doplnení zákona č. 82/2005 Z. z. o nelegálnej práci a nelegálnom zamestnávaní a o zmene a doplnení niektorých zákonov
Ministerstvo Práce, Sociálnych Vecí a Rodiny SR (MPSVR SR) - Úrad práce, sociálnych vecí a rodiny	Zamestnanosť	Dodržiavanie povinného podielu zamestnávania občanov so zdravotným postihnutím na celkovom počte zamestnancov zamestnávateľa	Vývoj prediktívnych modelov, ktoré by identifikovali medzery v pracovných zručnostiach pre daného zamestnanca so zdravotným postihnutím a následne identifikovali potenciálne pozície so zdravotným postihnutím.	Zákon č. 5/2004 Z. z. o službách zamestnanosti a o zmene a doplnení niektorých zákonov
Ministerstvo Práce, Sociálnych Vecí a Rodiny SR (MPSVR SR), Štátna Poľnohospodárska a Potravinová Komora SR, Štátna Veterinárna a Potravinová Správa SR	Bezpečnosť výrobkov	Kontrola kvality výroby vinárskych produktov a zabezpečenie ich zdravotnej neškodnosti	Analýza surovín, fliaš a iných komponentov používaných počas výroby vinárskych produktov a na zistenie akýchkoľvek anomálií, ktoré môžu viesť k problémom s kvalitou alebo bezpečnosťou. Prediktívne modely sa potom môžu použiť na identifikáciu vzorov v údajoch a na poskytovanie upozornení, ktoré umožnia preventívne opatrenia.	Zákon č. 313/2009 Z. z. o vinohradníctve a vinárstve
Ministerstvo Spravodlivosti SR (MS SR)	Právny štát a bezpečnosť	Sledovaním dodržiavania zákonnosti postupov exekútorov v konkrétnych veciach	Zlepšenie monitorovania zákonnosti sledovaním platnosti dokumentácie pre postupy exekútorov. Konkrétne by sa algoritmy ML mohli použiť na odhalenie anomálií v obsahu alebo štruktúre dokumentácie, ktoré by signalizovali zvýšený potenciál rizika nesúladu, aby orgány pre dohľad mohli prijať nápravné opatrenia s cieľom zabezpečiť, aby exekutorovia dodržiavali platné zákony a predpisy.	Zákon č. 233/1995 Z. z. o súdnych exekútoroch a exekučnej činnosti (Exekučný poriadok) a o zmene a doplnení ďalších zákonov
Ministerstvo Spravodlivosti SR (MS SR)	Právny štát a bezpečnosť	Overenie odbornej spôsobilosti znalcov a tlmočníkov	Zlepšenie overenia odbornej spôsobilosti odborníkov a tlmočníkov automatickou analýzou práce, ktorú vykonali v minulosti, a využitím získaných znalostí na predpovedanie očakávaných výsledkov a presnosti ich budúcej práce. Okrem toho sa tieto modely môžu použiť na predpovedanie pravdepodobnosti úspechu pre akýkoľvek daný projekt alebo úlohu, pričom sa zohľadnia individuálne charakteristiky odborníka spárované s požiadavkami konkrétnej úlohy, čím sa získa celkové skóre, ktoré možno použiť na hlbší skríning a overenie.	Zákon č. 382/2004 Z. z. o znalcoch, tlmočníkoch a prekladateľoch a o zmene a doplnení niektorých zákonov
Ministerstvo Spravodlivosti SR (MS SR) - Komora notárov	Právny štát a bezpečnosť	Vybavovanie sťažností (na notársku činnosť) podľa osobitného predpisu a kontrolou spisov, listín, predmetu úschov a registrov	Analýza frekvencie, typov a základných príčin sťažností a na identifikáciu trendov s cieľom preventívne riešiť bežné sťažnosti. Technológiu spracovania prirodzeného jazyka možno použiť aj na vývoj automatizácie služieb zákazníkom na zodpovedanie a riešenie dotazov zákazníkov alebo ich presmerovanie na správny personál.	Zákon č. 323/1992 Zb. o notároch a notárskej činnosti (Notársky poriadok)
Ministerstvo Spravodlivosti SR (MS SR) - Úrad na ochranu osobných údajov	Právny štát a bezpečnosť	Sledovanie stavu ochrany osobných údajov, registrácie informačných systémov a vedenia evidencie o informačných systémoch Kontrola spracúvania osobných údajov v informačných systémoch	Použitie algoritmov na zistenie akýchkoľvek nezrovnalostí v používaní osobných údajov a prístupe k nim. Umelá inteligencia sa dá použiť na identifikáciu vzorov používania údajov, ktoré sú nezvyčajné a pravdepodobne budú podozrivé, čo umožňuje rýchlo zasiahnuť a vyšetriť podozrenie.	Zákon č. 428/2002 Z. z. o ochrane osobných údajov
Ministerstvo Vnútra SR (MV SR)	Právny štát a bezpečnosť	Kontrola bezpečného uloženia zbrane a streliva u držiteľa zbrane kategórie A	Analýza údajov zozbieraných z registra držiteľov zbraní na vytvorenie modelu, ktorý poskytuje rizikové skóre pre skladovanie zbraní a munície a upozorňuje držiteľa na akékoľvek potenciálne bezpečnostné riziká.	Zákon č. 190/2003 Z. z. o strelných zbraniach a strelive a o zmene a doplnení niektorých zákonov
Ministerstvo Vnútra SR (MV SR)	Právny štát a bezpečnosť	Dohľad nad určenými výrobkami uvádzanými na trh z hľadiska ich protipožiarnej bezpečnosti podľa osobitných predpisov Kontrola na úseku ochrany pred požiarmi u právnických osôb	Analýza existujúcich systémov požiarnej ochrany a určenie, či sú potrebné nejaké zmeny. Pokročilá analýza údajov môže tiež pomôcť identifikovať oblasti potenciálneho rizika a odporučiť potrebné aktualizácie alebo zlepšenia. Okrem toho by sa mohol model použiť	Zákon č. 314/2001 Z. z. o ochrane pred požiarmi

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
			na vypracovanie plánov inšpekcií založených na potencionálnom riziku.	
Ministerstvo Vnútra SR (MV SR)	Právny štát a bezpečnosť	Poskytovanie pomoci obciam v odborných veciach a potrebných údajov z jednotlivých evidencií vedených orgánmi štátu a odborná príprava zamestnancov obcí a poslancov obecných zastupiteľstiev	Prediktívne modelovanie možno použiť na predpovedanie nedostatkov v zručnostiach obecných úradníkov a na poskytovanie prispôborených online školení, ktoré pomôžu tieto nedostatky preklenúť. Tento typ modelovania môže pomôcť lepšie pochopiť zručnosti a kompetencie zamestnancov a prispôbiť odborné školenia tak, aby sa zamerali na špecifické zručnosti, ktoré je potrebné zlepšiť.	Zákon č. 369/1990 Zb. o obecnom zriadení
		Odborná príprava orgánov ochrany pred povodňami a organizovanie hlásnej povodňovej služby a varovanie obyvateľstva		Zákon č. 7/2010 Z. z. o ochrane pred povodňami
Ministerstvo Vnútra SR (MV SR)	Efektívnosť VS	Vypracovanie koncepcie rozvoja archívov, preberania, sprístupňovania a ochrany archívnych dokumentov a správy registratúry	Identifikácia vzorcov a vzťahov v historických údajoch, čo pomáha archívárom určiť relevantné dokumenty, zistiť dôležité vzťahy medzi časťami informácií a určiť nové úrovne prístupu k určitým zbierkam. Okrem toho je možné prediktívne modelovanie použiť aj na zlepšenie bezpečnosti archívnych dokumentov, napríklad označovaním podozrivých aktivít alebo prístupových bodov.	Zákon č. 395/2002 Z. z. o archívoch a registratúrach a o doplnení niektorých zákonov
Ministerstvo Vnútra SR (MV SR)	Efektívnosť VS	Udeľovanie súhlasu s používaním štátnych symbolov, znamenia štátneho znaku a národného symbolu	Technológiu NLP možno použiť na analýzu žiadostí o súhlas a udelenie povolenia. Napríklad NLP systém môže zo žiadosti extrahovať kľúčové frázy, porovnať ju s príslušnými zákonmi a nariadeniami a udeliť súhlas na použitie štátnych symbolov, ak žiadosť spĺňa kritériá stanovené zákonmi a nariadeniami.	Zákon č. 63/1993 Z. z. o štátnych symboloch Slovenskej republiky a ich používaní
Ministerstvo Zdravotníctva SR (MZ SR)	Regulácia cien	Regulácia a kontrola cien výrobkov, služieb a výkonov v zdravotníctve a v oblasti cien nájmu nebytových priestorov v zdravotníckych zariadeniach	Prediktívne modelovanie sa môže použiť na identifikáciu potenciálne nadmerných cien nájomného na základe predchádzajúcich trhových údajov. Prediktívnymi modelmi sa možno naučiť vzory z porovnateľných nehnuteľností a posúdiť, či je navrhované nájomné v porovnaní s inými zdravotníckymi zariadeniami podozrivé. Pokročilé analýzy údajov sa dajú použiť aj na sledovanie kolísania nájomného v priebehu času a na vytváranie virtuálnych stropov nájomného s cieľom pomôcť chrániť pred nadmerným zvyšovaním nájomného.	Zákon č. 18/1996 Z. z. o cenách
VÚC, Obce, Ministerstvo Financí SR (MF SR), Slovenská obchodná inšpekcia	Regulácia cien	Regulácia a kontrola cien výrobkov, výkonov, prác, služieb, nájmu a nehnuteľností		Zákon č. 18/1996 Z. z. o cenách
Ministerstvo Zdravotníctva SR (MZ SR)	Ochrana životného prostredia	Posudzovanie zámerov na vykonávanie činností a zisťovacieho konania na území kúpeľného miesta, na území s klimatickými podmienkami vhodnými na liečenie, na území ochranných pásiem prírodného liečivého zdroja, prírodného minerálneho zdroja a klimatických podmienok vhodných na liečenie	Posúdenie potenciálneho rizika spojeného s aktivitami v konkrétnom kúpeľnom mieste. Modely môžu napríklad brať do úvahy faktory, ako je dopravný tok a prítomnosť chránených druhov v okolitej oblasti. Výsledná prediktívna analýza môže poskytnúť prehľad o pravdepodobnosti poškodenia chránenej zóny, ako aj o možných environmentálnych dôsledkoch.	Zákon č. 538/2005 Z. z. o prírodných liečivých vodách, prírodných liečebných kúpeľoch, kúpeľných miestach a prírodných minerálnych vodách a o zmene a doplnení niektorých zákonov
Ministerstvo Zdravotníctva SR (MZ SR) - Štátny ústav pre kontrolu liečiv	Ochrana zdravia	Kontrola kvality liekov a zdravotníckych pomôcok	Vytvorenie prediktívnych modelov na identifikáciu potenciálnych bezpečnostných problémov skôr, ako sa vyskytnú, na základe komponentov použitého výrobného procesu. Modely sa môžu použiť na odhaľovanie a identifikáciu potenciálnych kontaminácií, a môžu tiež pomôcť identifikovať špecifické zmeny vo výrobnom procese, ktoré môžu viesť k zmene kvality produktu.	Zákon č. 140/1998 Z. z. o liekoch a zdravotníckych pomôckach, o zmene zákona č. 455/1991 Zb. o živnostenskom podnikaní (živnostenský zákon) v znení neskorších predpisov a o zmene a doplnení zákona Národnej rady Slovenskej republiky č. 220/1996 Z. z. o reklame
		Inšpekcia a skúšanie vzoriek na zabezpečenie splnenia požiadaviek tohto zákona týkajúcich sa humánnych liekov a veterinárnych liekov		
Ministerstvo Zdravotníctva SR (MZ SR) - Úrad pre dohľad nad zdravotnou starostlivosťou	Efektívnosť verejnej správy	Dohľad na diaľku nad zdravotnými poisťovňami, platiteľmi poisťného, poskytovateľmi zdravotnej starostlivosti, poisťencami a inými osobami	Identifikácia oblasti s vyšším rizikom podvodov v rámci zdravotného poistenia, čo umožňuje na diaľku monitorovať poisťovne a znižovať podvody. Modely dokážu rozpoznať vzory vo finančných transakciách, aby pomohli rozlíšiť medzi legitímnymi nákladmi na zdravotnú starostlivosť a podvodnými aktivitami. Okrem toho sa AI a ML môžu použiť na pomoc pri automatizácii procesu auditu poskytovateľov zdravotnej starostlivosti a poisťovní, aby sa zabezpečilo dodržiavanie predpisov.	Zákon č. 581/2004 Z. z. o zdravotných poisťovniach, dohľade nad zdravotnou starostlivosťou a o zmene a doplnení niektorých zákonov
	Ochrana zdravia	Hodnotenie rizík registrovaných látok na zdravie ľudí	Prediktívne modelovanie možno použiť na poskytnutie presnejších a komplexnejších pohľadov na toxicitu a zdravotné riziká spojené s registrovanými látkami. Využitím verejne dostupných databáz možno prediktívne modely trénovať na analýzu údajov o toxicite zo	Zákon č. 67/2010 Z. z. o podmienkach uvedenia chemických látok a chemických zmesí na trh a o zmene a doplnení niektorých zákonov (chemický zákon)

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
		Vydávanie vyjadrení k dovozu vybraných nebezpečných látok a vybraných nebezpečných zmesí podliehajúcich PIC postupu	štúdií in vivo a in vitro o registrovaných látkach a navrhovaných prediktívnych koncových bodoch. Je to užitočné pri vytváraní prehľadov, ktoré sú presnejšie, pretože je možné identifikovať a extrapolovať účinky toxicity špecifické pre jednotlivé druhy na ľudí. Prediktívne modelovanie sa môže použiť aj na výpočet „bezpečných“ úrovní registrovaných látok, ktoré možno použiť na expozíciu ľudí.	
Ministerstvo Životného Prostredia SR (MŽP SR)	Ochrana životného prostredia	Zisťovanie množstva, režimu a kvality povrchových vôd a podzemných vôd, hodnotenie stavu, množstva, režimu a kvality povrchových vôd a podzemných vôd a určovanie environmentálnych cieľov	Analýza historických údajov na identifikáciu vzorcov zrážok, vyparovania a iných meteorologických podmienok, ako aj trendov v populácii a dopyte. Historické údaje možno použiť aj na generovanie odhadov budúcej dostupnosti vody, založených na technológii máp s vysokým rozlíšením. Okrem toho je možné prediktívne modelovanie použiť na identifikáciu oblastí, ktoré sú náchylné na suchu alebo iné problémy súvisiace s vodou, ako aj na predpovedanie sezónnych zmien vody.	Zákon č. 364/2004 Z. z. o vodách a o zmene zákona Slovenskej národnej rady č. 372/1990 Zb. o priestupkoch v znení neskorších predpisov (vodný zákon)
		Vypracovanie plánov manažmentu povodí, Vodného plánu Slovenska		
Ministerstvo Životného Prostredia SR (MŽP SR) - Inšpekcia životného prostredia	Ochrana životného prostredia	Vypracovanie analýz charakteristík čiastkových povodí, zhodnotenia vplyvov ľudských činností na stav povrchových vôd a stav podzemných vôd a vypracovania ekonomických analýz nakladania s vodami	Pokročilú analýzu údajov a systém senzorov IoT možno použiť na vytvorenie automatizovaného systému na nepretržité monitorovanie rôznych parametrov povrchových a podzemných vôd. Využitím súborov údajov môže model posúdiť účinky ľudskej činnosti na vodné systémy a identifikovať akékoľvek odchýlky alebo vzory v kvalite vody. Tieto údaje možno použiť na informovanie tvorcov politik o faktoroch vedúcich k zmenám v životnom prostredí a na vývoj lepších stratégií na minimalizáciu negatívnych vplyvov na životné prostredie.	
		Vykonávanie v spolupráci s úradom verejného zdravotníctva identifikácie vôd určených na kúpanie		
		Inšpekcia na účely kontroly zabezpečuje vlastné sledovanie kvalitatívnych a kvantitatívnych hodnôt vypúšťaných odpadových vôd a ich vplyv na recipientov		
Ministerstvo Životného Prostredia SR (MŽP SR)	Ochrana životného prostredia	Vypracovanie, schvalenie, vyhodnotenie a aktualizácia plánu rozvoja verejných vodovodov a verejných kanalizácií pre územie Slovenskej republiky		Zákon č. 442/2002 Z. z. o verejných vodovodoch a verejných kanalizáciách a o zmene a doplnení zákona č. 276/2001 Z. z. o regulácii v sieťových odvetviach
		Vedenie centrálnej evidencie údajov o verejných vodovodoch a verejných kanalizáciách		
VÚC		Rozhodovanie o pásmach ochrany		Zákon č. 442/2002 Z. z. o verejných vodovodoch a verejných kanalizáciách a o zmene a doplnení zákona č. 276/2001 Z. z. o regulácii v sieťových odvetviach
Ministerstvo Životného Prostredia SR (MŽP SR)	Ochrana životného prostredia	Sprístupnenie informácií o životnom prostredí	AI môže zlepšiť dostupnosť informácií o životnom prostredí pomocou HD mapovania. Táto technológia zahŕňa použitie algoritmov AI na zhromažďovanie a analýzu údajov zo satelitných snímok, leteckých snímok a iných zdrojov na vytváranie presných a aktuálnych digitálnych máp. Táto technológia môže byť použitá na sledovanie environmentálnych zmien v priebehu času, ako je odlesňovanie, hladina vody, erózia pôdy a ďalšie.	Zákon č. 525/2003 Z. z. o štátnej správe starostlivosti o životné prostredie a o zmene a doplnení niektorých zákonov
		Vykonávanie ústredných revízií stavu osobitne chránených častí prírody a krajiny		Zákon č. 543/2002 Z. z. o ochrane prírody a krajiny
VÚC		Ochrana druhov voľne žijúcich živočíchov a voľne rastúcich rastlín a obchod s nimi		Zákon č. 15/2005 Z. z. o ochrane druhov voľne žijúcich živočíchov a voľne rastúcich rastlín reguláciou obchodu s nimi a o zmene a doplnení niektorých zákonov
VÚC		Vykonávanie štátneho dozoru vo veciach dosiahnutia cieľov štátnej environmentálnej politiky na miestnej úrovni akciami, na ktoré bola poskytnutá podpora z Environmentálneho fondu		Zákon č. 525/2003 Z. z. o štátnej správe starostlivosti o životné prostredie a o zmene a doplnení niektorých zákonov
Ministerstvo Životného Prostredia SR (MŽP SR)	Efektívna štátna správa	Zadávanie, vykonávanie a úhrada geologických prác financovaných zo štátneho rozpočtu	HD mapovanie a drony môžu orgánom pre dohľad uľahčiť kontrolu a správu geologických prác nákladovo efektívnym spôsobom. Pomocou obrázkov s vysokým rozlíšením a 3D modelov, ktoré pochádzajú z HD mapovania, môžu orgány pre dohľad kontrolovať problémy, plánovať a spravovať činnosti geologických prác rýchlejšie a presnejšie. Využitím flexibility dronov môžu navyše	Zákon č. 569/2007 Z. z. o geologických prácach (geologický zákon)

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
			monitorovať a kontrolovať aj tie najťažšie dostupné oblasti, čo im umožňuje včas odhaliť potenciálne hrozby a rýchlo na ne reagovať.	
Obce	Sociálne služby	Vypracovávanie, schvaľovanie komunitných plánov sociálnych služieb	Predpovedanie potrieb komunity pri vypracovávaní a schvaľovaní plánov sociálnych služieb. Analýzou údajov o životných situáciách jednotlivca sa prediktívne modely môžu naučiť vzory a trendy, ktoré sú dostatočne presné na to, aby presne predpovedali, aký typ zdrojov a služieb bude jednotlivec pravdepodobne potrebovať v budúcnosti. Vďaka tomuto prehľadu môžu komunity lepšie plánovať dlhodobé sociálne služby, ktoré lepšie zodpovedajú potrebám ich obyvateľov. Prediktívny model môže tiež generovať prehľad o efektívnejších metodológiách poskytovania služieb.	Zákon č. 448/2008 Z. z. o sociálnych službách a o zmene a doplnení zákona č. 455/1991 Zb. o živnostenskom podnikaní (živnostenský zákon) v znení neskorších predpisov
VÚC		Vydávanie, schvaľovanie koncepcie rozvoja sociálnych služieb		Zákon č. 448/2008 Z. z. o sociálnych službách a o zmene a doplnení zákona č. 455/1991 Zb. o živnostenskom podnikaní (živnostenský zákon) v znení neskorších predpisov
Slovenský hydrometeorologický ústav	Efektívna štátna správa	Vykonávanie preventívnych opatrení na ochranu pred povodňami, príprava na vykonávanie povodňových zabezpečovacích prác, a vykonávanie predpovednej povodňovej služby	HD mapovanie a drony môžu uľahčiť kontrolu a správu infraštruktúry nákladovo efektívnym spôsobom. Pomocou obrázkov s vysokým rozlíšením a 3D modelov, ktoré pochádzajú z HD mapovania, môžu kontrolovať problémy, plánovať opravy a spravovať činnosti údržby rýchlejšie a presnejšie. Využitím flexibility dronov môžu navyše monitorovať a kontrolovať aj tie najťažšie dostupné oblasti, čo im umožňuje včas odhaliť potenciálne hrozby a rýchlo na ne reagovať.	Zákon č. 7/2010 Z. z. o ochrane pred povodňami
Úrad vlády - Úrad jadrového dozoru SR	Právny štát a bezpečnosť	Schvaľovanie na účely havarijného plánovania veľkosť oblasti ohrozenia alebo veľkosť spoločnej oblasti ohrozenia jadrovým zariadením	Použitie prediktívnych modelovacích algoritmov na identifikáciu potenciálnych slabín v plánoch. Takéto algoritmy možno použiť na detekciu korelácií medzi environmentálnymi charakteristikami, ako je seizmická aktivita alebo rýchlosť vetra, a potenciálnymi nebezpečnými scenármi spojenými s jadrovým zariadením. To môže pomôcť pri predpovedaní potenciálnych plánov pre núdzové plány na rôznych miestach a merať ich účinnosť pri takýchto hrozbách. Okrem toho sa prediktívne modelovanie môže použiť na integráciu viacerých zdrojov údajov, ako sú siete na detekciu žiarenia v reálnom čase, s cieľom rýchlo a presne posúdiť závažnosť potenciálnej jadrovej hrozby.	Zákon č. 541/2004 Z. z. o mierovom využívaní jadrovej energie (atómový zákon) a o zmene a doplnení niektorých zákonov
		Posudzovanie plánov ochrany obyvateľstva krajov v oblasti ohrozenia		
		Hodnotenie jadrovej bezpečnosti, fyzickej ochrany a havarijnej pripravenosti nezávisle od držiteľa povolenia		
VÚC		Kontrola vozidiel a technického stavu, ako aj dodržiavanie bezpečnostných opatrení pri preprave nebezpečných vecí		Zákon č. 168/1996 Z. z. o cestnej doprave
Úrad vlády - Úrad pre reguláciu sieťových odvetví	Efektívna štátna správa	Dohľad nad prevodom záruky pôvodu elektriny z obnoviteľných zdrojov energie a potvrdenia o množstve biometánu	Prediktívne modelovanie možno použiť na automatizáciu procesu predpovedaní, ktoré záruky pôvodu by sa mali preniesť, odhadom množstva vyprodukovaného biometánu a analýzou vzorov podvodov a zneužitia. Automatickým overovaním pravosti zdrojov energie, ako aj zisťovaním možných anomálií v množstve vyprodukovaného biometánu je možné rýchlo identifikovať a riešiť podvody a zneužívanie. Prediktívne modelovanie môže tiež pomôcť vytvoriť efektívnejší a škálovateľnejší proces pre dohľad nad prenosom záruk, zaznamenávanie spotreby a vydávanie digitálnych certifikátov.	Zákon č. 276/2001 Z. z. o regulácii v sieťových odvetviach
		Dohľad nad priebehom aukcií výrobcu elektriny, dodávateľa elektriny a obchodníka s elektrinou	Automatická analýza procesov ponúkania cien energie s cieľom odhaliť nezrovnalosti a odhaliť podvodné správanie. Systém AI možno použiť aj na porovnanie ponúk elektriny a identifikáciu vzorcov tajne dohodnutého správania. Okrem toho je možné prediktívne modely použiť na predpovedanie cien elektriny a odporúčanie optimálnych stratégií ponúk.	
VÚC	Efektívna štátna správa	Kontrola dokladov záverečnej správy zbierky	Technológiu NLP možno použiť na pomoc pri automatizácii procesu dvojitej kontroly formulárov a overenia správnosti všetkých informácií. Dá sa to dosiahnuť pomocou technológie AI na odhalenie anomálií vo formulároch, ktoré môžu viesť k chybám, a ich označenie na ďalšiu kontrolu. To môže pomôcť zabezpečiť, aby bola záverečná správa presná a aby nedošlo k žiadnym chybám, a aby sa prostriedky dostali na zamýšľané miesto určenia.	Zákon č. 162/2014 Zb. o verejných zbierkach a o lotériách a iných podobných hrách
VÚC, Obce	Efektívna štátna správa	Vykonávanie kontroly hospodárenia školy s finančnými a materiálnymi prostriedkami a s majetkom	Automatizácia kontrolných procesov pomocou algoritmov spracovania prirodzeného jazyka na extrakciu a usporiadanie údajov z finančných záznamov a iných dokumentov súvisiacich s financiami školy. To umožňuje rýchlejšie a presnejšie odsúhlasenie	Zákon č. 416/2001 Z. z. o prechode niektorých pôsobností z orgánov štátnej správy na obce a na vyššie územné celky

Regulačný orgán	Regulovaná oblasť	Agenda v regulovanej oblasti	Prípád použitia pokročilých analýz údajov	Súčasná legislatíva
			účtov, rozpočtovanie, prognózovanie a ďalšie finančné procesy. Použitím spracovania prirodzeného jazyka je možné sledovať a vyhodnocovať vzorce používania týchto aktív, čo umožňuje lepšie riadenie zdrojov školy.	

5.3 Procesy manažmentu údajov

V tejto kapitole sa venujeme definovaniu vzorových postupov pre manažment údajov - jedná sa o vytvorenie vzorových postupov ako zbierať, spravovať a využívať údaje. Účelom je vytvoriť také postupy pre organizácie verejnej správy, ktoré budú jednoducho implementovateľné do ich štruktúr. Výstupom sú nasledujúce modelové príklady:

- Prioritizácia a zber požiadaviek,
- Zber a spracovanie údajov,
- Zdieľanie údajov,
- Rozhodovanie na základe údajov,
- Tvorba analytických výstupov,
- Testovanie dopadov a efektivity politík,
- Publikovanie údajov: otvorené údaje a vizualizácia.

5.3.1 Prioritizácia a zber požiadaviek

Čím viac údajov organizácia zbiera, tým väčšia je šanca, že pochopí správanie používateľov a kontext ich správania. Čím viac organizácia chápe o jednotlivých užívateľoch, ich potrebách, zámeroch a túžbach, tým viac môže zlepšiť užívateľskú skúsenosť. Dátami riadená organizácia, bude však pravdepodobne myslieť oveľa širšie: data-driven marketing, data-driven služby, data-driven zákaznícky servis, data-driven rozhodovanie, data-driven HR. Ak má každá z nich sadu interných a externých zdrojov údajov s rôznymi formátmi, latenciou, problémami s kvalitou údajov, požiadavkami na zabezpečenie a súlad atď., potom táto prax zhromažďovania maximálneho množstva údajov zlyhá. Na udržanie týchto systémov, zálohovanie údajov a na integráciu týchto zdrojov údajov s cieľom poskytnúť holistický pohľad sú vysoké náklady. Zostavujete zdroje údajov, spojenia medzi nimi a schopnosti spracovania v priebehu času. Musíte mať racionálnu, dobre premyslenú stratégiu získavania údajov. Dátové tímy vo väčšine organizácií sú navyše obmedzené na zdroje; nemôžu robiť všetko naraz, a preto musia uprednostniť, ktoré zdroje údajov sa majú veľmi starostlivo riešiť.

Kľúčovou zložkou sú nepochybne údaje. Samozrejme, musia to byť správne údaje. Súbor údajov musí byť relevantný, včasný, presný, čistý, objektívny; a čo je najdôležitejšie, musí byť dôveryhodný. Niektorí veľkí predajcovia údajov a poskytovatelia služieb inzerujú údaje ako všeliek: ak zbierate všetko, niekde tam sú aj diamanty, ktoré urobia každú spoločnosť úspešnou. Pravdou je, že samotné údaje nestačia. Malé množstvo čistých, dôveryhodných údajov môžu byť oveľa cennejšie ako nespočet nezmyslov. Dátami riadená organizácia by sa mala zamerať na hodnotový aspekt. Primárnou motiváciou dátového tímu by malo byť uspokojenie potrieb analytikov. Tímy musia mať svoje základné údaje, navyše môžu mať iný súbor údajov, ktoré rozširujú ich základné údaje. Tieto iné zdroje údajov sú pravdepodobne cenné a účinné, ale nie rozhodujúce.

Podporované postupy a priority pre prioritizáciu a zber požiadaviek:

4. Porozumenie doméne a formulácia hypotéz - porozumenie situácií, definícia problémov, stanovenie cieľov, ktoré je potrebné dosiahnuť, definícia hypotéz.
5. Výber vhodných dátových zdrojov - zabezpečenie prístupu k dátam na technickej úrovni, nákup dát.

6. Využívanie existujúcich údajov vrátane otvorených súborov údajov a údajov z interoperabilných systémov.
7. Identifikácia a riešenie rizík spojených s ochranou súkromia a bezpečnosti údajov - najmä v súvislosti s prístupom k osobným údajom a ich používaním. Vytvorenie zodpovedného rámca údajov môže pomôcť chrániť jednotlivcov pred škodami vyplývajúcimi z činností založených na údajoch vrátane diskriminácie z profilovania
8. Vypracovanie a implementácia plánu monitorovania a hodnotenia založený na osvedčených postupoch zberu a správy údajov a zahŕňajúci všetky typy požiadaviek na údaje. Identifikujte údaje potrebné na podporu posúdenia využívania údajov pri rozhodovaní.

5.3.2 Zber a spracovanie údajov

Dostupnosť údajov transformuje globálnu ekonomiku v nebývalej miere. Mnoho organizácií, bez ohľadu na zameranie v súčasnosti považujú údaje za ústredný zdroj inovácií a hospodárskeho rastu. Používanie údajov navyše tieto údaje nespotrebuje: skôr ich môžu používať iní. Organizácie založené na údajoch v súčasnosti generujú vyššie výnosy ako tradičné organizácie, pretože po ich zbere sa údaje môžu použiť na viaceré účely. Keď do organizácie prichádzajú nové druhy údajov, je potreba určiť, ako s nimi zaobchádzať. Niektoré dôležité funkcie nových nástrojov, ktoré pomáhajú s riadením údajov a analýz zahŕňajú:

- Dátové katalógy, glosáre a slovníky. Dátový katalóg organizácie je súpisom dát (vrátane metadát), ktoré umožňujú organizáciám stať sa riadenými údajmi tým, že pomáhajú používateľom porozumieť a budovať dôveru v údaje. Novšie nástroje automatizujú niektoré kroky a postupy na aktualizáciu katalógov, ako aj objavujú metaúdaje z existujúcich súborov údajov, aby sa o nich dozvedeli podrobnosti. Nástroje môžu tiež označovať údaje podľa definícií a pravidiel organizácie na vyššej úrovni a vyhľadávať a používať existujúcu dokumentáciu.
- Dátová línia. Dátová línia umožňuje používateľom dôverovať ich BI a analytike. Pomocou dátovej línie s metaúdajmi môžu organizácie pochopiť, odkiaľ údaje pochádzajú a sledovať, ako sa zmenili a transformovali. To by mohlo zahŕňať, ako by vplyv zmien na jeden dátový prvok mohol ovplyvniť iné systémy.
- Modelové riadenie. Akonáhle je prediktívny model postavený, môže sa časom stratiť a degradovať, takže kontinuálne sledovanie je dôležitou súčasťou procesu riadenia analýzy. Niektoré riešenia nástrojov automatizujú monitorovanie. Iné nástroje poskytujú automatické upozornenia, keď je model degradujúci.

Nástroje pre spracovanie a transformáciu dát predstavujú kľúčový prvok pre zabezpečenie efektivity. Tento komponent zahŕňa čistenie dát, transformáciu dát, anonymizáciu dát, obohacovanie dát, replikáciu dát, procesy dátovej kvality, optimalizáciu dát, orchestráciu dát, virtualizáciu dát, aktívny archív, spracovanie v pamäti.

Podporované postupy a priority pre zber a spracovanie údajov:

1. Zhromažďovanie a získavania dát - prehľadávanie dát a dátových zdrojov, zber dát, integrácia dát, popis dát, formátovanie dát, prepájanie dát, skladovanie dát, meranie dátovej kvality,
2. Použitie prísnych metód zberu údajov. Zvážte a zamerajte sa na možné skreslenia a medzery v zozbieraných údajoch, vykonajte kontroly kvality údajov a zozbierané údaje zdokumentujte.
3. Vytvorte kultúru využívania údajov uprednostnením budovania kapacít a úsilia o využívanie údajov medzi občanmi, ktorých údaje sa zbierajú.
4. Zber údajov z viacerých zdrojov a použitie kombinácie metód zberu a analýzy údajov.

-
5. Počas celého životného cyklu projektu by sa mali dodržiavať najlepšie postupy a normy pre zber a správu údajov.
 6. Vypracovanie plánu analýzy údajov. Zmapujte, ako budú zhromaždené údaje usporiadané, klasifikované, porovnávané a zobrazené. Tento plán by mal byť spojený s metódami a nástrojmi zberu údajov.

5.3.3 Zdieľanie údajov

Schopnosť zdieľať údaje prostredníctvom internetu prostredníctvom internetu priniesla nové hrozby pre bezpečnosť a súkromie osobných údajov, čo zvyšuje potrebu dôvery medzi vládou a občanmi a medzi vládnymi orgánmi. Lepšia spolupráca s občanmi a jasnejšie vysvetlenie, kedy a prečo sa údaje používajú, môžu pomôcť vybudovať dôveru. Auditovateľnosť je tiež kľúčom k tomu, aby pomohla ľuďom a organizáciám sledovať, ako sa údaje používajú na zabezpečenie toho, aby každá interakcia s osobnými údajmi bola kontrolovateľná, transparentná a bezpečná. Právny rámec týkajúci sa zdieľania údajov sa často označuje ako veľmi zložitý. Nové právne predpisy, ako napríklad všeobecné nariadenie o ochrane údajov (GDPR), sa nachádzajú nad existujúcimi rámcami, ktoré môžu organizáciám verejného sektora vytvárať neprehľadný systém na navigáciu. Vždy, keď sa informácie zdieľajú, musia organizácie verejného sektora prejsť procesom vytvorenia alebo nájdania správnej legálnej „brány“, aby sa umožnilo zdieľanie bezpečným spôsobom, ktorý môže trvať roky. Vytvorenie novej dátovej infraštruktúry, ktorá umožní organizáciám prekonať prekážky v zdieľaní údajov, si vyžaduje jasné vedenie a prístup založený na spolupráci. Objavujú sa príležitosti na presmerovanie vodcovstva prostredníctvom nových štruktúr a nových pozícií, napríklad CDO.

Podporované postupy a priority pre zdieľanie údajov

1. Príprava dát - príprava a výber dát, čistenie dát, prieskum dát, hľadanie informácií a vzťahov medzi dátami,
2. Zdieľanie údajov s vedeckou komunitou a používanie štandardov údajov a interoperability s cieľom vyplniť medzery vo vedomostiach
3. Prezentácia údajov vo formátoch, ktoré sa dajú ľahko interpretovať, ako napríklad vizualizácia údajov. Jednotlivé časti údajov musia byť prezentované v štandardných formátoch, aby sa umožnilo zdieľanie v rámci služieb. Kvalitu údajov je možné zlepšiť prostredníctvom lepšieho monitorovania kvality a štandardov údajov a prostredníctvom procesov spracovania údajov.
4. Technické riešenia, ako sú napríklad aplikačné programovacie rozhrania (API), sa môžu prekrývať na starších systémoch, aby sa zlepšila interoperabilita a umožnilo zdieľanie údajov. To je však možné iba so správnymi normami a spoľahlivým novým modelom údajov.
5. Audit toho, ako sa údaje používajú na zabezpečenie toho, aby každá interakcia s osobnými údajmi bola kontrolovateľná, transparentná a bezpečná.

5.3.4 Rozhodovanie na základe údajov

Dáta majú potenciál pomôcť formovať vládu budúcnosti. Údaje však nemajú mozog, a preto nemôžu nič riadiť. Rozhodovanie založené na údajoch je teda len čiastočne o údajoch. Jasná a spoločná vízia a vedenie zohrávajú hlavnú úlohu pri rozhodovaní. Ako už bolo uvedené, údaje musia byť včasné, relevantné a dôveryhodné. Ak tomu tak nie je, rozhodovacie orgány majú obmedzené možnosti. Ďalšou významnou prekážkou efektívneho rozhodovania založeného na údajoch je fakt, že sme ďaleko od dokonalých tvorcov rozhodnutí. Nie vždy pristupujeme k problémom najobjektívnejším spôsobom, často prinášame vlastné subjektívne skúsenosti a zameriavame sa na nepodstatné detaily. To vedie k

chybným, nelogickým mysleniam a rozhodnutiam. Tieto vplyvy a mechanizmy sa nazývajú kognitívne predsudky. prečo si nemôžeme vždy dôverovať?

- Sme rozporuplní – Keď máme k dispozícii rovnaké dôkazy v rôznych časoch, dospievame k iným záverom; a keď sú rôznym ľuďom predložené rovnaké dôkazy, môžeme dospieť k iným záverom
- Pamätáme si na veci, ktoré sa nestali – Naša intuícia je založená na častiach skutočných faktov, obklopených dierami, ktoré máme sklon vyplniť predpokladmi a presvedčeniami.
- Nevzdáme sa zlých údajov – Internalizujeme fakty, budujeme mentálne modely a potom, keď sú nové dôkazy v rozpore s týmito faktami, sme veľmi odolní voči zmene nášho modelu alebo prijatiu nových údajov.
- Sme unavení a hladní – Naše rozhodnutia ovplyvňujú iné vnútorné, vonkajšie faktory, ako je hlad, nálada a energia. V analýze boli sledované rozhodnutia ôsmich sudcov. Najjednoduchším rozhodnutím bolo odmietnuť prepustenie, ktoré dosiahlo až 65% po obede a ku koncu dňa sa postupne znižovalo.

Rozhodovanie založené na údajoch a potenciál prediktívnej analýzy sa dostáva do popredia, čo sa odráža predovšetkým v oblastiach:

- Lepšie poskytovanie služieb - Analýzu dát možno využiť na zlepšenie existujúcich služieb a na vytvorenie nových súborov údajov, ktoré by viedli k úplne novým verejným službám.
- Lepšia tvorba politík - Tvorcovia politík používajú satelitné snímky, údaje z mobilných telefónov apod. na sledovanie a vytvorenie nových alternatívnych ukazovateľov v reálnom čase, dôležitých pre tvorbu rozhodnutí..
- Lepšia angažovanosť občanov - Uplatňovaním strojového učenia na sociálne médiá môžu byť vlády vnímavejšie voči náladám občanov, čím sa začína nová dimenzia občianskej angažovanosti.

Keď organizácie uvažujú o analytických technológiách, ktoré pomáhajú pri rozhodovaní založenom na údajoch, zvyčajne uvažujú o nástrojoch, ako napríklad:

Riadenie výkonnosti. Metódy a nástroje riadenia výkonnosti pomáhajú používateľom zamerať sa na prístup k údajom, analýzu a v konečnom dôsledku na výkonnosť dôležitých cieľov a cieľov projektu. Ciele sa zvyčajne pohybujú od širších cieľov, ako je zlepšenie spokojnosti zákazníkov až po úzko definované ciele zamerané konkrétne na zodpovednosti zamestnanca, ako napríklad dokončenie procesu v stanovenej lehote. Riadenie výkonnosti je preto dlhodobou hlavným zameraním BI a dátových skladov, aby umožnilo podnikovým používateľom pracovať s metrikami založenými na údajoch efektívne na usmerňovaní rozhodnutí a činností. Namiesto toho, aby používatelia poskytovali objemné prehľady, ktoré vyžadujú, aby vyhľadávali relevantné údaje, môžu metriky výkonnosti uľahčiť používateľom rýchlejšie využívanie údajov v rámci kontextu a rýchlejší prístup k najdôležitejším údajom. Na presné a konzistentné definovanie KPI a iných metrík musia manažéri preskúmať BI reporty a analýzy. Dátové sklady často hrajú dôležitú úlohu pri poskytovaní prístupu k starostlivo vyčisteným a štruktúrovaným údajom na podporu metrík riadenia výkonnosti. Vďaka dobre definovaným metrikám, ktoré sú aktuálne, môže riadenie výkonnosti pomôcť organizáciám zosúladiť rozhodnutia a akcie s cieľmi. Ciele poskytujú hodnotný kontext pre analýzu údajov. Rozhodovatelia tak potrebujú technológiu, ktorá im umožní interakciu s údajmi relevantnými pre metriky výkonnosti. Ak užívatelia nie sú schopní preskúmať údaje, nemôžu efektívne využívať údaje na zlepšenie výkonu. To môže spôsobiť, že metriky budú menej cenné pre riadenie rozhodnutí a akcií.

Dashboardy a scorecards. Dashboardy a scorecards sú obvyčajne spôsob, akým organizácie komunikujú ciele riadenia výkonnosti. Väčšina BI riešení podporuje ovládacie panely na mobilných zariadeniach, natívne alebo prostredníctvom webu, ako aj na desktopoch, laptopoch a pracovných staniciach. Dashboardy sa vyvinuli tak, aby slúžili širšiemu účelu ako používateľský portál (alebo „informačný panel“) nielen pre metriky výkonnosti, ale aj pre širší rozsah vizualizácií, vrátane grafov, tepelných máp (heat maps) a meradiel a textových informačných kanálov.

Samoobslužná vizuálna analýza a zisťovanie údajov. Riešenia v tejto oblasti sa zameriavajú na riešenie potrieb používateľov, ktoré presahujú spotrebu údajov. Používatelia chcú analyzovať údaje, ale nechcú opustiť jednoduchšie používateľské rozhranie a grafické skúsenosti, ktoré sú charakteristické pre riadiace panely. Riešenia vizuálnej analýzy a vyhľadávania údajov poskytli väčšiu samoobslužnú funkcionálnu ako staršie podnikové BI riešenia. S týmito riešeniami môžu používatelia sledovať údaje prostredníctvom moderných grafických rozhraní a vizualizácií, vrátane dashboardov. Schopnosti samoobsluhy im umožňujú vybrať si súbory údajov, dotazovať sa na dáta a vytvárať vlastné vizualizácie. Väčšina riešení prichádza s knižnicami typov vizuálnej reprezentácie, ako sú grafy, tepelné mapy a rozptýlené projekty; Mnohé riešenia umožňujú používateľom rozšíriť svoje možnosti importom vizualizácií z vonkajších zdrojov, vrátane open source.

Príprava a integrácia údajov. Pokroky v príprave údajov sú rozhodujúce pre to, aby používatelia mohli využívať vizuálne analytické riešenia, pretože sa snažia o prístup k väčšiemu množstvu zdrojov údajov. Príprava dát zahŕňa celý rad procesov, ktoré začínajú s prijímaním a zhromažďovaním údajov a prebiehajú prostredníctvom zlepšovania kvality a transformácie. Tieto procesy sú často pomalé a komplikované a vyžadujú značné manuálne úsilie, ktoré môže zabrániť tomu, aby BI a analytika zohrávali integrálnejšiu úlohu v každodennom rozhodovaní. Užívatelia zvyčajne musia počkať, kým IT pripraví údaje, alebo prevziať úlohu s neštandardnými nástrojmi a menej konzistentnými metódami, ktoré môžu spôsobiť chyby a nezrovnalosti. Samoobslužná funkčnosť pomocou termínov, ako je napríklad miešanie údajov (blednign), wrangling a munging, umožňuje používateľom preskúmať údaje a vybrať súbory údajov, ktoré vyhovujú ich procesom BI a vizuálnej analýzy. Samoobslužná funkcionálna je tiež zrelá na použitie pri vývoji dátových katalógov, glosárov a repozitárov metadát. Toto je rozhodujúce pre to, aby používatelia mohli získať kompletný prehľad o údajoch a zdieľať údaje a poznatky založené na údajoch s ostatnými.

Pokročilé analýzy. Pokročilé analytické nástroje zahŕňajú nástroje ako prediktívne modelovanie a strojové učenie. Tieto nástroje môžu pomôcť používateľom nájsť vzory v údajoch, ktoré môžu riadiť rozhodnutia. Tieto nástroje majú miesto vo vznikajúcej oblasti automatizácie, ktorá môže tiež pomôcť organizácii stať sa viac orientovanou na údaje.

Automatizácia. Existuje celý rad nástrojov, ktoré automatizujú životný cyklus analýzy, od prípravy údajov až po budovanie modelov, ktoré využívajú pokročilé analytické metódy, ako napríklad strojové učenie alebo spracovanie prirodzeného jazyka. Tieto produkty môžu pomôcť organizáciám pri rýchlejšom rozhodovaní. Organizácie môžu používať prediktívne analýzy na pomoc pri upozorňovaní, napríklad podvodov – systémy môžu smerovať potenciálne podvodné transakcie na špeciálnu vyšetrovaciu jednotku na ďalšie spracovanie.

Podporované postupy a priority pre rozhodovanie na základe údajov:

1. Správa analytického „sandboxu“ pre potreby ad-hoc analýz a podpory inovácií
2. Využívanie kvalitných údajov v reálnom čase alebo včasných údajov na podporu rýchleho rozhodovania, zlepšenia programovania pre používateľov a informačnej stratégie
3. Zavedenie modelov, dát a nástrojov, ktoré umožnia vytvoriť analýzy, na základe ktorých sa podporia rozhodovacie procesy
4. Podpora analytického spracovania údajov využiteľného aj pre návrh a hodnotenie politík a posudzovanie vplyvov a hodnotenie dopadov regulácií
5. Transformácia fungovania organizácie a procesov tak, aby boli tieto analýzy efektívne používané a zároveň zverejňované vo vhodnej vizuálnej podobe pre verejnosť
6. Vytvorenie alebo posilnenie analytickej jednotky v organizácii, ktoré budú realizovať analýzy s využitím potrebných nástrojov poskytovaných ako služba.

5.3.5 Tvorba analytických výstupov

V našom informačnom veku je úloha informácií pri tvorbe politiky rozhodujúca. Údaje môžu poskytnúť hlboký prehľad o správaní ľudí, s cieľom lepšie vytvárať politické rozhodnutia. Objavujú sa aj nové dohody medzi verejným a súkromným sektorom s cieľom sprístupniť údaje zo sociálnych médií, profesionálnych sietí, mobilných telefónov a senzorov pre tvorcov politik. Tvorba politik sa tradične zakladá na správach, ktoré sú vo veľkej miere založené na tradičných prieskumoch a administratívnych údajoch a štatistikách - nástroje, ktoré sú pomalé a náročné na prácu. Na rozdiel od toho, nové technológie a nástroje môžu potenciálne priniesť politické pohľady na častejšom, rozčlenenom a nákladovo efektívnom základe. Tradičné prieskumy - ako sú sčítania, oficiálne štatistiky a podnikové údaje - budú vždy potrebné, ale je viac ako pravdepodobné, že sa veľké údaje budú aj naďalej objavovať a integrovať do procesov a rozhodnutí v oblasti tvorby politik. Existuje štyri základné typy analýz, usporiadané od najjednoduchších až po najzložitejšie: i.) Deskriptívna analýza; ii.) Diagnostická analýza; iii.) Prediktívna analýza a iv.) Preskriptívna analýza.

Deskriptívna analýza je najjednoduchší typ analýzy. Cieľom deskriptívnej analýzy je numericky opísať kľúčové vlastnosti vzorky. Často môže tvoriť údaje, ktoré sa zobrazujú na dashboardoch. Môžu tiež poskytnúť prehľad alebo pohodlie, pokiaľ ide o kvalitu údajov. Deskriptívna analýza je zvyčajne prvým krokom, šancou získať zmysel pre dáta k hlbšej analýze.

Použitie grafiky na preskúmanie a vizualizáciu údajov sa nazýva **Diagnostická analýza**. Grafy nám pomáhajú vidieť väčší obrázok dátového súboru a pomáhajú nám odhaliť zjavné alebo nezvyčajné vzory. Diagnostická analýza nám zvyčajne poskytuje množstvo možností, s ktorými sa dá študovať systém. To zase pomáha analytikovi, aby prišiel s novými hypotézami o tom, čo by sa mohlo diať a s ktorými pákami musíte pracovať. Diagnostická analýza môže tiež vyzdvihnúť medzery v našich vedomostiach a pomôcť určiť, ktoré experimenty by mohli zmysluplne vyplniť tieto medzery.

Prediktívna a Preskriptívna analýza vychádza z inferenciálnej analýzy. Cieľom je poukázať na vzťahy medzi premennými z existujúceho súboru údajov a vytvoriť štatistický model, ktorý dokáže predpovedať hodnoty atribútov pre nové, neúplné alebo budúce dátové body. Prediktívna analýza sa potom môže použiť na generovanie prognóz a budúcich predpovedí v časových radoch, ktoré sa môžu použiť na generovanie plánov (Preskriptívna analýza). Aplikácie prediktívnej analýzy sú obrovské, napríklad: softvér na predikciu akcií; Filtre proti spamu; Sociálne siete; prediktívny policajný dozor; Predpovedanie dopytu.

Tabuľka 9

	Použitie	Požadované nástroje
Pohľad naspäť		
Deskriptívna analýza (Čo sa stalo?)	Prehľad stavu za danú oblasť; Obsiahle, presné a živé dáta; Efektívna vizualizácia	1. Datová agregácia 2. Data Query 3. Štatistická analýza 4. KPIs
Diagnostická analýza (Prečo sa to stalo?)	Analýza príčin; Schopnosť prechádzať dátami a izolovať jednotlivé informácie	1. Data mining 2. Vizualizácia 3. Sémantická analýza 4. Analýza sentimentu 5. Regresná analýza
Pohľad dopredu		

Prediktívna analýza (Čo sa stane?)	Odhad pravdepodobných výsledkov; Využívanie historických trendov a algoritmov	<ol style="list-style-type: none"> 1. Štatistické modely 2. Simulácie 3. Machine learning 4. Prediktívne modelovanie
Preskriptívna analýza (Čo treba urobiť aby sa to stalo?)	Podpora rozhodovania; Využívanie pokročilých analytických techník pre návrh doporučení	<ol style="list-style-type: none"> 1. Optimalizačné modely 2. Neurónové siete 3. Umelá inteligencia 4. Heuristické metódy

Špecifické činnosti pre dátami riadené organizácie:

- Dátami riadené organizácie neustále testujú. Môže to byť testovanie A / B, tok na webovej stránke alebo testovanie vplyvu v kampani. LinkedIn napríklad vykonáva 200 experimentov za deň. Testy môžu tiež zahŕňať testovanie priamo s užívateľmi s cieľom získať priamu spätnú väzbu o možných nových funkciách alebo službách.
- Dátami riadené organizácie sú zapojené do prediktívneho modelovania, prognózovania, ale čo je najdôležitejšie, krmia predikčné chyby a iné učenia späť do modelov, aby sa zlepšili.
- Dátami riadené organizácie takmer určite budú vyberať medzi budúcimi možnosťami alebo akciami na základe údajov. Analytici musia informovať a ovplyvňovať tých, ktorí rozhodujú. Technológia a školenia môžu urobiť prvú časť: umožniť analytikom vykonávať analýzy a zverejňovať svoje zistenia. Je to však kultúra, ktorá vytvára spôsob myslenia, v ktorom môžu byť údaje dôverované a použité na určenie ďalších krokov
- Automatizácia, ktorá zahŕňa zníženie ľudského zásahu, prichádza v mnohých smeroch. Napríklad, pretože informatici a štatistici (ľudia, ktorí vytvárajú prediktívne modely) sú v nedostatočnej ponuke, existujú nástroje, ktoré automatizujú proces vytvárania modelu. Analytik napríklad jednoducho špecifikuje cieľovú (alebo výslednú) premennú, ktorá je predmetom záujmu, a softvér vytvorí najlepší model s použitím poskytnutých atribútov. Niektoré nástroje na prípravu údajov uľahčujú vyhľadávanie, zhromažďovanie, integráciu, profilovanie a transformáciu údajov. Niektoré nástroje využívajú strojové učenie a spracovanie prirodzeného jazyka na pochopenie sémantiky a urýchlenie porovnávania údajov. Niektoré nástroje tiež umožňujú tvorcom modelu, aby určil pravidlá pre systém na spustenie výstrah, keď je model degradujúci a je potrebné ho preškoliť. Iné nástroje idú ďalej a vykonávajú automatickú detekciu degradácie modelu na základe určitého parametra. Ďalším aspektom automatizácie je opätovné použitie toho, čo už bolo vytvorené pre správu dát a analýzu. Napríklad pracovné postupy sa často vytvárajú pomocou rozhraní drag-and-drop na zostavovanie dátových potrubí zo zdroja na cieľ. Ten istý pracovný tok možno uložiť a vložiť do analytického pracovného postupu, aby sa vytvoril prediktívny model. Mnohé nástroje poskytujú možnosť ukladania a opätovného použitia pracovných postupov. Niektoré poskytujú aj možnosti plánovania. Keďže nástroje sa ľahšie používajú, tí, ktorí používajú nástroje, musia pochopiť, čo robia. Napríklad používateľ, ktorý vytvára prediktívny model s automatizovaným nástrojom, musí pochopiť, čo výstup predstavuje. Na tento účel nástroje často obsahujú vysvetlenia toho, čo urobili. Napríklad analytický nástroj využívajúci technológiu neurónovej siete (Neural Network Technology) môže s výsledkami obsahovať vysvetlenie, ako boli výsledky získané.

Podporované postupy a priority pre tvorbu analytických výstupov:

1. Výber vhodných analytických metód,
2. Tvorba analytického dátového modelu: vypracovanie modelu, kontrola modelu, zdieľanie modelu,

3. Testovanie hypotéz (test relevantnosti a test istoty),
4. Realizácia „Randomized Control Trials“ (RCT) a A/B testovania
5. Automatizácia

5.3.6 Testovanie dopadov a efektivity politík

Vlády rýchlo videli výhody výpočtovej techniky a prijali ju. Pokiaľ ide o agentúry na správu príjmov, ktoré sa vždy obávali „úniku“, najskoršie a najpokrokovejšie spôsoby použitia prediktívnych analýz boli v oblasti zisťovania podvodov a chýb. Keďže podvody a omyly sú pre tieto agentúry naďalej najväčšou výzvou, technológia sa naďalej vyvíja, aby lepšie vyhovovala týmto potrebám. Zároveň je však väčšina vládnych agentúr iba v počiatočných fázach uplatňovania analytických prístupov, aby sa stala efektívnejšou v iných častiach svojich úloh v rámci misie, ako napríklad:

- Meranie efektívnosti a účinnosti poskytovania služieb;
- Vykonávanie účinnejších hodnotení vplyvu politiky;
- Zvýšenie presnosti prognóz týkajúcich sa dopytu a výdavkov.

Prediktívna analytika je nástroj založený na údajoch, ktorý vychádza z potvrdených vzťahov medzi premennými a predpovedá budúce výsledky. Preto môže poskytnúť vláde nové analytické schopnosti na zvýšenie efektívnosti rozhodovania o politikách v turbulentných prostrediach.

Podporované postupy a priority pre testovanie dopadov a efektivity politík:

1. vízia, stratégia a politiky, ktoré preukazujú odhodlanie vedenia analyzovať údaje a sprostredkujú zamestnancom úlohy a zodpovednosti. Správa údajov zodpovedá za normy a kontroly, ktoré sa uplatňujú v rámci celej organizácie a ktoré môžu pomôcť zabezpečiť kvalitu, konzistentnosť, bezpečnosť a údržbu údajov, ako aj monitorovanie a hodnotenie analytických údajov.
2. porozumenie a angažovanosť vedenia a personálu pri zavádzaní a udržiavaní účinných programov na analýzu údajov. Zdieľanie údajov a prijímanie nových procesov a nástrojov sa spoliehajú na kultúru, ktorá chápe výhody analytiky údajov, ale pri použití na hodnotenie efektívnosti politiky zachováva realistické očakávania a profesionálny skepticizmus.
3. technické zručnosti a znalosti potrebné na používanie príslušných metodík a softvéru sú kritické, vrátane skúseností s programovaním
4. pre inštitúcie je rozhodujúce zaujať strategický prístup k investíciám do technologickej infraštruktúry, ktorá uľahčuje analýzu údajov a zabezpečí, aby sa investície zosúladi s cieľmi.

5.3.7 Publikovanie údajov: otvorené údaje a vizualizácia

Otvorenosť je základom otvorených údajov, je to absencia obmedzení a bariér, s cieľom dosiahnuť rovnaký prístup a využitie. Otvorené verejné údaje sú viac ako samotné údaje. Zahŕňajú právnu a technickú otvorenosť:

Právna otvorenosť - možnosť získať legálne údaje, stavať na nich a zdieľať ich. Zákonná otvorenosť sa zvyčajne poskytuje uplatňovaním primeranej (otvorenej) licencie, ktorá umožňuje voľný prístup k údajom a ich opakované použitie alebo umiestňovaním údajov do verejnej sféry.

Technická otvorenosť - pri používaní údajov by nemali existovať žiadne technické prekážky. Napríklad poskytnutie údajov na papieri (alebo ako tabuľky v dokumentoch PDF) sťažuje prácu s informáciami. Otvorená definícia má rôzne požiadavky na „technickú otvorenosť“, napríklad vyžaduje, aby údaje boli strojovo čitateľné a dostupné hromadne. Takto sú skutočne otvorené verejné údaje súborom údajov, ktorý je v zásade pripravený pre každého, aby si ho vzal a urobil s ním všetko, čo chce.

Prezentácia dát v grafickom formáte, umožňuje analytikom a pracovníkom vykonávajúcim rozhodnutia vizualizovať trendy a koncepty. Pokročilé nástroje umožňujú interaktívne analyzovať dáta jednotlivým užívateľom vo forme self-service. Pre manažerskú úroveň je štandardom Dashboard, vizuálne prezentujúci kľúčové KPIs a sektorové/medzinárodné benchmarky. Príklady použitia Dashboardu sú procesy ako napr.:

- Demografia a štatistika
- Plánovanie a rozpočtovanie
- Alokácia fondov
- Kriminalita
- Vzdelávacie aktivity a ich vyhodnocovanie
- Hodnotenie výkonnosti projektov

Každý súbor údajov, každá databáza, každá tabuľka má príbeh. Úlohou analytika je nájsť tento príbeh, interpretovať ho a komunikovať. Hľadanie príbehu a jeho interpretácia zahŕňa celý rad analytických techník, ktoré zvyčajne zahŕňajú vizualizáciu údajov pomocou grafov a tabuliek. Vizualizácia dát má mnoho komponentov, z ktorých každá vyžaduje starostlivé zváženie. Jediná zlá voľba, ako sú nízko kontrastné farby, malá veľkosť písma alebo nevhodná voľba grafu, môže urobiť celú vizualizáciu škaredou a zbytočnou.

Infografiky - Všeobecne platí, že organizácia riadená údajmi bude mať malé využitie pre infografiku interne a určite nie pre rozhodovanie. Zaujímavé je, že nedávny výskum zistil, že „chartjunk“, piktogramy, farba a kontrast (z ktorých všetky sú prominentné v infografike) uľahčujú ich zapamätanie. Aby sme však zopakovali hlavné posolstvo, cieľom je komunikácia s cieľom podnikat' činnosť. Vedenie potrebuje vysokokvalitné informácie, ktoré im umožnia nielen vidieť a zapamätať si údaje, ale aj hodnotiť na ich základe a uistiť sa, že rozhodnutie je správne.

Dashboardy - Mnohé organizácie mylne merajú svoju údajovú orientáciu podľa počtu správ a dashboardov, ktoré produkujú. Dashboardy sú veľmi užitočné a môžu podporovať celý rad aktivít, ako je napríklad poskytovanie rozhrania na vyhľadávanie údajov a upozornenia, ako aj prístup k predpovediam a prediktívnym modelom. Dashboardy patria do troch kategórií: i.) výkonné alebo strategické; ii.) analytické; iii.) operatívne; výkonnostné dashboardy poskytujú vysokoúrovňový pohľad na organizáciu a zvyčajne sa zameriavajú na scorecard (KPI a ich ciele). Informačný panel by mal poskytnúť rýchly a jednoduchý prehľad o tom, či organizácia plní svoje ciele. Analytické dashboardy zaujímajú pohľad na nižšiu úroveň, zachytávajú kľúčové trendy a ukazovatele v rámci jednej jednotky. Typicky interaktívne, čo umožňuje zúžiť pohľad na neobvyklé trendy a objavovať údaje. Operatívne dashboardy poskytujú nižšiu latenciu, podrobnejšie pohľady na veľmi špecifické časti. Mal by existovať jasný prípad použitia a presvedčivý dôvod pre každú tabuľku alebo číslo, ktoré sa objaví na dashboarde. Menej je viac. Možno má zmysel mať viac dashboardov pokrývajúcich rovnaké údaje, ale pre rôzne časové rámce.

Storytelling - Obsah založený na údajoch nie je len o prezentovaní čísel a pochopení. Ide aj o vytváranie vzťahov s cieľovými skupinami. Každé slovo alebo vyhlásenie nemožno považovať za údaje. Môžu to byť len faktické informácie, ktoré sú výsledkom testovania alebo experimentov, ktoré tvoria záver alebo ponúkajú riešenie. Rôzni výskumníci a experimenty na tej istej téme môžu ponúknuť rôzne údaje, ale pokiaľ údaje pochádzajú zo spoľahlivých zdrojov, váš obsah založený na údajoch bude hodnotnejší v očiach cieľovej skupiny. Efektívne príbehy založené na údajoch začínajú so silnými otázkami, ktoré sú

relevantné pre vaše publikum a ak môžete kvantifikovať svoje odpovede na tieto otázky, môžete vytvoriť základ pre svoj obsah založený na údajoch. Prečo je rozprávanie založené na dátach tak dôležité? Nájdenie odpovedí musí predchádzať pochopenie bariér, ktoré bránia oslovenie publika:

- Ľudia sú zahltení nadbytkom obsahu a médiami.
- Marketingové správy, mobilné zariadenia a ďalšie obsahy denne útočia na pozornosť spotrebiteľa a multitasking sa stal novou kultúrnou normou.
- Ľudia nemajú dostatok pozornosti. Mozog spotrebiteľov nie je nafukovací a môže v jednom okamihu vstrebať len určité množstvo informácií tak, aby ešte dávali zmysel. Konzumácia obsahu vyžaduje tunelové videnie. Spotrebiteľia sa zameriavajú len na obsah, ktorý je pre nich ešte relevantný v danom okamihu a všetko ostatné odfiltrujú.
- Cesta spotrebiteľa je nepredvídateľná. Spotrebiteľia obsah spracúvajú bez špecifickej rutiny. Ich rozhodovací proces pri nákupe je nepredvídateľný, čo značne znižuje schopnosť značiek je osloviť.

Ak zistíte, aké sú najdôležitejšie otázky cieľovej skupiny, budete musieť posúdiť, či sú k dispozícii údaje, ktoré vám pomôžu odpovedať na tieto otázky. Na zhromažďovanie, odhadovanie a filtrovanie informácií budete potrebovať postup. Hľadanie vhodných údajov na podporu vášho príbehu je kľúčové, pretože nechcete vytvárať legitímny obsah, ktorý nemôže presvedčiť vaše publikum. Hlavnými komponentmi dobrého zdroja údajov sú:

- Originalita - Vaše údaje by mali vždy pochádzať z primárneho zdroja. Ak narazíte na zaujímavé pozorovanie v článku alebo prípadovej štúdii, nájdite jeho pôvodný zdroj. Ak údaje neskúmate, nikdy neviete, či je to pravda alebo nie.
- Dôkladnosť – Váš zdroj údajov by mal byť dostatočne informatívny, aby zodpovedal otázky vašich zákazníkov.
- Včasnosť – Údaje sa rýchlo menia. Informácie sú zastarané v mesiacoch. To je dôvod, prečo by ste mali pre svoju stratégiu obsahu používať iba najnovšie zdroje.
- Spoľahlivosť – Váš zdroj údajov by mal byť čo najrelevantnejší. Skôr ako si vyberiete zdroj, opýtajte sa sami seba, kto to napísal, kto to povedal alebo kedy bola naposledy aktualizovaná, ako aj účel zverejnených informácií. (Akademické časopisy, univerzitné stránky, štúdie a výskumné správy sú vo všeobecnosti výbornými zdrojmi údajov, zatiaľ čo väčšina blogov na druhej strane nie sú.)

Napriek skutočnosti, že mnohé zo špecifík, ktoré sa týkajú rozprávania príbehov údajov, závisia od konkrétneho prípadu použitia, zámeru a problému, ktorý sa rieši, existujú niektoré všeobecné zásady, ktoré predstavujú najlepšie postupy a ktoré sú podrobne opísané v nasledujúcom poradí:

- Nastavenie - Počiatočné okamihy prezentácie údajov by mali začať zaujímavým otváračom, ktorý podporí zvedavosť. Najlepším príkladom je ilustrovanie problému alebo jeho účinkov na organizáciu.
- Kontext - Je potrebné ilustrovať súčasné skutočnosti, ktoré sa týkajú údajov alebo problému, ktorý vyžaduje, aby vyšetrovatelia vybrali vizualizácie, určili zámer akcie a identifikovali nástroje a iné logistické informácie.
- Možnosti - Tento krok predstavuje bod v príbehu, v ktorom moderátor presvedča poslucháčov o užitočnosti svojho návrhu založeného na analytike. Priamo zahŕňa dôsledky údajov a je vizuálne reprezentovaný. Podmienené obavy zahŕňajú údaje, ktoré sú k dispozícii na použitie, a všetky procesy riadenia, ktorých sa môžu týkať.
- Výzva na akciu - výzva na akciu zdôrazňuje, čo presne organizácia môže urobiť, aby poukázala na príčinu problému alebo poskytla jej riešenie.

Podporované postupy a priority pre publikovanie údajov:

1. Hodnotenie výsledkov: produkcia finálneho reportu, posúdenie výsledkov a ich významu,
2. Komunikácia výsledkov a pripomienkovanie: publikovanie reportu, zber spätnej väzby, vizualizácia výsledkov, príprava analytického produktu.
3. Rozvoj kultúry založenej na údajoch v celej organizácii s modelovým prístupom k správe údajov a zverejňovaniu údajov v otvorenom formáte, ktorý sa stáva rutinou.
4. Budovanie hodnotovo orientovanej ekonomiky okolo otvorených údajov zverejňovaním súborov údajov
5. Stimulácia inovácií a hospodárskeho rastu, podpora transparentnosti a efektívnosti verejnej správy prostredníctvom využívania údajov a zlepšenie kvality údajov na základe spätnej väzby od používateľov
6. Zabezpečenie riadiacich štruktúr na vedenie a riadenie iniciatívy a zabezpečenie konzistentného a koherentného prístupu k otvoreným údajom.
7. Spolupráca so širokou komunitou zainteresovaných strán vrátane obchodu, výskumu a akademických pracovníkov, občianskej spoločnosti a občanov na propagácii a podpore využívania otvorených údajov.

6 Riešenie

- výber a implementácia vhodných dátových modelov pre Regulácie 2.0

Aby bolo možné úspešne aplikovať dátové modely do fungovania organizácie je potrebné:

- **Prebudovať organizačný model práce a úloh:** Navrhujeme zaviesť model takzvanej dátovej fabriky, ktorá natívne podporuje rozhodovanie na základe algoritmov s využitím dát. Je preto potrebné zabezpečiť kontinuálne toky údajov o regulovanej oblasti.
- **Zaviesť neustále experimentovanie:** Algoritmy v dátových modeloch je potrebné neustále vylepšovať prostredníctvom testovania hypotéz. Ide o prístup, ktorý sa snaží prekonať tradičné hierarchické a byrokratické štruktúry a prospešne využíva experimentovanie a agilné metódy na zlepšovanie.
- **Výber algoritmov:** Algoritmy budú generovať predikcie o budúcich stavoch alebo akciách pre verejnú inštitúciu. Je potrebné vybrať vhodné algoritmy a manažovať ich životný cyklus pre jednotlivé agendy.
- **Softvérová infraštruktúra:** Na spracovanie údajov, beh algoritmov a realizáciu výsledkov sú potrebné aplikácie a technológie. Dátová kancelária ponúka k dispozícii nástroje KAV a zabezpečenie prepojenia KAV a agendových systémov.

6.1 Dátová fabrika

6.1.1 Koncept dátovej fabriky

Dátová fabrika je škálovateľný operačný model. Manažérske rozhodnutia sú stále viac automatizované a zakomponované do informačného systému verejnej správy, čo umožňuje digitalizáciu a optimalizáciu mnohých procesov, ktoré tradične vykonávali úradníci. Digitálna transformácia umožňuje rýchlejšie a efektívnejšie spracovanie dát, automatizáciu regulačných postupov a poskytuje nástroje na rozhodovanie založené na analýze dát. Úradníci vo verejnej inštitúcii 21. storočia neposudzujú každú žiadosť o povolenie samostatne. Tieto procesy sú digitalizované a podporované v rámci modelu dátovej fabriky. Rozhodovanie sa stáva priemyselným procesom. Analytické metódy systematicky prevádzajú interné a externé dáta na predikcie a poznatky.

Koncept dátovej fabriky zavádza nový operačný model pre verejné inštitúcie. V jadre svojej podstaty, nový operačný model verejnej inštitúcie vytvára kruhový proces medzi angažovanosťou občanov a podnikateľov, zhromažďovaním údajov, návrhom algoritmov, predikciou a zlepšovaním oblasti. Integruje údaje generované z viacerých zdrojov s cieľom doladiť a trénovať súbor algoritmov. Tieto algoritmy nielen predpovedajú, ale tiež využívajú údaje na zlepšenie vlastnej presnosti. Predikcie potom riadia rozhodnutia a akcie, buď informujúc ľudské poznatky, alebo umožňujúce automatizovanú odpoveď. Hypotézy o zmenách v správaní občanov a podnikateľov, reakciách účastníkov regulovaného trhu a variáciách procesov sa testujú prostredníctvom experimentálnych protokolov, ktoré umožňujú identifikáciu príčinných súvislostí zmien, ktoré by mohli zlepšiť systém. Údaje o používaní, presnosti a dopade predikčných výsledkov sa potom opäť zasielajú späť do systému pre ďalšie učenie a predikcie. A tento cyklus sa neustále opakuje.

Inštitúcia verejnej správy, ktorá by sa zmenila na dátovú fabriku, prípadne AI fabriku, by tým pádom výraznou mierou zjednodušila a zefektívnila svoje každodenné interné aktivity a procesy a zároveň zlepšila, zmodernizovala a skvalitnila svoje externé výstupy a služby smerom k občanom. Štátni zamestnanci by boli odbremenení od mnohých (častokrát automatických a nudných) úloh, ktoré by na seba prebrali algoritmy a technológie a namiesto nich by sa mohli venovať dôležitejším a zaujímavejším aktivitám.

Úradníci by vďaka pokročilej dátovej analytike získavali cenné podklady, ktoré by slúžili pre vznik kvalitnejších politík a služieb, ktoré občania najviac potrebujú, resp. najviac využívajú. Popritom všetkom by sa šetril čas, ľudské zdroje a ich energia, ako aj finančné a iné zdroje štátu.

Myšlienka dátovej fabriky a fabriky umelej inteligencie predstavuje radikálnu inovatívnu zmenu v spôsobe fungovania verejných inštitúcií, ktorými by sa štát mohol konečne priblížiť modernému digitalizovanému fungovaniu, ktoré už niekoľko rokov úspešne funguje v súkromnom sektore.

Miesto AI v organizačnom modeli

Pre dosiahnutie fungujúceho organizačného modelu s pevnou súčasťou umelej inteligencie je dôležité, aby inštitúcie urobili jednu z troch vecí:

- Možnosť 1: Skonsolidovať väčšinu schopností AI v centrálnom „hube“.
- Možnosť 2: Decentralizovať AI a zakomponovať ju do organizačnej jednotky, tzv. „spoke“.
- Možnosť 3: Distribuovať AI medzi oba modely a to pomocou hybridného modelu „hub + spoke“.

Hub je ideálnou entitou pre činnosti ako správa dát, vytváranie metodológie pre tvorbu modelov, vytváranie stratégie odbornej prípravy či spolupráca s poskytovateľmi dát, služieb a softvéru AI od tretích strán. Huby tiež efektívne podporujú rozvoj talentu v oblasti umelej inteligencie, vytvárajú komunity, kde si experti na AI môžu vymieňať osvedčené postupy a stanovovať procesy a normy rozvoja AI v celej organizácii AI.

Spoke je vhodný systém pre úlohy súvisiace s implementáciou AI, vrátane organizácie školení koncových používateľov, prepracovania pracovného postupu, stimulačných programov, riadenia výkonnosti a sledovania dopadov.

Navrhujeme použiť možnosť 3. Dátová kancelária verejnej správy bude slúžiť ako centrálny AI hub pre algoritmy vo verejnej správe (MIRRI) a jednotlivé inštitúcie si budú realizovať vlastné decentralizované algoritmy s využitím údajov a nástrojov z KAV.

6.1.2 Realizácia dátovej fabriky

Infraštruktúru pre zmenu svojho operačného modelu si môže verejná inštitúcia vybudovať aj lokálne a decentralizovane. Vďaka konceptu KAV však získava digitálny priestor pre analytickú podporu svojho fungovania.

KAV podporuje nasledujúce komponenty dátovej fabriky:

- „Data pipeline“: Tento proces zhromažďuje, vstupuje, čistí, integruje, spracováva a zabezpečuje údaje systematickým, udržateľným a škálovateľným spôsobom
- Experimentálny priestor: Ide o mechanizmus, prostredníctvom ktorého sa testujú hypotézy týkajúce sa nových predikčných a rozhodovacích algoritmov, aby sa zabezpečilo, že navrhované zmeny majú zamýšľaný (príčinný) účinok.
- Vývoj algoritmov: Algoritmy generujú predikcie o budúcich stavoch alebo akciách pre verejnú inštitúciu. Tieto algoritmy a predikcie sú srdcom digitálnej organizácie a riadia jej najdôležitejšie činnosti.
- Softvérová infraštruktúra: nástroje KAV a zabezpečenie prepojenie KAV a agendových systémov.

6.1.3 Konsolidovaná analytická vrstva

Konsolidovanú analytickú vrstvu spravuje organizačná zložka MIRRI - Dátová kancelária verejnej správy. Ide o verejnú inštitúciu. Odpovedá sa tak na otázky, ako nastaviť manažment analytickej vrstvy, akým spôsobom analytickú vrstvu vybudovať, ako zabezpečiť ochranu osobných údajov pri ich analytickom spracovaní a akým spôsobom zabezpečiť potrebné analytické nástroje a dáta.

Dátová kancelária verejnej správy vytvára otvorený ekosystém dát a aplikácií pre potreby analytických jednotiek. Ide súbor nástrojov a možností, z ktorých si budú môcť analytické jednotky nakombinovať systém podľa svojich potrieb a želaní.

Do Konsolidovanej analytickej vrstvy sa postupne integrujú všetky dostupné zdroje dát, pričom budú prístupné všetkým používateľom. Údaje budú prepojené na „mikroúrovni“, pričom identita subjektov nebude prístupná, k dispozícii budú len pseudoanonymizované údaje.

Zároveň si budú môcť inštitúcie vytvárať vlastné zóny, v rámci ktorých môžu používať aj neanonymizované údaje alebo integrovať nástroje KAV s vlastným informačným prostredím (agendovými systémami).

KAV bude verejný otvorený technologický priestor vytvorený vo verejnom cloude. Umožní sa tak orientácia na konkrétne prípady použitia, ktoré budú realizované dátovými projektami. Pôjde aj o dátové modely, algoritmy strojového učenia, metodiky pre zber a transformáciu údajov alebo vytváranie poučení („insights“).

Takýto návrh je relatívne praktický, pretože umožňuje špecializáciu pri využití analytických metód a nástrojov. Analytické jednotky, organizované flexibilne so zameraním na riešenie problémov a experimentovanie sa môžu venovať podpore prípadov použitia a vytváraniu analytických modelov. Technickú stránku vecí, akou je zabezpečenie kvalitných dát, dátovej infraštruktúry a vhodných nástrojov, bude riešiť Dátová kancelária.

6.2 Experimentálny priestor pre dátovú vedu

Aby mala zmena organizačného modelu na dátovú fabriku zmysel, je potrebné aj zmeniť prístup k práci: začať aktívne a pravidelne experimentovať pri návrhu a realizácii politík a masívne nasadiť metódy dátovej vedy do bežnej činnosti.

6.2.1 Experimentálna organizácia

Bez experimentovania verejne inštitúcie a politiky stagnujú. Experimentovanie sú základom pokroku vo vede, v medicíne a v rozvojovej spolupráci a je na mieste uvažovať, ako takýto model uviesť aj v rámci verejného zdravotníctva. Je potrebné, aby organizácia dokázala:

- Učiť sa z realizovaných aktivít a adaptovať sa meniacim sa podmienkam,
- Vyrovnávať sa s komplexnosťou a rizikom,
- Myslieť najskôr v malom.

Učiť sa a adaptovať

Experimentálna organizácia nie je o skúšaní vecí náhodným spôsobom. Je potrebná istá miera systematického prístupu. Experimenty musia byť realizované spôsobom, aby sa z výsledkov dalo poučiť a celkovo, aby sa výkon politík dokázal prispôbovať okolnostiam.

Experimentálny prístup by mal tiež prekračovať statickú realizáciu politík, založenej iba na dôkazoch. Dôkazy totiž ukazujú na to, čo fungovalo v minulosti, maximálne je možné preniesť prístup, ktorý fungoval v iných krajinách. Posilňuje sa tak súčasný stav. Aby sme však dokázali čeliť súčasným výzvam, musíme neustále skúmať nové alternatívy a generovať tak nové znalosti.

Vyrovňávať sa s komplexnosťou a rizikom

Častou výčitkou pre nasadenie experimentálneho prístupu je riziko, že sa veci nepodarí ako sú plánované a že experimenty môžu skončiť neúspechom. Pri riešení akéhokoľvek otvoreného komplexného systému, o ktorom chýbajú informácie a v situácii keď panuje neistota, je však najlepším spôsobom, ako zistiť čo funguje, testovanie a experimentovanie. Vyžaduje si to však pragmatický prístup k výkonu verejnej politiky, ktorý podporuje riskovanie a je prívetivý k zlyhaniu. Naopak, chyby a neúspechy je potrebné pretaviť do poučenia sa z chýb. Rastú tak vnútorné znalosti a schopnosti organizácie.

Začať (najskôr) v malom

Výhoda experimentálneho prístupu spočíva v tom, že môžete byť inovatívni a opatrní zároveň. Nové prístupu je možné skúšať v obmedzenom rozsahu. Ak sa inovácia ukáže ako úspešná, môže byť nasadená plošne. Môžete tak verejnú politiku odskúšať, systematicky preskúmať jej dopady, prispôbiť ju a následne implementovať vo veľkom.

Výhoda obmedzených experimentov spočíva v nižších nákladoch na rozpočet, ale i nižšie reputačné riziko a politické náklady v prípade, ak experiment zlyhá. Experimentálne vládnutie by sa malo uskutočňovať na miestnej a regionálnej úrovni, nielen na vnútroštátnej úrovni.

6.2.2 Metódy dátovej vedy

Vzhľadom na trend neustále rastúceho objemu historických údajov, ktoré sú k dispozícii na analýzu, často nestačia len tradičné prístupy biznis inteligencie. Nastupuje dátová veda, vďaka ktorej je možné nájsť vzorce a poznatky v mori dát. Dátová veda poskytuje nové metodologické a technologické postupy k analýze historických údajov kombinovaním prístupov z rôznych vedných odborov ako matematika, štatistika, počítačová veda a v neposlednom rade aj z odboru, z ktorého sú samotné dáta na analýzu zozbierané.

Obrázok 2: Prienik zručností pre kvalitnú dátovú vedu



Dátová veda = Vecná expertíza + Hackerské zručnosti + Znalosť matematiky a štatistiky:

- Vecná expertíza – ide o schopnosť pýtať sa správne otázky a vedieť dobre naformulovať problém, ktorý je potrebné vyriešiť pomocou dát. Tiež je dôležitá vecná expertíza na kritické zhodnotenie kvality dát a na to, či závery z dátových analýz sú správne.

-
- Hackerské zručnosti – sú to zručnosti v oblasti extrakcie a dolovania dát, ich čistenia, formátovania, vizualizácie a analýzy, písania kódu pre strojové a hĺbkové učenie a využívania IT nástrojov.
 - Znalosť matematiky a štatistiky – predstavuje vedomosti o tom, ako správne analyzovať dáta a využívať štatistické prístupy na získavanie znalostí z dát.

Dátová veda sa v posledných rokoch posunula vpred hlavne vďaka exponenciálnemu rastu dostupných dát a výpočtovej kapacity. Dátová veda pracuje s:

- Dátovým setom – nazývaným aj štatistický súbor, ktorý predstavuje skupinu prvkov, ktoré sú predmetom skúmania dátovej vedy a ktoré majú spoločnú vlastnosť,
- Premennými, ktoré môžu byť:
 - Vstupnými premennými (premenná na x-ovej osi alebo nezávislá premenná, ktorú možno meniť a nezávisí od ostatných premenných),
 - Výstupnými premennými (premenná na y-ovej osi alebo závislá premenná, u ktorej sa očakáva, že sa bude meniť v dôsledku zmien nezávislej premennej),
- Dátami, ktoré sú za premennými a môžu byť:
 - kvantitatívne, teda poskytujú informáciu o veličine, ktorá môže byť počítaná alebo meraná (vek, výška, váha, počet prípadov a podobne),
 - kvalitatívne, ide o popisné veličiny, ktorú môžu byť pozorované, avšak nie odmerané (farba, krvná skupina, adresa, informácia o nákaze a podobne),
- Hypotézou, teda s kvalifikovaným odhadom toho, aký je vzťah medzi premenným a výsledkom experimentu.

Súčasťou dátovej vedy je aj schopnosť vysporiadať sa s dátami, ktoré sú chaotické a neštruktúrované, a preto treba neustále rozvíjať zručnosti, podporovať trpezlivosť a vyhradiť dostatok času na čistenie dát a ich štruktúrovanie a normalizovanie, aby sa dali jednoducho používať cez dátové trhoviská v dátovom sklade. Ďalším aspektom sú chýbajúce dáta pre niektoré premenné a inštancie v zdrojových systémoch, a preto dátová veda definuje niekoľko techník, ako sa vysporiadať aj s týmto problémom.

Najdôležitejšie pravidlo pre dátových vedcov musí byť toto nasledovné: vždy je potrebné si klásť otázky predtým, než sa začnú hľadať dáta. Tak, ako vedecké metódy začínajú s hypotézou, dátová veda začína s otázkami, ktoré sú kľúčové pre vyriešenie daného problému. Podobne, ako vedecká metóda, tak aj dátová veda má svoj proces na to, aby premenila dáta na poznatky. Proces dátovej vedy možno v krátkosti zhrnúť nasledovne:

1. Generovanie otázok, ktoré pomáhajú dobre porozumieť problému.
2. Potom, čo sú otázky správne naformulované, je čas zozbierať dáta z relevantných zdrojov využitím techník dátovej vedy.
3. Keď sú dáta zozbierané, treba ich prečistiť a transformovať do vhodného formátu, čím sa pripraví na nasledujúci krok.
4. Následne sú dáta podrobené analýze a prieskumu aplikovaním štatistických metód s cieľom objaviť ukryté vzorce a vzťahy.
5. V ďalšom kroku sa vytvárajú modely strojového učenia pre predikciu a inferenciu.

6. Následne sa dosiahnuté výsledky podrobujú konštruktívnej kritike a upravia sa akékoľvek nesprávne predpoklady,
7. Na záver sa výstupy procesu dátovej vedy komunikujú ostatným a využívajú v procesoch rozhodovania.

Čo sa týka zberu dát v kroku 2, v ideálnom prípade to znamená len vyextrahovanie podmnožiny historických údajov z dátového skladu (z predpripraveného dátového trhoviska). Ak sa v dátovom sklade dáta nenachádzajú, bude ich potrebné najskôr replikovať z externých zdrojov do dátového skladu a vytvoriť pre ne dátové trhovisko. Môže sa však stať, že dáta na zodpovedanie danej otázky nebudú k dispozícii ani v externých systémoch, alebo nebudú v požadovanej kvalite, a bude sa musieť navrhnúť a realizovať najprv ich zber.

Obrázok 3: Postup dátovej vedy



Postup dátovej vedy znázornený na obrázku vyššie vychádza z experimentálneho dizajnu – teda z prístupu, pri ktorom sa navrhne a zrealizuje experiment za účelom získania a zanalyzovania správnych dát na efektívne zodpovedanie danej otázky alebo vyriešenie daného problému. Experimentálny dizajn má spravidla takýto priebeh:

1. Správne naformulovanie otázky alebo problému: Čo sa snažíme odmerať alebo zanalyzovať pomocou dát a ako?
2. Návrh experimentu: Ide o najnáročnejšiu fázu, v ktorej treba nájsť odpovede na tieto otázky: Aký je ten najlepší spôsob, ako odpovedať na danú otázku alebo vyriešiť daný problém? Aké sú tie správne dáta, ktoré nám k tomu dopomôžu? Ako možno tieto dáta zozbierať? Aké nástroje a knižnice sa budú dať použiť na analýzu?
3. Identifikovanie problémov a možných zdrojov chýb: Aké stratégie a metódy zvoliť, aby sa dalo predísť prípadným pochybeniam v návrhu experimentu alebo pri zbere dát?
4. Zber samotných dát, ktorý môže nastať až po získaní odpovedí na otázky vyššie. Samozrejme, historické údaje nemuseli byť zbierané v kontexte takého experimentálneho dizajnu, preto ich ale treba s ohľadom na tento postup zhodnotiť. Žiaľ, pokročilejšia analýza historických údajov veľmi často začína práve zmenami v oblasti zberu dát, čo sú často náročnejšie investície ako samotná analýza historických údajov a využívanie výsledkov analýz pri rozhodovaní.

Treba mať teda na pamäti, že: nesprávne dáta vedú k nesprávnej analýze a tá vedie k zlým rozhodnutiam.

Dátová veda sa delí na dva tábory:

- Generovanie hypotéz – hĺbkovou analýzou dát a kombinovaním doménovej znalosti možno generovať hypotézy, ktoré vysvetľujú, prečo sa premenné a dáta za nimi správajú tak, ako sa správajú.
- Potvrdzovanie hypotéz – s využitím presných matematických modelov možno generovať falzifikovateľné tvrdenia, ktoré podporujú pôvodné hypotézy.

Za dátovou vedou sú metódy dátovej analýzy, ktoré možno rozdeliť do 6 skupín, zoradených podľa narastajúceho stupňa náročnosti:

- Deskriptívna analýza,

-
- Prieskumná analýza,
 - Inferečná analýza,
 - Prediktívna analýza,
 - Kauzálna analýza,
 - Mechanistická analýza.

6.3 Algoritmy

Umelá inteligencia, dátový model, analytický model a algoritmus sú vzájomne prepojené pojmy v oblasti spracovania dát a strojového učenia:

- Umelá inteligencia sa zaoberá vytváraním inteligentných systémov, ktoré sú schopné vykonávať úlohy, ktoré zvyčajne vyžadujú ľudskú inteligenciu. U zahŕňa mnoho techník a metód, ktoré sa snažia napodobniť ľudské myslenie a správanie.
- Dátový model je abstraktná reprezentácia dát a ich vzťahov. Služi na popis a organizáciu dát, ktoré sa používajú v rôznych systémoch a aplikáciách. Dátový model definuje štruktúru a formát dát, ktoré sa používajú v analytických modeloch.
- Analytický model je matematický alebo štatistický model, ktorý sa používa na analýzu dát a odhalenie vzorcov, trendov a vzťahov v dátach. Analytický model môže byť použitý na predikciu budúcich udalostí, klasifikáciu dát do rôznych skupín alebo na získanie záverov z dostupných dát.
- Algoritmus je postup alebo procedúra, ktorá sa používa na riešenie konkrétneho problému alebo vykonávanie určitej úlohy. V kontexte umelej inteligencie a dátovej analýzy sa algoritmy často používajú na tréning analytických modelov, vyhľadávanie vzorcov v dátach a vykonávanie výpočtov potrebných na rozhodovanie.

Algoritmy, sú tak implementované v analytických a dátových modeloch. Budú generovať predikcie o budúcich stavoch alebo akciách pre verejnú inštitúciu a vstupovať do rozhodovacích procesov inštitúcie. Je potrebné poznať reálne možnosti, ktoré algoritmy umožňujú a hľadať vhodné modely pre riešenie problémov v agende. V nasledujúcej časti sú predstavené základné dostupné riešenia ako pomôcka pre výber algoritmov.

6.3.1 Prehľad metód a aplikácií umelej inteligencie

Algoritmy umelej inteligencie umožňuje efektívnejšie, účinnejšie a optimalizované rozhodovanie. Niektoré získané poznatky budú stále poskytované úradníkovi (ľudskému rozhodovateľovi), napríklad odporúčanie kontrolórovi, v ktorom subjekte a kedy vykonať kontrolu. Iné rozhodnutia a akcie môžu priamo vykonávané strojmi napríklad odporúčanie na digitálne služby, ktoré môže občan využiť pri návšteve stránky Slovensko.sk. Vzhľadom na nedôveryhodnosť ľudských rozhodovateľov a ťažkosti pri interpretácii strojového učenia je pravdepodobné, že čoraz viac rozhodnutí bude v priebehu času vykonávaných strojmi. Niektoré z týchto rozhodnutí budú typické rozhodnutia riaditeľov, napríklad pridelenie osoby k určitému projektu. V priebehu času by to mohlo zmenšiť úlohu stredného managementu v organizáciách verejnej správy.

V nasledujúcom texte je možné nájsť prehľad aplikácií umelej inteligencie a vysvetlené sú základné používané metódy. Podľa typu problémov navrhujeme použitie algoritmov umelej inteligencie v jednotlivých úlohách regulačnej kapacity inštitúcie verejnej správy.

Aplikácie umelej inteligencie

Aplikáciu dátovej vedy a umelej inteligencie nie je možné chápať ako jednotné alebo unifikované riešenia. V skutočnosti ide o veľké množstvo rôznych aplikácií a prístupov. Najskôr predstavíme základné technológie, ktoré používajú dátové algoritmy, aby sme mali prehľad o možných aplikáciách dátových riešení.

Tabuľka 10: Prehľad aplikácií umelej inteligencie

Aplikácia	Popis
Inteligentný agenti	Agenti, ktorí interagujú s ľuďmi priamo, prostredníctvom prirodzeného jazyka. Môžu byť využití na doplnenie ľudí v oblastiach, ako je obsluha klientov (pri vybavovaní služieb) ale i v rámci školení, odpovedaní na FAQ, v rámci podpory ľudských zdrojov v organizáciách a podobne.
Kolaboratívni roboti	Roboti, ktorí operujú pri pomalých rýchlostiach a sú vybavení senzormi, aby dokázali kooperovať s ľuďmi. V rámci verejnej správy majú uplatnenie najmä v colnej správe.
Biometrické Identifikácia, rozpoznávanie tváre	Nový a jednoduchý spôsob identifikácie a autentifikácie, ktorý je možné využiť napríklad v bezpečnostných aplikáciách (identifikácia zločincov na kamerových záznamoch, autorizácia prístupu do objektov).
Inteligentná automatizácia	Možnosť nahradiť vybrané úlohy priamo strojom. Napríklad automatický výpočet, priznanie a výplatu prídavkov na deti.
Odporúčacie systémy	Na základe identifikovaných vzorov dokáže odporúčací systém navrhovať ďalšie kroky: môže ísť o navrhované rozhodnutia (v správnych a súdnych konaniach), odporúčané vyšetrenia v rámci životnej cesty pacienta a podobne. Odporúčacie systémy môžu byť tiež použité pre komunikáciu s občanmi a podnikateľmi, napríklad pri navrhovaní ďalších krokov v životnej situácii (odporúčame vám rezervovať si miesto v jasliach).
Inteligentné služby	Inteligentné služby majú adaptabilitu zakódovanú priamo do svojho návrhu a dokážu sa prispôbovať situáciám a potrebám používateľov. Predstavte si napríklad inteligentné kariérne poradenstvo v nezamestnanosti alebo inteligentnú podporu vášho dieťaťa, aby dokázalo v maximálnej miere využiť svoj potenciál (kombinácia vzdelávacích a sociálnych služieb), ako i inteligentné zdravotné liečebné programy.
Personalizácia	Na základe analýzy trendov a vzorov správania (ako i deklarovaných preferencií) dokáže služba ponúknuť vhodné riešenie pre životnú situáciu občana (adresná dávka v hmotnej núdzi, investičný stimul do výskumu a vývoja).
Rozpoznávanie textu a hlasu	Na základe analýzy a vyhodnotení textu respektíve hlasu je možné ponúknuť novú úroveň v interakcii medzi strojom a človekom.
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 (napríklad v colných procesoch).

Metódy umelej inteligencie

V oblasti strojového učenia a dátových modelov existuje niekoľko typov algoritmov a modelov, ktoré sa používajú na riešenie reálnych problémov vo verejnej správe a základné metódy sú popísané v tabuľke nižšie.

Tabuľka 11: Metódy umelej inteligencie

Metóda	Popis
Optimalizácia	Matematický prístup pri hľadaní optimálneho riešenia podľa definovanej kritériálnej funkcie.
Reprezentácia znalostí	Podoblasť umelej inteligencie, ktorá sa zaoberá reprezentáciou znalostí a informácií o svete spôsobom, ktorý môže byť použitý počítačom na vykonanie komplexnej úlohy, napríklad pri odporúčaní rozhodnutia.
Expertný systém	Systém, ktorý využíva špecifické znalosti (legislatíva, medicína) v kombinácii z nastavenými pravidlami spôsob aplikácie znalostí. Takéto riešenie je založené na prístupe, že znalosti sú na základe poznatkov expertov prenesené a "zakódované" do systému.
Počítačové videnie	Prístup v strojovom učení orientovaný na identifikáciu, kategorizáciu a skúmanie obsahu v obrázkoch a videách. Tento prístup je možné vo verejnej správe využívať napríklad pri sledovaní dopravných tokoch, pri ochrane prírodu alebo bezpečnostných aplikáciách.
Spracovanie signálu	Prístup v strojovom učení orientovaný na spracovanie signálu, ako sú zvukové záznamy.
Spracovanie prirodzeného jazyka	Prístup v strojovom učení orientovaný na porozumenie textu alebo hovorov. Spracovanie prirodzeného jazyka je možné využiť napríklad pri automatickom vylepšovaní textu, pri spracovaní záznamov z pojednávani, pri prekladoch.
Supervised Learning (Nadzorované učenie)	Tento typ strojového učenia je založený na tréovaní modelu na základe vstupných dát, ktoré obsahujú vstupné premenné a príslušné výstupné hodnoty. Model sa potom používa na predikciu výstupu pre nové, neznáme vstupné dáta. Tento typ algoritmov sa často využíva na klasifikáciu, regresiu a predikciu v rôznych oblastiach verejnej správy, ako napríklad predikcia volebných výsledkov, detekcia podvodov alebo predpovedanie dopytu po verejných službách.
Unsupervised Learning (Nenadzorované učenie)	Tento typ strojového učenia sa používa na objavovanie vzorov alebo štruktúr v dátach bez prítomnosti označených výstupov. Algoritmy nenadzorovaného učenia sú často používané pri zhlukovaní dát, kde sa snažia identifikovať skupiny podobných inštancií, alebo pri odporúčaní obsahu, kde sa snažia identifikovať podobné položky pre personalizované odporúčania.
Reinforcement Learning (Učenie založené na posilňovaní)	Tento typ strojového učenia je založený na interakcii agenta s prostredím prostredníctvom vykonávania akcií a získavania odmeny za správne rozhodnutia. Agent sa učí optimalizovať svoje rozhodnutia prostredníctvom skúmania rôznych stratégií a získavania spätnej väzby zo svojho prostredia. Reinforcement Learning sa používa v rôznych oblastiach verejnej správy, napríklad pri riadení dopravy, optimalizácii energetických systémov alebo pri vytváraní politik na riadenie zdrojov.
Deep Learning (Hlboké učenie)	Deep Learning je pododborom strojového učenia, ktorý využíva neurónové siete s viacerými vrstvami na učenie komplexných vzorov a reprezentácií z dát. Tieto hlboké neurónové siete sú schopné automaticky extrahovať hierarchické znaky a reprezentácie z dát.

Základné riešenia pre zlepšenie regulácie

Pre účely ďalej skúmame štyri základné riešenia, ktoré môžu priniesť algoritmy a analytické modely do optimalizácie procesov vo verejnej správe: prediktívne modely, klasifikačné modely, roboticko-procesná automatizácia a manipulácia s informáciami. Pre každé riešenie popíšeme základné algoritmy a spôsob aplikácie v rámci regulačnej kapacity inštitúcie verejnej správy.

Tabuľka 12: Prehľad základných riešení pre zlepšenie regulácie

Riešenie	Popis
Prediktívny model	Systém, ktorý dokáže hľadať súvislosti medzi historickými datasetmi a výsledkami. Na základe týchto súvislostí je možné vytvoriť model, ktorý bude predikovať budúce výsledky podľa vstupných dát. Prediktívne systémy môžu posúdiť riziko podvodu alebo chýb pri verejnom obstarávaní, správanie sa odsúdeného po uplynutí trestu a podobne. Nasadením prediktívnych systémov môžeme výrazne zlepšiť schopnosť inštitúcií verejnej správy riešiť problémy.
Klasifikačný model	Klasifikačný systém je technika strojového učenia, ktorá sa používa na priradenie vstupných dát do jednej z preddefinovaných tried alebo kategórií. Model sa trénuje na základe označených dát, kde sa vstupné premenné (príznaky) mapujú na správne triedy. Následne sa model používa na klasifikáciu nových, neznámych vstupov na základe naučených vzorov.
Roboticko procesná automatizácia (RPA)	Technológia, ktorá umožňuje automatizovať opakujúce sa, štruktúrované a informačne náročné úlohy pomocou softvérových robotov. Tieto roboty sú schopné simulovať ľudské interakcie s rôznymi digitálnymi systémami a aplikáciami, čím vykonávajú rutinné úlohy efektívne a presne.
Manipulácia informáciami	z Reprezentácia znalostí: Podoblasť umelej inteligencie, ktorá sa zaoberá reprezentáciou znalostí a informácií o svete spôsobom, ktorý môže byť použitý počítačom na vykonanie komplexnej úlohy, napríklad pri odporúčaní rozhodnutia.

6.3.2 Použitie predikčných modelov

Predikčný model je matematický a štatistický nástroj, ktorý sa používa na predpovedanie budúcich udalostí alebo hodnôt na základe dostupných dát a vzorcov. Tieto modely analyzujú vzťahy medzi vstupnými premennými (známymi ako funkcie alebo príznaky) a výstupnými premennými (známymi ako cieľové premenné) a následne generujú predikcie pre nové, neznáme vstupné dáta.

Verejná správa môže využívať predikčné modely na rôzne účely. Tu je niekoľko príkladov, ako môžu byť predikčné modely použité vo verejnej správe:

- Predpovedanie dopytu a zdrojov: Predikčné modely môžu pomôcť predpovedať dopyt po verejných službách, ako je zdravotná starostlivosť, doprava, voda a energia. Na základe týchto predpovedí môžu byť lepšie naplánované a riadené zdroje a prostriedky, aby sa zabezpečilo ich efektívne využitie.
- Prevencia kriminality a bezpečnosti: Predikčné modely môžu byť použité na analýzu kriminálnych vzorov a predikciu miest a časov, kde by mohlo dôjsť k zvýšeniu kriminality. Tieto modely môžu byť využité na zlepšenie rozmiestnenia policajných jednotiek a iných bezpečnostných opatrení s cieľom znížiť kriminalitu a zvýšiť bezpečnosť občanov.
- Predikcia rizika a monitorovanie: Predikčné modely môžu pomôcť predpovedať riziká a ohrozenia v rôznych odvetviach alebo oblastiach regulácie. Na základe týchto predikcií môže byť možné identifikovať potenciálne problémy alebo nedostatky v existujúcich reguláciách a prijať preventívne opatrenia.

- Rýchle identifikovanie porušení a podvodov: Predikčné modely môžu byť použité na analýzu dát a identifikáciu nezrovnalostí, porušení predpisov alebo potenciálnych prípadov podvodov. Tieto modely môžu automaticky vyhodnocovať veľké množstvo údajov a identifikovať vzory, ktoré by mohli naznačovať nezákonné činnosti.
- Plánovanie a prognózovanie účinkov regulácie: Predikčné modely môžu byť použité na predpovedanie účinkov nových regulácií alebo politík. Môžu pomôcť predvídať ekonomické, sociálne a environmentálne dôsledky určitých regulácií a umožniť lepšie plánovanie a prispôsobovanie sa.
- Personalizovaná regulácia: Predikčné modely môžu byť použité na personalizáciu regulácie podľa konkrétnych potrieb alebo charakteristík subjektov, ktoré sú regulované. Týmto spôsobom môže byť regulácia efektívnejšia a spravodlivejšia, pretože sa berú do úvahy individuálne faktory a podmienky.

Existuje niekoľko typov predikčných algoritmov, ktoré sa používajú na predpovedanie budúcich udalostí alebo hodnôt na základe dostupných dát. Medzi najpoužívanejšie typy patria:

- Lineárna regresia: Lineárna regresia je jedným z najzákladnejších predikčných algoritmov. Modeluje vzťah medzi vstupnými premennými a výstupnými premennými pomocou lineárnej funkcie.
- Rozhodovacie stromy: Rozhodovacie stromy sú stromové štruktúry, kde každý vrchol predstavuje rozhodnutie na základe určitého atribútu. Tieto stromy sa používajú na klasifikáciu a predikciu hodnôt na základe rôznych atribútov a pravidiel.
- Náhodné lesy: Náhodné lesy sú súborom rozhodovacích stromov, ktoré sa trénujú na rôznych vzorkách dát a náhodne vyberajú atribúty pre každý strom. Tento algoritmus je robustný a efektívny pri predikcii a klasifikácii.
- Podporné vektory (Support Vector Machines - SVM): SVM je algoritmus, ktorý sa používa na klasifikáciu a regresiu. Tento algoritmus hľadá hyperrovinu alebo viacdimenzionálnu plochu, ktorá najlepšie rozdeľuje dáta rôznych tried.
- Neurónové siete: Neurónové siete sú založené na fungovaní ľudského mozgu a modelujú viacvrstvé siete neurónov. Tieto siete sa používajú na riešenie širokého spektra predikčných problémov.
- Gradientný boosting: Gradientný boosting je technika, ktorá kombinuje viacero slabých predikčných modelov a postupne ich zlepšuje. Tento algoritmus sa používa na predpovedanie a klasifikáciu a je známy pre svoju schopnosť dosahovať vysokú presnosť.

Tabuľka 13 Typy analytických modelov pre predikciu

Analytický model	Na čo slúži	Príklad využitia
Regresia (odhad hodnoty)	Dokáže odhadnúť alebo predpovedať pre každú entitu v dátovom sete numerickú hodnotu nejakej premennej danej entity. Pomáha predpovedať, do akej miery bude pôsobiť daný fenomén, napríklad chemická látka v životnom prostredí alebo vírus v populácii.	Napríklad pre daného jednotlivca možno predpovedať zmenu dávky žiarenia v danej časti tela. Alebo je možné vykresliť ako rozptylový graf, kde čas v dňoch je nezávislou vstupnou premennou na osi X a počet nových prípadov chrípky je závislá premenná na osi Y. Pre tieto dáta možno vypočítať vzťah ako pozitívnu alebo negatívnu koreláciu, znázornenú lineárnou krivkou. Pomocou lineárnej regresie možno vytvoriť jednoduchý model na

Analytický model	Na čo slúži	Príklad využitia
		predpovedanie počtu nových prípadov chrípky.
Profilovanie (popisovanie správania)	Model charakterizuje typické správanie entity, skupiny alebo populácie.	Príkladom využitia bude napríklad hľadanie bežného vzorca pohybu u skupiny obyvateľov, ktorý sa dá využiť počas predpovedania šírenia pandémie. Profilovanie dokáže zdefinovať normy správania, na základe ktorých možno detegovať anomálie ako napríklad podvod zo strany potravinárskych prevádzok alebo výrobcov kozmetických výrobkov.
Predpoveď prepojenia	Ide o snahu predpovedať prepojenie medzi dátovými prvkami, väčšinou upozornením, že existuje medzi nimi vzťah, pričom sa odhadne aj sila tohto vzťahu.	Predpovedanie prepojenia je typické pre systémy sociálnych sietí, v ktorých možno analyzovať mieru prepojenia medzi jednotlivými účastníkmi, čo môže byť užitočné napríklad pri sledovaní kontaktov pozitívnych osôb v čase pandémie.
Korelácia pomocou experimentálneho dizajnu	Základom tejto metódy je stanoviť si hypotézu o súvislosti medzi závislou a nezávislou premennou. Tu si však treba dať pozor na takzvaný zavádzajúci faktor – teda ďalšiu premennú, ktorá môže ovplyvňovať vzťah medzi závislými a nezávislými premennými. S ohľadom na tento faktor treba vhodne navrhnuť experiment a zber dát, či už z historických zdrojov alebo v novom experimente.	Príkladom je hypotéza, že vyšší počet kontrol prevádzok v danej oblasti znižuje počet zistení. Pre túto otázku je počet vykonaných kontrol prevádzok v danej lokalite nezávislou premennou a závislou je počet zistení. Zavádzajúcim faktorom však môžu byť premenné, ktoré ovplyvňujú na prvý pohľad logické správanie sa majiteľov alebo manažérov prevádzok ako výška pokuty za nedodržanie opatrení, náročnosť dodržiavania opatrení alebo frekvencia, s akou sa menia.
Kauzálne modelovanie	Tento model nám pomáha porozumieť, aké udalosti alebo aktivity ovplyvňujú daný fenomén. Techniky si vyžadujú buď značné investície do zberu dát, napríklad cez randomizované kontrolované experimenty, alebo využitie sofistikovaných metód pre vyvodenie kauzálnych záverov z pozorovaných dát. Obe techniky sa snažia modelovať rozdiel medzi dvoma situáciami, ktoré nemôžu nastať naraz.	Napríklad spozorujeme, že sa koncentrácia danej chemickej látky v danej skupine populácie znižuje. Kauzálne modelovanie môže napomôcť objasniť, čím je to spôsobené – či napríklad zabrala úprava regulácie alebo znečisťovatelia životného prostredia zmenili svoje správanie, alebo ľudia z nejakého dôvodu prestali byť s kontaminovanou súčasťou prostredia v kontakte.

6.3.3 Použitie klasifikačných modelov

Klasifikačný model je technika strojového učenia, ktorá sa používa na priradenie vstupných dát do jednej z preddefinovaných tried alebo kategórií. Model sa trénuje na základe označených dát, kde sa vstupné premenné (príznačky) mapujú na správne triedy. Následne sa model používa na klasifikáciu nových, neznámych vstupov na základe naučených vzorov.

Klasifikačné modely teda môžu byť nástrojom, ktorý pomáha verejnej správe pri identifikácii rizikových subjektov, hodnotení súladu s predpismi, profilovaní rizika a triedení dát a dokumentov. Tieto modely umožňujú presnejšie a efektívnejšie riadenie a reguláciu v rámci verejnej správy.

V rámci regulačnej kapacity verejnej správy môže byť klasifikačný model použitý nasledovne:

- Identifikácia rizikových subjektov: Klasifikačné modely môžu byť využité na identifikáciu subjektov alebo entít, ktoré predstavujú vysoké riziko alebo potenciálnu hrozbu pre verejný sektor. Tieto modely môžu analyzovať rôzne faktory a príznaky a klasifikovať subjekty do kategórií ako "vysoké riziko", "stredné riziko" alebo "nízke riziko", čo môže pomôcť pri priradení zdrojov a vykonávaní presnejších kontrol.
- Hodnotenie súladu a dodržiavania predpisov: Klasifikačné modely môžu byť použité na hodnotenie súladu subjektov s určitými predpismi, pravidlami alebo noriem. Na základe dostupných dát a klasifikačného modelu sa môže určiť, či subjekt dodržiava pravidlá alebo nie. Toto môže byť užitočné pri monitorovaní a overovaní dodržiavania predpisov v oblastiach ako ochrana životného prostredia, finančný sektor, zdravotníctvo a iné.
- Rizikové profilovanie a včasné varovanie: Klasifikačné modely môžu byť použité na vytvorenie rizikových profilov subjektov na základe ich vlastností, histórie alebo správania. Tieto modely môžu identifikovať subjekty s vysokým rizikom, ktoré vyžadujú bližšie monitorovanie alebo prípadné opatrenia. Včasné varovanie umožňuje verejnej správe rýchlejšie a účinnejšie reagovať na potenciálne problémy alebo nezrovnalosti.
- Klasifikácia dát a dokumentov: Klasifikačné modely môžu byť použité na klasifikáciu a triedenie dát a dokumentov v rámci regulačnej kapacity. Môžu pomôcť s automatickým priradením dokumentov do kategórií, ako sú žiadosti, sťažnosti, podania a iné, čo zjednodušuje ich spracovanie a riadenie.

Existuje niekoľko typov klasifikačných algoritmov, ktoré sa používajú na kategorizáciu vstupných dát do preddefinovaných tried. Medzi najpoužívanejšie typy patria:

- Naivný Bayes: Naivný Bayesovský klasifikátor je založený na Bayesovskej pravdepodobnosti a predpokladá nezávislosť medzi príznakmi. Používa sa najmä pri spracovaní textových dát a klasifikácii na základe prítomnosti rôznych slov alebo vzorov v texte.
- Rozhodovacie stromy: Rozhodovacie stromy sú stromové štruktúry, kde každý vrchol predstavuje rozhodnutie na základe určitého atribútu. Tieto stromy sa používajú na klasifikáciu a triedenie dát na základe rôznych atribútov a pravidiel.
- Náhodné lesy: Náhodné lesy sú súborom rozhodovacích stromov, ktoré sa trénujú na rôznych vzorkách dát a náhodne vyberajú atribúty pre každý strom. Tento algoritmus je schopný dosiahnuť vysokú presnosť a je odolný voči pretrénovaniu.
- Podporné vektory (Support Vector Machines - SVM): SVM je algoritmus, ktorý sa používa na klasifikáciu a rozdeľovanie dát do rôznych tried. Hľadá hyperrovinu alebo viacdimenzionálnu plochu, ktorá najlepšie rozdeľuje dáta rôznych tried.
- K-NN (k-najbližších susedov): K-NN algoritmus klasifikuje vstupné dáta na základe ich podobnosti s najbližšími susedmi v tréningovej množine. Trieda vstupného vzoru je určená na základe triedy jeho k najbližších susedov.
- Neurónové siete: Neurónové siete sú zložené z viacerých vrstiev neurónov a používajú sa na klasifikáciu a rozpoznávanie vzorov. Tieto siete majú schopnosť naučiť sa zložité vzťahy medzi vstupnými dátami a ich príslušnými triedami.
- Gradientný boosting: Gradientný boosting je technika, ktorá kombinuje viacero slabých klasifikátorov a postupne ich zlepšuje. Tento algoritmus sa používa na klasifikáciu a je známy pre svoju schopnosť dosahovať.

Tabuľka 14: Typy analytických modelov pre klasifikáciu

Analytický model	Na čo slúži	Príklad využitia
Klasifikácia	Priradí danú entitu z dátového setu triede z (malej) skupiny tried. Alternatívne určí pravdepodobnosť, že daná entita patrí do priradenej triedy.	Na základe výsledkov meraní u pacienta ho priradíme do vopred definovanej rizikovej skupiny pre dané ochorenie. Alebo napríklad možno určiť, s akou pravdepodobnosťou bol človek vystavený danej chemickej látke či nadmernému žiareniu.
Hľadanie podobnosti	Pomocou tohto modelu možno hľadať podobné entity na základe dostupných dát o nich.	Napríklad sa dajú hľadať podobné prevádzky stravovacích služieb, či už na základe ponuky jedál alebo ich minulých zistení počas výkonu kontrol.
Klastrovanie	Ide o snahu združiť entity do skupiny na základe podobných črt v dátach, avšak bez akejkoľvek inej konkrétnej motivácie.	Tento model je často vstupom do modelu rozhodovania, kedy sa zaoberáme otázkami ako: „Ako majú byť organizované tímy pre štátny zdravotný dozor? Na skúmanie akých typov chemických látok v akých prostrediach sa máme zamerať?“
Zoskupovanie na základe spoločného výskytu	Tento prístup hľadá asociácie medzi entitami na základe transakcií, do ktorých sú entity zapojené, a na základe toho vytvára skupiny entít. Na rozdiel od klastrovania, ktoré zoskupuje entity podľa črt v dátach o nich. Výsledkom zoskupenia je popis entít, ktoré sa vyskytujú spolu. Tento popis zväčša obsahuje štatistiku frekvencie spoločného výskytu a odhad toho, ako je táto informácia prekvapivá.	Príkladom využitia bude napríklad snaha odpovedať na otázku, aké potraviny sa často kupujú spolu, a tým pádom bude možné aktualizovať spotrebný kôš potravín.
Redukovanie dát	Je to metóda na nahradenie veľkého setu dát menším, ktorý ale obsahuje zásadnú časť informácií o veľkom sete. S menším setom sa potom pracuje jednoduchšie, aj v modeloch rozhodovania. Tiež menšie sety môžu prispieť k lepšiemu odhaleniu kľúčovej znalosti v dátach.	Napríklad obrovský dataset o jednotlivých nákupoch potravín v obchodoch môže byť zredukovaný na to, čo ľudia preferujú pri nákupe.

6.3.4 Realizácia štrukturovaných digitalizovaných úloh

Relatívne nová, ale už zrelá technológia nazývaná robotická procesná automatizácia (RPA) využíva kombináciu schopností na vykonávanie štruktúrovaných digitálnych úloh, ktoré pracujú s informáciami a obsahom. RPA sa musí najskôr naučiť, aké akcie vykonávať v určitých situáciách, ale dokáže jednat autonómne a plniť užitočné funkcie. Vďaka svojej jednoduchosti a nízkym nákladom dosahujú projekty RPA jedny z najvyšších návratností investícií zo všetkých technológií súvisiacich s umelou inteligenciou.

Implementácia RPA (ktorá často zahŕňa vytvorenie vizuálnych diagramov procesov a niektorých základných pravidiel rozhodovania) sa zvyčajne dá vykonať aj netechnickými zamestnancami.

Robotická procesná automatizácia (RPA) je technológia, ktorá umožňuje automatizovať opakujúce sa a štruktúrované úlohy v digitálnom prostredí. RPA využíva softvérových robotov, ktorí simulujú ľudské interakcie s rôznymi softvérovými systémami a aplikáciami. Títo roboti dokážu vykonávať opakujúce sa úlohy s vyššou presnosťou, rýchlosťou a efektivitou ako ľudskí operátori. Čo zahŕňa štruktúrovanú digitálnu úlohu? Je to opakujúca sa činnosť, ktorá môže byť vopred špecifikovaná s určitou presnosťou, zahŕňa rozhodnutia založené na pravidlách a vyžaduje prístup k informáciám a vkladanie informácií z jedného alebo viacerých informačných systémov. RPA systém interaguje v rámci širšieho procesu tak, ako by to robil ľudský používateľ. Procesy alebo úlohy, ktoré by neboli vhodné pre RPA, by zahŕňali tie, ktoré vyžadujú nezávislé posúdenie, tie, pre ktoré by nebolo možné predvídať všetky prípadné situácie vopred, a tie, ktoré zahŕňajú nepredvídateľné interakcie s zákazníkmi alebo zamestnancami.

V rámci regulačnej kapacity verejnej správy môže byť RPA využitá na automatizáciu a zlepšenie procesov, ktoré vyžadujú spracovanie a správu veľkého množstva štruktúrovaných informácií. Niektoré možné aplikácie RPA v tejto oblasti zahŕňajú:

- Správa dokumentov: RPA môže byť použitá na automatické triedenie, klasifikáciu a spracovanie dokumentov, čo znižuje manuálnu prácu a zvyšuje efektivitu spracovania.
- Kontrola dodržiavania predpisov: RPA môže byť využitá na overovanie dodržiavania predpisov a noriem. Roboti môžu automatizovať proces kontroly a vyhľadávať potenciálne nesprávne správanie alebo nezrovnalosti v dátach.
- Monitorovanie a audity: RPA môže byť využitá na pravidelné monitorovanie a vykonávanie auditov v rôznych oblastiach verejnej správy. Roboti môžu automaticky sledovať a vyhodnocovať dáta, identifikovať odchýlky a generovať správy o výsledkoch.
- Spracovanie žiadostí a formulárov: RPA môže byť použitá na automatizáciu spracovania žiadostí a formulárov od občanov. Roboti môžu extrahovať relevantné informácie, overiť ich a spracovať žiadosti efektívnejším spôsobom.

Robotická procesná automatizácia (RPA) sa zvyčajne nezakladá na tradičných algoritmoch strojového učenia. Je to skôr technológia založená na pravidlách a skriptoch, ktoré definujú postup, akcie a pravidlá pre vykonávanie úloh, používa expertné systémy. RPA roboti využívajú túto súbor pravidiel na automatizáciu opakujúcich sa úloh. Je dôležité si uvedomiť, že RPA nie je primárne založená na strojovom učení alebo algoritmoch hlbokého učenia. Je to skôr nástroj na automatizáciu procesov, ktorý sa opiera o pravidlá a preddefinované postupy.

Pri implementácii RPA sa často používajú nasledujúce komponenty a techniky:

- Procesný designer: Tento nástroj umožňuje definovať vizuálne procesy a tok úloh, ktoré majú byť automatizované. Procesný designer poskytuje prostredie na vytváranie, upravovanie a správu automatizačných pravidiel.
- Pravidlá rozhodovania: RPA umožňuje definovať pravidlá a podmienky, ktoré určujú, aké akcie majú byť vykonané v závislosti od stavu a údajov, s ktorými robot pracuje. Pravidlá rozhodovania umožňujú automatizovaným robotom vykonávať logické rozhodnutia a správne reagovať na rôzne situácie.
- Optické rozpoznávanie znakov (OCR): OCR je technika, ktorá umožňuje RPA robotom čítať a spracovávať textové informácie zo skenovaných dokumentov, obrazov a iných zdrojov. Týmto spôsobom roboti dokážu extrahovať dáta a pracovať s nimi.
- Integrácia s existujúcimi systémami: RPA umožňuje integráciu s existujúcimi softvérovými systémami a aplikáciami, čo umožňuje robotom vykonávať úlohy, ktoré zahŕňajú interakciu so systémami tretích strán. Toto sa často dosahuje prostredníctvom použitia aplikačného rozhrania (API) alebo mechanizmov emulácie používateľa.

6.3.5 Manipulácia z informáciami

Existuje niekoľko metód manipulácie s informáciami, ktoré sa často využívajú na spracovanie a extrakciu údajov z rôznych zdrojov. Niektoré z týchto metód zahŕňajú:

- Optické rozpoznávanie znakov (OCR): Táto metóda umožňuje automatické rozpoznanie textu z obrázkových a skenovaných dokumentov. OCR technológia transformuje obrázok textu do editovateľného a vyhľadateľného formátu, čo umožňuje spracovanie a analyzovanie týchto údajov.
- Optické rozpoznávanie čiarových kódov (OCR): Táto metóda sa používa na rozpoznanie čiarových kódov, ako sú napríklad čiarové kódy na produktoch. OCR technológia dokáže identifikovať a dekódovať tieto čiarové kódy, čo umožňuje rýchle a presné získanie údajov o produkte.
- Textová analýza: Textová analýza je metóda spracovania textu, ktorá sa používa na identifikáciu, extrakciu a porozumenie informáciám obsiahnutým v texte. Táto metóda môže zahŕňať rozpoznávanie kľúčových slov, klasifikáciu textu, extrakciu entít a vytváranie súhrnných štatistík.
- Webový scraping: Webový scraping je proces získavania dát z webových stránok. Táto metóda umožňuje automatické zbieranie údajov zo stránok a ich transformáciu do štruktúrovaného formátu pre ďalšie spracovanie.
- NLP (Prírodný jazyk spracovanie): NLP je oblasť umelého inteligentného zameraná na porozumenie a spracovanie ľudského jazyka. Táto metóda sa používa na extrakciu významu z textov, identifikáciu vzorcov, rozpoznanie jazykových entít a rôzne iné úlohy spojené s jazykom.

Metódy pre manipuláciu s informáciami môžu byť veľmi užitočné v rámci regulačnej kapacity verejnej správy. Tu je niekoľko príkladov, ako by mohli byť tieto metódy aplikované:

- Monitorovanie a analýza právnych predpisov: Textová analýza a NLP môžu byť využité na spracovanie a porozumenie právnych predpisov a zákonov. Tieto metódy umožňujú identifikáciu kľúčových termínov, vzorcov a súvislostí v textoch, čo pomáha pri vyhľadávaní a porovnávaní relevantných informácií pre účely regulačného dodržiavania a analýzy.
- Hodnotenie rizika a dodržiavania predpisov: OCR a textová analýza môžu byť využité na analýzu a spracovanie dokumentov týkajúcich sa rizika a dodržiavania predpisov. Tieto metódy umožňujú extrakciu údajov zo súborov, napríklad finančných správ, správ o výkonoch organizácií alebo správ auditu, a následné vyhodnotenie a hodnotenie rizika a dodržiavania predpisov.
- Vyhľadávanie informácií a spracovanie podaní: OCR a NLP môžu byť využité na automatizované spracovanie a extrakciu údajov z rôznych dokumentov a podaní, ako sú žiadosti, žaloby alebo podania. Tieto metódy umožňujú rýchle vyhľadávanie a spracovanie informácií, čo znižuje manuálnu prácu a zlepšuje efektivitu regulačných procesov.
- Automatizovaná extrakcia rôznych typov informácií z dokumentov a komunikácií, čo zlepšuje efektivitu a presnosť spracovania dokumentov.
- Kombinovanie a zhromažďovanie podobných údajov z viacerých informačných systémov verejnej správy, čo umožňuje lepšiu analýzu a hodnotenie údajov v rámci regulačných procesov verejnej správy.

6.4 Nástroje

V dnešnej dobe je stále potrebný ľudský analytik alebo dátový vedec, ktorý spustí analýzu a pustí na konkrétnej sade dát príslušné algoritmy. S dobrými nástrojmi je však možné vytvoriť oveľa viac modelov na jedného dátového experta. Buď organizácia jednoducho vygeneruje oveľa viac modelov pomocou

týchto nástrojov, alebo sa v priebehu času bude potrebovať mierne znížiť počet analytických pracovníkov na vytvorenie rovnakého počtu modelov.

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.

6.4.1 Požiadavky na nástroje

Moderný, integrovaný dátový „stack“ pre analýzu

Takýto dátový „stack“ prepája dátové sklady, databázy, rozhrania pre získavanie a nahrávanie dát do databáz, nástroje pre sledovanie udalostí a biznis aplikácie. Tie najužitočnejšie „stacky“ umožňujú organizáciám užívať výhody rýchlo sa vyvíjajúcich technológií a pridávať najlepšie riešenia na trhu pre zber, transformáciu a analýzu dát bez toho, aby na to bolo nevyhnutné alokovať veľa času a financií. Budovanie takéhoto „stacku“ však v mnohých organizáciách narazí na bariéry vytvorené monolitickými, zastaranými aplikáciami a nemodernou IT architektúrou.

Moderný „stack“ pre analýzu údajov je vytvorený desiatkami nástrojov a aplikácií, ktoré pracujú v harmónii a pomáhajú tímom získať rýchlejšie znalosti obsiahnuté v historických údajoch. Každý komponent takejto IT architektúry musí byť **dostatočne flexibilný**, aby ho bolo možné odstrániť nezávisle od ostatných komponentov, a zároveň **dostatočne robustný**, aby dokázal prispieť k odpovediam na komplexné otázky. Týmto princípom možno dosiahnuť neustále zlepšovanie za dostupné náklady pri vysokej spokojnosti zamestnancov.

V raných štádiách nastavovania analýzy historických údajov možno takýto dátový „stack“ vybudovať vyskladaním open source a freemium nástrojov. Ako sa však začne analyzovať stále viac historických údajov v rôznych agendách, bude potrebné riešiť viac špecifické problémy a nuansy pri tvorbe podkladov pre rozhodovanie, ako aj spracovávať stále väčšie objemy dát v rôznorodých formátoch. Aby dátami riadené rozhodovanie ostalo konkurencieschopné a prinášalo hodnotu za peniaze, musia sa dátové tímy naučiť „stack“ modernizovať tak, aby sa nemíňali veľké objemy financií na náročné implementácie a aby sa nestávali obeťou takzvaného „vendor lock-inu“ (ide o situáciu, kedy dokáže IT architektúru upravovať a aktualizovať len jeden dodávateľ pôvodného riešenia). Vymeniť dodávateľa je bolestivé, pokiaľ jedno riešenie dominuje v dátovej infraštruktúre organizácie. Je spojené s migráciou obrovského množstva dát do nového systému, pričom nemožno dopredu zaručiť, že nové riešenie bude spĺňať všetky požiadavky. Preto je výmena dodávateľa spravidla označovaná ako riskantná. Monolitické riešenia často vyžadujú vysokú prvotnú investíciu z pohľadu času a financií, čo prispieva k mentalite utopených nákladov

a odmietaniu implementácie nového, vhodnejšieho riešenia. Preto modulárne riešenia zásadne uľahčujú rozhodovanie o aktualizácii nástrojov na prácu s dátami a výrazne zjednodušujú proces nákupu.

Monolitické riešenia tiež vyžadujú dôsledné procesy správy a dohľadu, ktoré štandardizujú dátové formáty, preverujú duplikované alebo nepresné údaje, manažujú dodržiavanie súladu s metodikami a požiadavkami na bezpečnosť a poskytujú rámec pre celkovú dátovú politiku organizácie. To predstavuje problém pri výmene dodávateľa, ak procesy správy a dohľadu sú implementované v rámci jedného nástroja business intelligence (BI), kvôli čomu by bolo potrebné s novým dodávateľom začať v bode nula.

V modernom, flexibilnom dátovom „stacku“ musia byť dáta prístupné celej škále rôznych nástrojov, preto musia byť centrálné spravované v databázach a výmena jedného nástroja za iný by nemala spôsobiť žiadne komplikácie. Dáta sú preto transformované podľa definovaného dátového modelu ešte predtým, ako sa nahrajú do akéhokoľvek konkrétneho nástroja na ich analýzu. Jedným zo spôsobov, ako to dosiahnuť, je používať nástroje ako dbt⁸, ktoré umožňujú transformáciu dát (teda len „T“ časť bežných ETL nástrojov), priamo v dátovom sklade alebo v databázach, a to len písaním skriptov. Cieľom je zachovať dátovú kvalitu bez ohľadu na to, aký nástroj bude zo „stacku“ odstránený.

6.4.2 Kolaboratívne vysoko výkonné nástroje pre analytikov a doménových expertov

Tieto nástroje umožňujú analytikom rýchlo si medzi sebou, ale aj medzi ostatnými členmi tímu, zdieľať získané poznatky a reporty. Samotné historické údaje a ich analýza nedokážu mať vplyv na zlepšenie chodu organizácie, pokiaľ sa nestanú integrovanou súčasťou odbornej práce a rozhodovacích procesov zamestnancov.

V priemere 60 až 73 percent všetkých dát organizácie sa nevyužíva na žiadnu analýzu. Nie je tomu inak ani v rezorte verejného zdravotníctva, v ktorom sa nevyužíva asi 60 percent údajov. Dôvodov tohto zlyhania vo využívaní dát je mnoho, ale najzásadnejším je ten, že tímy v rámci organizácie si ani nie sú isté, ktoré dáta sú relevantné pre riešenie danej otázky alebo problému. Ak postupy a nástroje podporujú spoluprácu medzi zamestnancami na rôznych oddeleniach, ktorí rozumejú kontextu dát a informáciám v nich obsiahnutých, začne sa využívať v praxi vyššie percento objemu dát. Odborníci na danú agendu potrebujú znalosti, aby mohli viesť svoje tímy, a spravidla potrebujú odpovede založené na hĺbkovej analýze daného problému. Ich každodenná skúsenosť s danou agendou im umožňuje pýtať sa veľmi cenné doplňujúce otázky, ktoré by sa ľudia bez takéhoto úzkeho kontaktu s problematikou nevedeli pýtať. Ak dátový analytický tím a odborníci na danú agendu spolu úzko spolupracujú, dokážu ďalej stavať na svojej expertíze a posúvať vpred znalosti o tom, ako čo najlepšie využiť analýzu historických údajov na zlepšenie danej agendy. V praxi to znamená, že odborníci na danú agendu bez technologických znalostí by mali byť schopní využívať kolaboratívne analytické nástroje tak, aby sa mohli:

- podieľať na procese dátového modelovania,
- využívať výhody prednastavených šablón na dátovú analýzu,
- robiť dopyty nad dátovým sklado,
- vytvárať dátové vizualizácie,

a to bez znalosti programovania alebo nutnosti spoliehať sa na dátový tím, aby im vytvorili prispôbené dashboards – panely alebo report. Dátoví analytici analyzujú dáta, interpretujú ich a robia na ich základe predikcie, avšak nie sú blízko situáciám v praxi, v ktorých dáta vznikajú. Spolupráca dátových analytikov a odborníkov na danú agendu na otázkach „prečo?“ vie predísť nákladným pochybeniam, kedy dátoví analytici bez tejto spolupráce môžu urobiť nesprávne predpoklady.

⁸ Zdroj: <https://www.getdbt.com/>, Dátum referencie: 28.04.2021

Získavanie nových poznatkov z dát je nákazlivé. Ak sa člen tímu dozvie niečo z dát, čo ovplyvní jeho pracovný úspech zásadným spôsobom, bude okamžite zvedavý, aké ďalšie poznatky sú v dátach, ktoré čakajú na to, aby boli objavené. Ak členovia tímu naprieč organizáciou alebo rezortom dostanú nástroje na to, aby participovali na analytickom procese, sú motivovaní zdieľať svoje vstupy a hľadať v dátach spoločne ďalšie poznatky. Zvedavosť podporuje kultúru inovácie a nových objavov, ktoré sú na nezaplatenie pre každú organizáciu.

6.4.3 Prehľad nástrojov a ich funkcionalít, ktoré sú dostupné v BI.

6.4.3.1 „Dashboardy“ a panely

Počas posledných 20 rokov sa veľmi obľúbeným nástrojom v organizáciách stali práve dashboardy – panely. Vďaka nim možno jednoducho začať zlepšovať prevádzku a aplikovať princípy dátami riadenej organizácie do praxe. V súkromnom sektore vedúci pracovníci už očakávajú interaktívne funkcionality na preskúmanie dát o chode organizácie ako súčasť štvrtročných správ. Dashboardy - panely však aj v mnohom zaostávajú:

- Trvá veľmi dlho ich vytvoriť, v závislosti od kompromisov spravených medzi tým, ako ich analytici zostavujú a ako sa v organizácii sledujú cieľové metriky.
- Využívajú sa aj tam, kde nie sú potrebné – v oblastiach, kde nepomáhajú lepšiemu rozhodovaniu, ako napríklad opakujúce sa dashboardy - panely, ktoré ale slúžili len jednorazovému rozhodnutiu v minulosti.
- Vyžadujú od svojich používateľov, aby ich neustále revidovali a venovali im neúnavnú pozornosť.
- Neponúkajú automaticky aj analýzu a návody – poskytujú len odpovede na otázku „čo?“, ale nie „prečo?“.

Dashboardy - panely dokážu ale stále byť veľmi užitočným nástrojom a softvérové riešenia, v ktorých sa vytvárajú, neustále napredujú a ponúkajú viac interaktívnych funkcionalít, pomocou ktorých možno do istej miery dáta analyzovať. V organizácii by malo existovať pár kľúčových dashboardov – panelov, ktoré využíva každý tím, aby mal vysokoúrovňový prehľad o výkonnosti a bol tak na jednej lodi ohľadom kľúčových cieľov rezortu verejného zdravotníctva. Dashboardy - panely sa tiež musia stať súčasťou iteratívneho procesu neustáleho zlepšovania – nemožno ich vytvoriť len raz a dúfať, že budú užitočné roky. Dashboardy - panely sú len tak užitočné, ako ľudia, ktorí stoja za ich vývojom a používaním, preto treba aj neustále investovať do zručností práce s dátami. Tiež príliš komplikované dashboardy - panely prispievajú k problému, že sa v nich ťažko nachádzajú nové postrehy a poznatky, obzvlášť ak obsahujú priveľa „widgetov“. Tejto téme sa ďalej venujeme v kapitole 3.6.

6.4.3.2 Nástroje na analýzu komplexných udalostí a procesov

Rok 2020 bol prelomový, kedy vďaka umelej inteligencii bolo možné pretaviť dashboardy - panely do výstražných systémov monitorovaných strojmi, ktoré dokážu hĺbkovo analyzovať historické údaje a upozorňovať na rôzne nové poznatky a prípadné anomálie. Vďaka tomu je možné analytické snaženie upriamiť na otázku „prečo?“ (napríklad: prečo sa neplní daný merateľný ukazovateľ?, prečo nastala chyba v danom procese?, prečo sa oneskorilo dané rozhodnutie?) namiesto otázky „čo?“ (napríklad: dnes sa vydalo 98 rozhodnutí alebo pribudlo vyše 1000 prípadov akútneho respiračného ochorenia len v týchto piatich okresoch). Najúspešnejšie svetové organizácie sa sústreďujú na niekoľko základných merateľných ukazovateľov a zvyšok času investujú do hĺbkovej analýzy hľadania odpovedí na otázky „prečo?“. Tieto organizácie investujú do nástrojov, ktoré podporujú túto hĺbkovú analýzu trendov a odľahlých hodnôt nájdených v dashboardoch –paneloch.

6.4.3.3 Nástroje prediktívnej analýzy

Ak organizácia zvládne všetky počiatočné štádiá manažmentu dát v dostatočnom rozsahu, kvalite a granularite, znamená to, že jej dátoví analytici vedia okamžite integrovať rôznorodé dáta z viacerých

zdrojov, rôzne odbory majú prístup k jednému zdroju pravdy ohľadom všetkých potrebných informácií a majú prístup k podrobným poznatkom cez dashboards - panely šité na mieru a cez ďalšie nástroje pre hlbšiu analýzu trendov a odľahlých hodnôt. V takejto situácii už organizácii nestačí pracovať len s historickými údajmi, ale musí sa posunúť smerom k pokročilej analytike, vďaka ktorej dokáže predpovedať najväčšie príležitosti, kam treba sústrediť svoju zvyšnú odbornú kapacitu pre dosahovanie výsledkov s čo najväčším pozitívnym vplyvom na verejné zdravie.

Vďaka prediktívnej analytike sa môžu zamestnanci verejného zdravotníctva prepnúť z reaktívneho módu na proaktívny. Popri dashboardoch – paneloch tak môžu bežať aj algoritmy strojového učenia, ktoré predpovedajú zhoršujúcu sa kvalitu vody na kúpanie, okres, v ktorom sa výrazne zhorší epidemiologická situácia či identifikujú podozrivé kozmetické výrobky, ktorých kvalitu treba preveriť, či zariadenia stravovacích služieb, ktoré nie sú v súlade s reguláciou.

6.4.3.4 Koncové body pre SQL a SPARQL

Na dopytovanie štruktúrovaných (SQL) a neštruktúrovaných (SPARQL) dát, uložených v databázach, slúžia koncové body – aplikačné rozhrania, ktoré možno jednoducho používať v pokročilých nástrojoch analýzy. Skriptami v jazyku SQL a SPARQL je možné vybrať si podmnožinu relevantných údajov, ktoré sú potrebné pre vytvorenie daného analytického modelu, a prezrieť si ju.

6.4.3.5 Dátový „engine“

Slúži na vizualizáciu a manipuláciu miliónov riadkov v databázach, ideálne v sekundách. Súčasťou má byť aj nástroj na získavanie, transformáciu a nahrávanie dát z externých zdrojov do interných databáz (ETL nástroje). Získavanie dát z externých zdrojov mimo inštitúcie verejnej správy môže byť potrebné pre hlbšie analýzy a hľadanie kauzality.

6.4.3.6 Pokročilé nástroje analýzy

Grafické rozhrania, cez ktoré možno analyzovať historické údaje, ako je popísané v kapitole 3.4.1, majú samozrejme svoje limity, a nemožno v nich realizovať všetky typy dátových analýz podľa metód dátovej vedy, ako budú popísané v kapitole 3.5. Pre pokročilejšie analýzy je potrebné využívať programovacie jazyky ako R a Python, napríklad aj v unifikovanom prostredí. Trendom je urobiť tieto jazyky prístupnejšie aj menej skúseným používateľom cez nadstavbové riešenia v grafických používateľských rozhraniach, ale tento trend je ešte len na začiatku.

Programovací jazyk R vznikol ako jednoduchšia alternatíva k SAS pre štatistov. Je to veľmi populárny jazyk, ktorý je implementovaný ako open source v nástroji pre štatistické analýzy pod názvom RStudio. Podobne ako k Pythonu existuje aj k jazyku R veľká komunita, ktorá ho používa a diskutuje o rôznych prístupoch k riešeniu analytických problémov. R je viac určené dátovým vedcom, obsahuje tie najnovšie knižnice s novými metódami a algoritmi. Python je vhodnejší na tvorbu analytických modelov, ktoré môžu ísť aj do produkcie. Ide o oveľa univerzálnejší programovací jazyk ako R. Oba jazyky poskytujú aj nespočetné možnosti na vizualizáciu dát.

Ponúkajú nasledovnú množinu funkcionalít:

- 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 problematiku subjektu a odporučiť ideálne nastavenie 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, „crowd-sourcing“ a „red teaming“: pre plánovanie budúceho vývoja.

6.4.3.7 Nástroje na riadenie verzí a zdieľanie zdrojového kódu a dátových súborov

Nástroje na riadenie verzí zdrojového kódu a dát umožňujú sledovať závislosti v jednotlivých súboroch zdrojového kódu počas vývoja modelu a zreprodukovať proces modelovania. Na sledovanie samotných zmien v jednotlivých súboroch a dátach slúžia nástroje ako git . Dobrou praxou je rozdeliť celý zdrojový kód na nasledujúce čiastkové súbory, ktoré nasledujú štandardizovaný, iteratívny proces dátového modelovania:

- Súbor, v ktorom sa vytvorí dátový set napríklad vo formáte .csv z dát stiahnutých z dátového trhu,
- Súbor, v ktorom sa dátový set cez vzorkovanie podľa výstupnej premennej rozdelí na testovací a tréningový set,
- Súbor, v ktorom sa identifikujú relevantné vstupné premenné pre analytický model,
- Súbor, v ktorom sa natrénuje vybraný analytický model alebo model strojového učenia,
- Súbor, v ktorom sa zhodnotí prostredníctvom kvantitatívnych metrík výkonnosť natrénovaného modelu na testovacích dátach.

Nástroje pre riadenie verzí si vytvoria model závislostí jednotlivých súborov so zdrojovým kódom a vstupných a výstupných dátových súborov, a pri nejakej zmene vedú zreprodukovať nevyhnutné časti procesu pre vytvorenie modelu.

6.4.3.8 Nástroje na zdieľanie dashboardov – panelov a dátových analýz

Tieto nástroje umožnia zdieľanie výsledných modelov a analýz online, cez webové sídla alebo na intranete za hodiny práce, nie za týždne či mesiace. Vďaka tomu môžu dátoví analytici jednoducho prezentovať výsledky svojej práce a podrobiť ich konštruktívnej kritike odborníkov na danú agendu a na jej základe iteratívne svoje modely zlepšovať.

6.5 Dáta, dátové zdroje a výstupy

Dostupnosť kvalitných, včasných dát v potrebnej granularite

Užitočnosť výstupov analýz pre fungovanie inštitúcie verejnej správy veľmi závisí od kvality dát, ktoré budú do týchto analýz vstupovať. Je preto nevyhnutným predpokladom mať zavedené postupy efektívneho manažmentu dát s ohľadom na riadenie kvality dát.

Zavádzanie metód Regulácie 2.0 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.

Údaje o regulovanej oblasti a jej fungovaní

- 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.

Báza relevantných dát

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

Skupina údajov	Potencionálne zdroje
Katalóg metadát s číselníkmi a ontologický model	<ul style="list-style-type: none"> ■ Centrálny model údajov verejnej správy v rámci Metainformačného systému
Referenčné údaje o subjektoch (podnikateľoch a občanoch)	<ul style="list-style-type: none"> ■ Registra právnických osôb (RPO) ■ Registra fyzických osôb (RFO)
Finančné vzťahy subjektu a štátneho rozpočtu	<ul style="list-style-type: none"> ■ Rozpočtový informačný systém ■ Databázy Finančnej správy, ■ Databázy Sociálnej poisťovne
Sociálny status subjektu	<ul style="list-style-type: none"> ■ Databázy ÚPSVaR o nezamestnanosti ■ Systém sociálnych dávok ■ Sociálne prípady
Vzdelávanie	<ul style="list-style-type: none"> ■ Rezortný informačný systém (RIS)
Štatistické údaje	<ul style="list-style-type: none"> ■ 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 réžii a ktoré bude nakupovať od špecializovaných spoločností. Ďalšou zaujímavou skupinou údajov sú údaje zo sietí internetu vecí z takzvanej machine-to-machine komunikácie (M2M) v energetike, konkrétne v Smart Grid, Smart Metering a Smart Home. Zlepší a spríjemní sa tiež proces štatistického zisťovania vnímania administratívnej 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 16: Príklady údajov z monitoringu regulovaného prostredia

Skupina údajov	Potencionálne zdroje
Údaje z monitoringu trhu	<ul style="list-style-type: none"> ■ 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	<ul style="list-style-type: none"> ■ geografické údaje o objektoch pevne spojených so zemou ■ satelitné údaje

Historické údaje z výkonu agendy

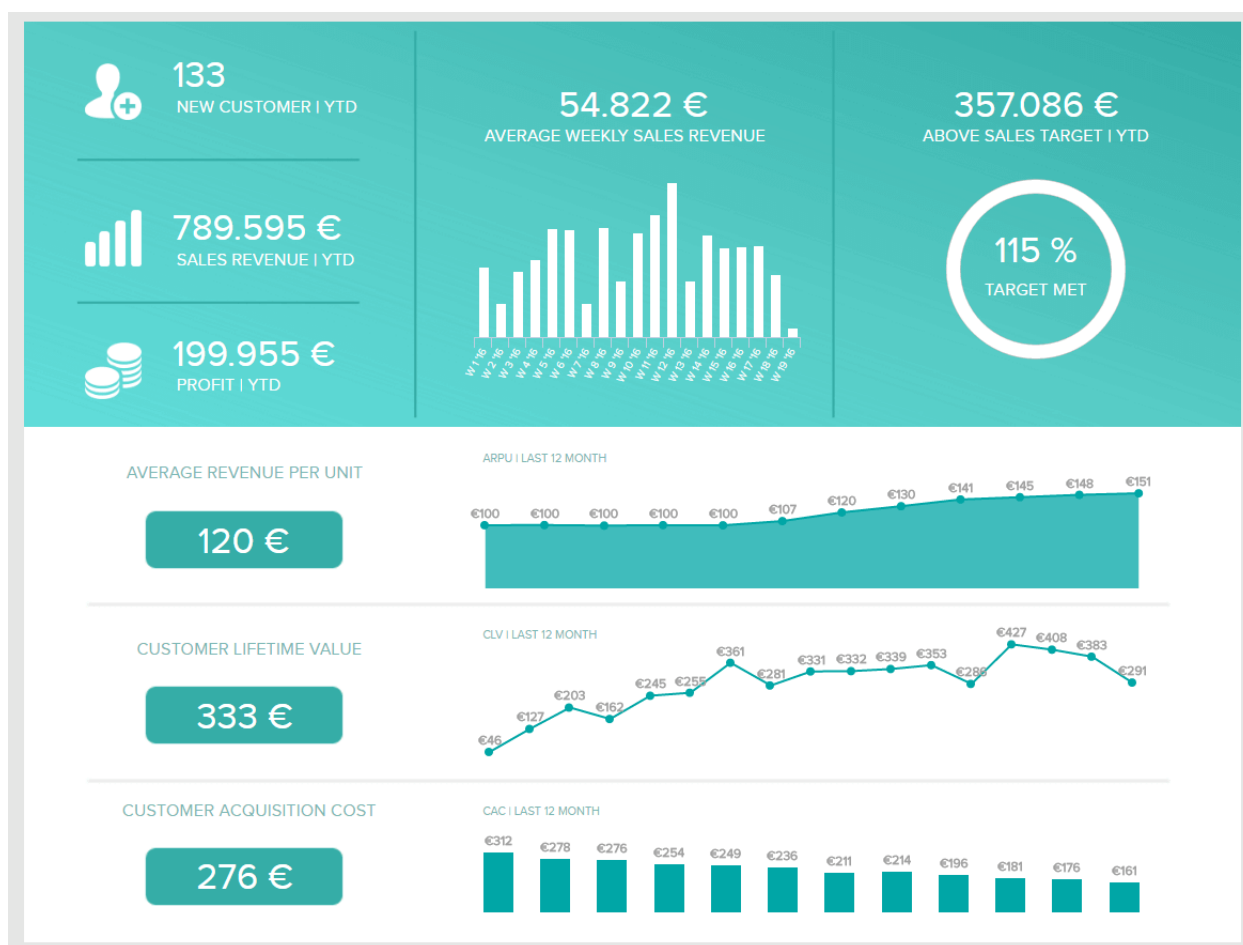
Pre učenie algoritmov je veľmi dôležité mať prístup k historickým údajom, na základe ktorých je možné automatizovať rozhodovací proces alebo navrhovať odporúčané formuláre. V prípade spracovania historických údajov, ako sú rozhodnutia v správnom konaní alebo súdne rozhodnutia, je však potrebné brať do 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:

- Ako údaje o minulosti, v istom časovom intervale (napríklad o minulom kalendárnom roku), zozbierané na základe vykazovania (napríklad na základe tvorby výročnej správy o činnosti organizácie) – takéto dáta sú k dispozícii pre analýzu s veľkým oneskorením,
- Ako dáta o minulosti, ktoré sú zbierané o danej agende priebežne, počas roka, napríklad aj pomocou informačného systému – v tomto prípade sú dáta k dispozícii priebežne, na základe inkrementálnych aktualizácií.
- Ako dáta o minulom okamihu, ktoré sú zbierané informačnými systémami takmer v reálnom čase počas vykonávania agendy. Zdržanie oproti aktuálnej realite je dané buď len rýchlosťou spracovania dát v informačných systémoch alebo časom, ktorí zamestnanci potrebujú na zadanie dát do informačných systémov – v tomto prípade sú dáta pre analýzu dostupné takmer okamžite, ako sa daná udalosť stala, a môžu slúžiť pre zlepšovanie každodennej prevádzky.
- Analýzou historických údajov možno tiež prísť k záveru, že niektoré dáta nie sú zbierané v dostatočnej granularite na to, aby z nich bolo možné vytvoriť užitočné analytické výstupy. To znamená, že napríklad o danej aktivite v agende chýbajú niektoré kľúčové informácie, aby bolo možné zistiť, prečo sa v danej agende nedarí dosahovať lepšie výsledky.

6.5.1 Výstupy - Dashboardy

Táto časť sa venuje prehľadu prípadov použitia, ktoré je možné navrhnuť pri dátovej analýze. Základným prípadom použitia je vytvorenie rôznych typov dashboardov –panelov pre určené skupiny používateľov, ktoré budú zachytávať stav tých agend, ktoré má zmysel sledovať prostredníctvom analýzy historických údajov. Hoci dashboardy - panely majú svoje limity v schopnosti odpovedať na otázku prečo je stav v agende taký, aký je, sú základným analytickým výstupom pre organizáciu a dokážu prispieť k mnohým zlepšeniam fungovania a k lepšiemu rozhodovaniu. Dashboardy - panely môžu byť statické, ale aj interaktívne, ktoré umožňujú používateľom pracovať so zobrazenou informáciou v dashboarde - paneli. To znamená, že môžu napríklad zmeniť filter dát (napríklad časový interval alebo konkrétnu premennú), typ grafu či zobraziť podrobnejšie informácie o danej téme.

Obrázok 4: Ukážka dashboardu⁹ - panelu



Existujú tri základné typy dashboardov panelov:

1. Prevádzkový dashboard - panel, ktorý znázorňuje, čo sa práve v organizácii udialo,
2. Strategický dashboard - panel, ktorý sleduje dosahovanie kľúčových ukazovateľov výkonnosti,

⁹ Zdroj: <https://www.datapine.com/blog/strategic-operational-analytical-tactical-dashboards/>, Dátum referencie: 03.05.2021

-
3. Analytický dashboard - panel, ktorý spracúva historické údaje pre identifikovanie trendov a odhaľovanie poznatkov v dátach.

Ideálne je, keď sa v organizácii podarí nasadiť do praxe všetky tri typy dashboardov – panelov, ale tento scenár nie je vždy realistický. Návrh a realizácia užitočného dashboardu – panelu si vyžaduje čas, starostlivé zváženie, ktoré historické údaje bude využívať, ako aj výber vhodného dodávateľa softvéru. Dashboardy - panely môžu slúžiť nielen pri každodenných odborných aktivitách, ktoré si vyžadujú mať prehľad o dianí v danej agende na základe dát, ale dokážu zásadne pomôcť aj pri transformácii či zlepšovaní interného fungovania organizácie. Cez dashboardy - panely môže organizácia rýchlo zistiť svoju aktuálnu aj historickú výkonnosť a úspešnosť pri dosahovaní stanovených cieľov. Dashboardy - panely môžu mať nasledujúce prínosy:

- Podpora kultúry neustáleho zlepšovania sa,
- Transparentnosť v oblasti dát a rozhodovania naprieč organizáciou,
- Lepšia kontrola nad rozhodovaním vďaka dostupnosti správnych dát v správnom čase,
- Úspora času a peňazí pri vykazovaní činnosti a výsledkov organizácie,
- Nasmerovanie zamestnancov organizácie k efektívnemu dosahovaniu spoločných cieľov.

Prevádzkový dashboard - panel

Ide o vykazovací nástroj, ktorý sa používa na monitorovanie biznis procesov v organizácii, ktoré sa často menia, a na sledovanie kľúčových ukazovateľov výkonnosti. V porovnaní s ostatnými typmi dashboardov – panelov sa dáta aktualizujú veľmi často, niekedy až každú minútu, takže je potrebné mať k dispozícii historické údaje z biznis procesov v takmer reálnom čase. Prevádzkové dashboardy - panely sú navrhnuté tak, že sa na nich vybraní zamestnanci pozerajú niekoľko ráz za deň. Často sa využívajú na sledovanie pokroku k definovanému cieľu.

Príkladom použitia prevádzkového dashboardu – panelu je sledovanie počtu zaočkovaných osôb na ochorenie COVID-19 na mapovom podklade a sledovanie úspešnosti jednotlivých opatrení v rámci kontinuálnej kampane na osvetu a podporu ochoty ľudí dať sa zaočkovať. Ďalším príkladom je analytický panel pre analýzu dynamiky šírenia ochorenia Covid-19 prostredníctvom kľúčových epidemiologických ukazovateľov a premenných, ako počet pozitívnych testov v danom laboratóriu alebo odbornom mieste a približné miesto zdržiavania sa kontaktov získaných epidemiologickým vyšetrovaním. Prevádzkový dashboard – panel môže tiež slúžiť na prehľad o práci štátneho zdravotného dozoru – možno v ňom napríklad nad mapou Slovenska sledovať, aké kontroly aktuálne prebiehajú a aké majú zistenia.

Strategický dashboard – panel

Strategický dashboard – panel predstavuje vykazovací nástroj, ktorý monitoruje stav kľúčových ukazovateľov výkonnosti na úrovni organizácie a jej strategických priorít, a spravidla ho využívajú vyššie manažérske pozície v organizácii. Dáta, ktoré sú za vizualizáciami v tomto dashboarde – paneli, sa aktualizujú na pravidelnej báze, avšak menej často ako v prevádzkovom dashboarde – paneli. Strategické dashboardy - panely si možno pozerieť raz za deň a umožňujú manažérom sledovať pokrok v oblasti kľúčových agend organizácie.

Príkladom strategického dashboardu – panelu môže byť prehľad o počte verejných obstarávaní v rezorte verejného zdravotníctva po jednotlivých agendách, a ich stav (príprava, kontrola, prijímanie ponúk, vyhodnocovanie ponúk, uzatváranie zmlúv a podobne).

Analytický dashboard –panel

Jedná sa o vykazovací nástroj, ktorý sa využíva na analýzu obrovského množstva historických údajov, aby bolo možné skúmať trendy, predpovedať výsledky a odhaľovať nové poznatky obsiahnuté v dátach.

Analytické dashboards - panely sú často súčasťou nástrojov biznis inteligencie, pretože sú spravidla navrhnuté a vytvorené dátovými analytikmi. Dáta za týmito dashboardmi – panelmi musia byť presné a aktuálne a smú byť aktualizované len zriedkakedy. Analytické dashboards - panely sú komplikovanejšie ako prevádzkové a strategické, pretože často obsahujú aj možnosti, ako sa pozrieť na daný dátový aspekt hlbšie a ako vytvárať ad hoc dopyty na dáta.

Tabuľka 17: Výber dashboardu –panelu na základe požiadaviek na reporting a dostupnosť dát

Na aké otázky sa snažíme nájsť odpoveď?		
<i>V prvom kroku je potrebné zdefinovať, aké potreby má dashboard –panel adresovať a aký bude rozsah projektu súvisiaceho s jeho vytvorením.</i>		
Prevádzkové dashboards - panely	Strategické dashboards - panely	Analytické dashboards – panely
Otázky, ktoré súvisia s analýzou údajov z nedávnej minulosti (pár minút) a majú vplyv na chod každodennej agendy	Otázky ohľadom strategického smerovania organizácie, plnenia strategických cieľov a kľúčových ukazovateľov výkonnosti, ktoré sú relevantné pre celú organizáciu a jej podriadené organizácie, prípadne pre celý rezort verejného zdravotníctva.	Otázky, ktoré si vyžadujú analytický až vedecký prístup k spracovaniu veľkého množstva historických údajov o danom fenoméne v danej agende, alebo otázky ohľadom historických trendov v danej agende.
Kto bude dashboards - panely používať?		
<i>Návrh, vlastnosti a požadované školenia sú ovplyvnené rolou používateľa dashboardu –panelu v rámci organizácie.</i>		
Prevádzkové dashboards - panely	Strategické dashboards - panely	Analytické dashboards – panely
Riaditelia a odborní zamestnanci	Hlavný hygienik, regionálni hygienici	Biznis analytici, dátoví analytici, riaditelia, vedci
Aké nedostatky vo výkone agendy je potrebné riešiť?		
<i>Identifikácia nedostatkov môže slúžiť na vytvorenie sady ukazovateľov, ktoré budú použité ako základ pre tvorbu dashboardu - panelu.</i>		
Prevádzkové dashboards - panely	Strategické dashboards - panely	Analytické dashboards – panely
Výkon agendy v rámci každodenných aktivít	Výkon agendy v rámci štvrťroka až roka	Problém s dosahovaním konkrétnych výsledkov v danej agende, týždenná výkonnosť
Aký je stav dátovej infraštruktúry?		
<i>Ak sú dáta dostupné z viacerých zdrojov a v dobrej kvalite v dátovom sklade, možno vytvoriť sadu analytických a strategických dashboardov - panelov.</i>		
Prevádzkové dashboards - panely	Strategické dashboards - panely	Analytické dashboards – panely

Webové aplikačné programovateľné rozhrania, databázy, tabuľkové dáta (napr. MS Excel)	Webové aplikačné programovateľné rozhrania, databázy, tabuľkové dáta (napr. MS Excel), dátový sklad	Dátový sklad, databázy
Aké sú požiadavky na oneskorenie dát? <i>Odpoveď na otázku, či potrebujeme analyzovať dáta z posledných minút alebo posledných rokov, a či takého dáta máme k dispozícii, nám tiež pomáha vybrať ten správny dashboard - panel.</i>		
Prevádzkové dashboards - panely	Strategické dashboards - panely	Analytické dashboards - panely
Dáta s nízkym oneskorením, dáta takmer v reálnom čase, kde extrémne záleží na ich dostupnosti	Inkrementálne aktualizácie dát, potreba presných dát v správnom čase	Presné dáta, ktoré ale môžu byť dostupné so značným oneskorením oproti realite

7 Transformácia

— návrh postupu transformácie,

Analýza dát pokrýva oveľa viac ako len prácu analytikov, ktorí aplikujú počítačové algoritmy na neustále sa zväčšujúce objemy dát o verejnom zdravotníctve. Na vstupe sú dáta a relevantný kontext daný odborníkmi na danú agendu, vďaka ktorému možno dátam porozumieť, určiť, ktoré sú podstatné, a správne ich interpretovať. Na výstupe musia byť prezentované výsledky modelov rozhodovania tak, aby boli pre relevantných odborníkov užitočné a vedeli ich využiť na lepšie rozhodovanie a skvalitnenie výkonu svojej agendy. Základné vrstvy takéhoto systému analýzy dát sú nasledovné, ako znázorňuje aj obrázok nižšie:

- Prezentácia výsledkov,
- Riadenie kvality a výkonnosti,
- **Analytická vrstva,**
- **Dátová vrstva,**
- **Odborný kontext agendy.**

Obrázok 5: Vrstvy systému analýzy dát

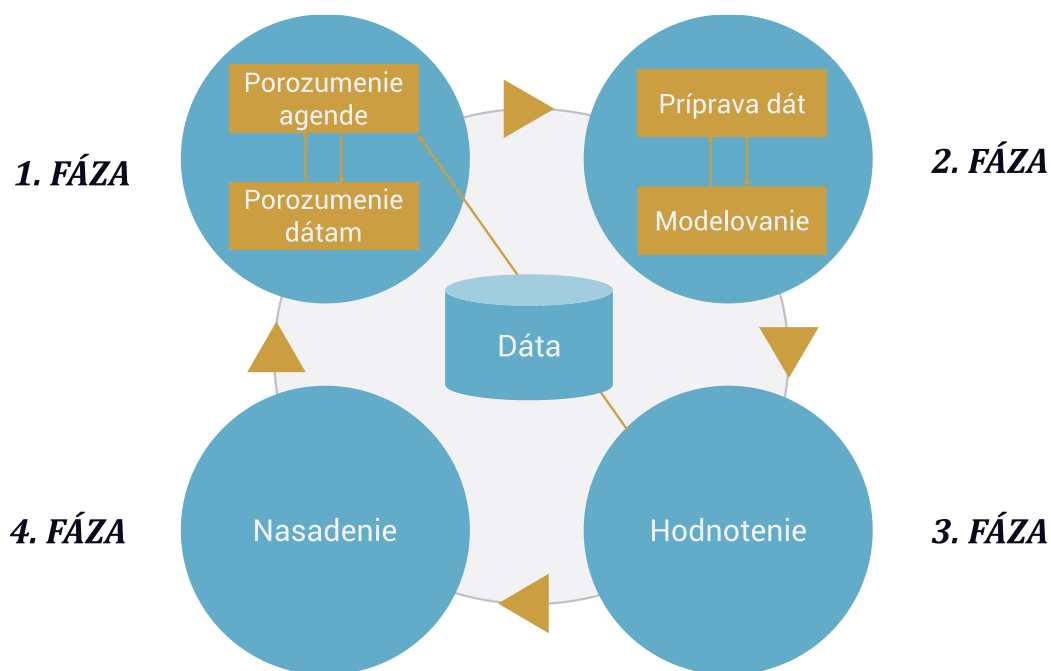
Analytický zásobník ("Stack")		
Prezentácia výsledkov		
Vizualizácie	Dashboardy	Reporty
Upozornenia	Mobilné aplikácie	Priestorové viz.
Riadenie kvality a výkonnosti		
Procesy	KPIs	Kritériá úspechu
Stratégia zlepšovania	Stratégia hodnotenia	
Analytická vrstva		
Nástroje	Metódy	Tím
Zúčastnené strany	Požiadavky	
Nasadenie	Spravovanie	
Dátová vrstva		
Kvalita	Manažment	Integrácia
Infraštruktúra	Úložiská	
Odborný kontext agendy		
Zámer	SMART ciele	Hlas verejnosti

Vrstva dát predpokladá, že sú v organizácii zavedené postupy efektívneho manažmentu dát a implementované patričné technológie, ktoré dokážu sprostredkovať dáta v požadovanom formáte a kvalite analytickej vrstve.

V tomto dokumente sa venujeme predovšetkým analytickej vrstve, na ktorej sa vytvárajú analytické modely a modely rozhodovania, ale aj dátovej vrstve, na ktorej prebieha meranie a zber dát, a odbornému kontextu dát, ktorý napomáha porozumieť dátam a správne ich interpretovať. Prístup je založený na dátovej vede a postupoch pre vyvíjanie algoritmov umelej inteligencie. Dátová veda je o extrahovaní informácií a znalostí z dát (**Chyba! Nenašiel sa žiaden zdroj odkazov.**) pomocou presne d

efinovaných techník dolovania dát. Dolovanie dát, aby dosahovalo maximálne výsledky, si vyžaduje okrem dôsledného aplikovania vedy a technológií aj istú dávku umeleckého remesla. Avšak, ako pri mnohých vyspelých umeleckých remeslách, aj v tomto prípade existuje dobre zanalyzovaný proces, ktorý umožňuje štruktúrovať problém, čím možno dostatočne zaručiť konzistentnosť, opakovateľnosť a objektivnosť dátového dolovania. Tento proces je znázornený na obrázku nižšie a ukazuje, že pravidlom sú iteratívne zlepšovania.

Obrázok 6: Proces dátového dolovania. Zdroj: CRISP-DM



V realite sú problémy, na ktoré potrebujeme nájsť riešenia, málokedy uchopiteľné tak, že ich možno presne prepojiť s technikami dolovania dát. Napríklad riešenie reálneho problému nevnímate tak, že potrebujeme vytvoriť klasifikáciu alebo klastre dát, či použiť regresiu. Alebo ani dáta o týchto problémoch nie sú reprezentované tak, že na ne možno tieto techniky ako regresiu či klastrovanie priamo aplikovať. **Preto prvou fázou je porozumenie problému z pohľadu agendy a porozumenie dátam súvisiacim s problémom.** Keďže problémy alebo otázky priamo z agendy neprichádzajú ako jednoznačne naformulované problémy dolovania dát, vyžaduje si tento krok značnú kreativitu dátového vedca. Kľúčom k úspechu je teda kreatívne preformulovanie problému vyplývajúceho z vykonávania agendy na jeden alebo viacero problémov dátovej vedy, teda na problémy, na ktoré sa dajú aplikovať analytické modely ako klasifikácia a regresia a ktoré možno prepojiť do modelu rozhodovania. Cieľom je teda nájsť riešenie problému a pomôcť s rozhodnutím, a pritom slúžia dáta ako surový materiál, z ktorého bude toto riešenie vystavané. Historické dáta však spravidla neboli zbierané za účelom vyriešiť daný problém, alebo poskytnúť návod na rozhodnutie v danej otázke. Je preto kľúčové porozumieť silným stránkam a aj limitom dát, pretože málokedy existuje presný súlad medzi dostupnými dátami a dátami, ktoré riešenie problému vyžaduje. Dáta môžu byť napríklad o prekrývajúcich sa množinách entít, avšak o žiadnej množine nemusia byť dostupné všetky dáta. Dáta môžu mať rôznu úroveň spoľahlivosti, môžu byť zadarmo, alebo spoplatnené, alebo nemusia vôbec existovať, a tým pádom sa budú musieť zbierať dodatočne v rámci riešenia daného problému. Investícia do nových dát musí byť opodstatnená. Často je veľmi náročné už len zlučovať dáta o tej istej entite z rôznych dátových zdrojov. Cieľom kroku porozumenia dát je odkryť štruktúru problému a dát, ktoré sú dostupné, a namapovať ich na jednu alebo viaceré úlohy dolovania dát, na ktoré možno aplikovať vedecký a technologický prístup.

Odporúčame v tejto fáze začať zbierať informácie o oblastiach na obrázku nižšie z pohľadu odborného garanta danej problematiky. Ide o cenný vstup pre dátových analytikov a vedcov, ktorí budú tvoriť a testovať modely.

V druhej fáze je potrebné nadizajnovať riešenie pre daný problém spojený s lepším rozhodovaním. V rámci tejto fázy sa pripravujú dáta do vhodnej štruktúry a formátu pre modelovanie a iteratívnym spôsobom sa vytvára analytický model a prípadne aj model rozhodovania, ak je založený na pokročilých analytických alebo simulačných technikách. Techniky dátovej analýzy sú síce výkonné, ale kladú zásadné požiadavky na dáta, s ktorými pracujú. Krok prípravy dát často prebieha spolu s krokom porozumenia dát z predchádzajúcej fázy, aby sa podarilo dostať dáta do takej podoby, ktorá prinesie najlepšie výsledky. Typickými príkladmi prípravy dát je transformácia dát na tabuľkový formát, vysporiadanie sa s chýbajúcimi hodnotami a konverzia dát na iný typ. Niektoré techniky dolovania dát vedia pracovať len so symbolickými alebo kategorickými dátami, iné zas len s číslami. Číselné hodnoty musia byť tiež normalizované alebo škálované, aby ich bolo možné porovnávať. V závere tohto kroku sú dáta pripravené pre proces modelovania, ktorému sa podrobnejšie venujeme v kapitole 7.1. Analytické modelovanie sa snaží odhaliť vzorce, ktoré zachytávajú zákonitosti obsiahnuté v dátach. Využívajú sa na to postupy dátovej vedy a techniky dolovania dát.

V tretej fáze je potrebné kriticky a dôsledne vyhodnotiť, či výsledky analytického modelovania sú validné a spoľahlivé. Musí byť k dispozícii dostatok dôkazov o tom, že modely a vzorce získané z dát sú skutočné zákonitosti a nie len anomálie. Tieto dôkazy je možno získať testovaním modelu v kontrolovaných „laboratórnych“ podmienkach. Táto fáza tiež slúži na preverenie toho, či vytvorený model je v súlade s cieľmi a očakávaniami v rámci výkonu agendy a či má skutočne potenciál podporiť lepšie rozhodovanie. Tiež treba pri hodnotení brať do úvahy fakt, že analytický model je len časť celkového riešenia pre podporu rozhodovania. Môže sa stať, že model bude veľmi presný v laboratórnych podmienkach, avšak v reálnom kontexte agendy sa môže ukázať ako nepraktický – napríklad vyhodnotí priveľa podobne podozrivých subjektov poskytujúcich stravovacie služby, avšak kapacity dozoru ich nedokážu všetky preveriť a pri výbere podmnožiny už nemusia dosiahnuť očakávané zvýšenie efektivity. Preto je potrebné vyhodnotiť model kvantitatívne aj kvalitatívne a získať názory viacerých zúčastnených strán, aby výsledkom bol model, ktorý ozaj prinesie zlepšenie v rozhodovaní a efektívite. Kľúčové je neustále zlepšovať rámec a nástroje pre hodnotenie modelov, ideálne je aj vedieť simulovať produkčné prostredie, aby sa minimalizovalo riziko, že vo výslednom riešení nebude model fungovať spoľahlivo, čo je ale už oveľa ťažšie odhaliť včas. Ďalšou možnosťou je vytvoriť také produkčné prostredie systému pre podporu rozhodovania, ktoré podporuje randomizované experimenty, ktorými možno veľmi dobre overiť viacero typov analytických modelov a modelov rozhodovania. Pri akýchkoľvek závažnejších pochybnostiach o kvalite, spoľahlivosti alebo účelnosti modelu je potrebné sa vrátiť späť do prvej fázy a odpovedať si na nasledujúce otázky: Je porozumenie agendy dostatočné? Je správne definovaný problém, ktorý sa snažíme daným modelom vyriešiť? Môžeme zvýšiť kvalitu, spoľahlivosť a rozsah dostupných dát pre modelovanie?

Vo štvrtej fáze ide o nasadenie modelu rozhodovania (viac o ňom v kapitole 7.2) s využitím analytického modelu **do praxe** s cieľom zefektívniť výkon danej agendy. Nasadený model rozhodovania môže byť súčasťou informačného systému alebo webovej aplikácie, alebo môže byť zakomponovaný do biznis procesu. Tu je ešte dôležité poznamenať, že model rozhodovania môže byť napríklad jednoduchý súbor pravidiel (rozhodovacie tabuľky alebo stromy, vid' **Chyba! Nenašiel sa žiaden zdroj odkazov.**), ktorý využíva hodnoty predpovedaných premenných z analytického modelu, alebo môže ísť o komplexný model založený napríklad preskriptívnej analytike. Ak je model rozhodovania komplikovaný, musí prejsť tiež obdobnou fázou kritického a dôsledného hodnotenia jeho spoľahlivosti a použiteľnosti, ako bolo popísané vo fáze 3. Bez ohľadu na úspech nasadenia sa celý proces vracia do prvej fázy porozumenia kontextu agendy, pretože proces dolovania dát vždy prinesie nové poznatky o fungovaní agendy, možných riešeniach problémov ako aj tipy ako zlepšiť dostupné dáta a prácu s nimi. Ak sa podarí ďalšia iterácia celého procesu, výsledkom bude vylepšené riešenie pre podporu rozhodovania.

Je dôležité si uvedomiť, že dolovanie dát je prieskumnou aktivitou, ktorej podstata je bližšie k výskumu a vývoju ako k softvérovému inžinierstvu. Uvedený cyklus podľa CRISP iteratívne tvorí prístup a stratégiu, nie softvérový dizajn. Výsledky akéhokoľvek kroku môžu zásadne zmeniť porozumenie problému.

Nasledujúca tabuľka poskytuje prehľad jednotlivých fáz celého procesu dátového dolovania podľa CRISP-DM.

Tabuľka 18: Prehľad jednotlivých fáz celého procesu dátového dolovania podľa CRISP-DM¹⁰

Fáza	Oblasť úloh	Popis
1	A. Porozumenie agende a problémom	<ol style="list-style-type: none"> 1. Definovanie cieľov a kritérií úspešnosti pre zlepšenie rozhodovania v danej agende. 2. Zhodnotenie situácie – dostupnosti zdrojov, požiadaviek, rizík. 3. Definovanie cieľov dolovania dát, ktoré sú prepojené s cieľmi lepšieho rozhodovania. 4. Vytvorenie projektového plánu pre každú fázu.
	B. Porozumenie dátam	<ol style="list-style-type: none"> 1. Zozbieranie dostupných dát a ich nahratie do analytickej platformy. 2. Popísanie dát prostredníctvom metadát. 3. Preskúmanie dát cez analýzu a vizualizáciu, zhodnotenie vzťahov. 4. Zhodnotenie kvality dát a spísanie problémov, ktoré treba vyriešiť v oblasti prípravy dát.
2	C. Príprava dát	<ol style="list-style-type: none"> 5. Výber dát, ktoré budú ďalej použité, a spísanie dôvodov, prečo niektoré dáta boli vynechané (ak je to relevantné). 6. Prečistenie dát, aby nemali chýbajúce či nesprávne hodnoty. Ide o kľúčovú a často o časovo najnáročnejšiu úlohu. 7. Vytvorenie nových užitočných premenných z dostupných dát, napríklad index telesnej hmotnosti z výšky a váhy. 8. Integrácia dát z rôznych zdrojov do jedného datasetu pre analýzu. 9. Zjednotenie formátov dát a normalizácia dát, ak je to nevyhnutné.
	D. Modelovanie	<ol style="list-style-type: none"> 1. Výber vhodných modelovacích techník a algoritmov pre tvorbu analytického modelu.

¹⁰ Zdroj: <https://www.datascience-pm.com/crisp-dm-2/>, Dátum referencie: 22.11.2020

Fáza	Oblasť úloh	Popis
		<ol style="list-style-type: none"> 2. Rozdelenie dát na dáta na tréovanie, testovanie, prípadne aj na validáciu a návrh prístupu k testovaniu algoritmov v modeli. 3. Vytvorenie modelov z dostupných možností. 4. Zhodnotenie modelov cez testovacie a validačné dáta, výber použiteľných modelov.
3	E. Hodnotenie	<ol style="list-style-type: none"> 1. Zhodnotenie vytvoreného analytického modelu/ modelu rozhodovania z pohľadu dosiahnutia cieľov a kritérií úspešnosti, definovaných v prvej oblasti. 2. Revízia celého procesu, či sa vykonali všetky kroky dôsledne, či sa neopomenuli novovzniknuté skutočnosti alebo nezanedbali nové poznatky. 3. Rozhodnutie o ďalších krokoch – či je možné analytický model/ model rozhodovania nasadiť do praxe, alebo je potrebné sa vrátiť na začiatok procesu.
4	F. Nasadenie do praxe	<ol style="list-style-type: none"> 1. Naplánovanie nasadenia analytického modelu a modelu rozhodovania do praxe. 2. Výber modelu rozhodovania – ak sa jedná o príliš komplexný model, je nutné sa vrátiť do oblasti D, a začať s modelovaním. 3. Vytvorenie plánu monitorovania a údržby celého riešenia. 4. Vytvorenie finálnej správy, vrátane ponaučení z celého procesu. 5. Zhodnotenie celého projektu a nastavenie procesu neustáleho zlepšovania sa.

7.1 Tvorba analytických modelov

Hlavným zámerom dolovania dát je vytvoriť na základe dát analytický model, ktorý dokáže predpovedať budúce výsledky, a tým pádom podporiť lepšie rozhodovanie. Model je vždy zjednodušenou reprezentáciou reality. Toto zjednodušenie sa vytvára na základe predpokladov o tom, čo je a čo nie je dôležité pre daný účel modelu. Príkladom je mapa ako model fyzického mesta - veľmi dobre slúži účelu orientovať sa v meste, pritom však nezohľadňuje veľmi veľa informácií o ňom. V dátovej vede je takýmto modelom vzorec, ktorý dokáže odhadnúť neznámu hodnotu premennej, ktorá nás zaujíma. Tento vzorec môže byť matematický alebo môže ísť o logický výrok ako pravidlo. Často ide však o hybrid oboch možností. Model popisuje vzťahy medzi atribútmi - súborom premenných, ktoré považuje za relevantné na riešenie danej problematiky - a vybranou cieľovou premennou, ktorú chceme predpovedať v budúcnosti pre nový, doposiaľ nepozorovaný prípad. Model pre predpoveď odhaduje hodnotu cieľovej

premennej pomocou funkcie atribútov. Tabuľka nižšie poskytuje prehľad najčastejších analytických modelov.

Proces tvorby prediktívneho modelu možno rozdeliť do nasledujúcich krokov, pričom predpokladáme, že problém alebo agenda, v ktorej chceme zlepšiť rozhodovanie, je už predefinovaná na sériu cieľových premenných, ktorých hodnoty chceme v budúcnosti predpovedať. Ďalším predpokladom je, že dátam plne rozumíme a máme ich v požadovanej podobe pre modelovacie techniky:

1. Výber relevantných premenných – atribútov, ktoré poskytujú informáciu užitočnú pre predpoveď cieľovej premennej: Ak máme k dispozícii obrovský objem dát, identifikovanie tých premenných, ktoré korelujú alebo sú kauzálne prepojené s cieľovou premennou záujmu, je samo o sebe zaujímavým výstupom dolovania dát. Jednou z bežných modelovacích techník pre určenie relevantných premenných je stromová indukcia („tree induction“), ktorá rekurzívne hľadá atribúty pre danú podmnožinu dát.
2. Rozdelenie historického dátového setu, v ktorom poznáme hodnotu cieľovej premennej, na dáta na tréning analytického modelu a na testovacie dáta, ktorým sa vhodnosť modelu overí.
3. Výber analytického modelu, ktorý má najlepšie šance generalizovať – to znamená, že dokáže uspokojivo predpovedať cieľovú premennú aj na základe budúceho setu dát, ktorý nebol použitý na tréning.
4. Tréning analytického modelu dátami na tréning, čím sa iteratívne nastaví všetky potrebné parametre modelu.
5. Overenie spoľahlivosti analytického modelu určením rozdielu medzi presnosťou predpovede cieľovej premennej v tréningových dátach a v testovacích dátach, pričom presnosť predpovede v oboch prípadoch bude spravidla rozdielna. Presnosť predpovede založenej na testovacích dátach odzrkadľuje schopnosť modelu generalizovať. Ak nie sme spokojní so spoľahlivosťou modelu, musíme sa vrátiť do kroku 3. Ak model nie je dostatočne komplexný, nie je ani veľmi presný. Avšak komplexné modely majú tendenciu byť veľmi presné na tréningových dátach a presnosť sa radikálne zhoršuje na testovacích dátach. Nájsť vhodný model je preto sčasti umenie a vyžaduje si veľa skúseností a pokusov dátového vedca a spoluprácu s doménovými expertmi.

Účelom tohto dokumentu nie je do detailov vysvetliť matematiku alebo procedúry nevyhnutné pre vykonanie vyššie spomenutých krokov, ale aplikovať tieto kroky na návrh odporúčaných modelov pre lepšie rozhodovanie vo vybraných agendách.

7.2 Tvorba modelov rozhodovania


Základnou úlohou pri transformácii inštitúcie je popri zmene organizačnej štruktúry aj príslušná zmena procesov. V nasledujúcej kapitole vysvetlíme, ako správne nastaviť spôsob a procesy rozhodovania v rámci inštitúcie. V rámci snahy o vytvorenie modelových procesov pre lepšie rozhodovanie verejnej správy je potrebné realizovať 3 základné činnosti:

- Pochopenie pracovného postupu a nastavenie nových pracovných postupov („workflow“),
- Dekompozícia rozhodnutí a zavedenie modelovania rozhodnutí pomocou nástrojov dátovej vedy,
- Redizajn úloh a zmena pracovných náplní s využitím nástrojov dátovej vedy.

7.2.1 Dekompozícia pracovného postupu

Ako sa umelá inteligencia stáva schopnou nahradiť ľudí v back-office a midde-office procesoch, vyvstáva otázka a možnosť redizajnovať celý spôsob výkonu verejnej moci.

Obrázok 7: Dekompozícia procesu



Pri redizajne je dôležité sústrediť sa na hlavný účel procesu: z akého dôvodu proces vykonávame. Ak dokážeme dobre zadefinovať zmysel činnosti v našej organizácii, ďalším krokom j pre každý proces identifikovať:

- Úlohy (aktivity a činnosti), ktoré sa v rámci procesu (workflow) vykonávajú. Úlohu môžeme definovať ako kolekciu rozhodovaní,
- Body rozhodovania, keď dochádza k prijatiu rozhodnutí,
- Role a pozície a ich pracovné náplne (ktoré sú v organizácii potrebné).

Takáto jednoduchá analýza môže vychádzať s procesného modelu, ktorý si inštitúcia vytvorila podľa metodiky na optimalizáciu procesov vo verejnej správe. V skutočnosti je však potrebná menšia miera detailu, dekompozícia sa nevenuje kauzálnym vzťahom medzi úlohami a činnosťami, ale skôr logickému poradiu úloh.

Na základe dekompozície procesu môžeme identifikovať:

- Náklady na realizáciu jednotlivých úloh (aktivít a činností),
- Potencionálne prínosy, ktoré je možné dosiahnuť vďaka lepšiemu rozhodovaniu,
- Potenciál automatizácie úloh a ich nahradenie algoritmickým spracovaním údajov: niekedy je možné automatizovať všetky rozhodnutia v rámci úlohy, niekedy je potrebný vstup človeka v rámci posledného rozhodnutia v sérii.
- Ktoré body rozhodovania môžeme podporiť dátovou analýzou a ako.

Ďalšou dôležitou úlohou je nastaviť prioritizáciu transformácie. V súčasnosti existujú tisíce dátových riešení a nástrojov, ktoré umožnia zlepšiť jednotlivé aspekty úloh (napríklad anonymizovať údaje, pomôcť s prekladom zahraničných textov, zvýrazniť kľúčové podmienky v reguláciách). Vieme si predstaviť, že úlohy budú vylepšované postupne pomalými inkrementálnymi krokmi a v mnohých prípadoch sa tak bude diať. V tejto príručke však podporujeme čo najrozsiahlejšiu transformáciu. Jednoduchý návod ako prioritizovať

zavádzanie dátových riešení je vypočítať NPV (čistú súčasnú hodnotu) a zoradiť jednotlivé nástroje od najvyššej hodnoty po najnižšiu. Následne vytvorte cestovnú mapu zavádzania dátových riešení, kde postupne implementujte jednotlivé nástroje ktoré majú NPV vyššiu ako 0 tempom určený zdrojmi, ktoré máte k dispozícii.

7.2.2 Modely rozhodovania

Základným prínosom dátových technológií, ako je AI, je zlepšenie rozhodovania vďaka aplikácií predikcie.

Pre každú úlohu respektíve rozhodovací proces, ktorý máme záujem automatizovať alebo podporiť dátovými nástrojmi je vhodné vyplniť takúto tabuľku a jasne tak stanoviť požiadavky pre budúci nástroj.

Z pohľadu rozhodovacieho procesu je dôležité:

- Identifikovať oblasti neistoty, ktoré je potrebné riešiť,
- Posúdiť hodnotu správnych a nesprávnych opatrení,
- Stanoviť akcie, ktoré môže algoritmus vykonať respektíve odporučiť,
- Nastaviť merateľné ukazovatele, ktoré dokážu vyjadriť výsledok respektíve zmysel úlohy.

Z pohľadu dátového toku je dôležité:

- Zabezpečiť množinu tréningových dát, ktoré umožnia nastaviť algoritmus,
- Zabezpečiť prísun vstupných dát v požadovanej kvalite, aby sme dokázali ponúknuť predpovede,
- Zaviesť parametrizáciu algoritmu pomocou spätnej väzby.

Modely rozhodovania a ich účel možno popísať nasledovne:

- Dokážu znázorniť to, ako možno kombinovať dáta a znalosti získané z analytických modelov pre podporu lepšieho rozhodovania,
- Možno ich použiť pre priamočiare aj komplexné rozhodovanie,
- Sú prepojené s procesmi, výkonnosťou a organizačnou štruktúrou,
- Reprezentujú rozhodnutia ako analytické poznatky.

Vytvorenie modelu rozhodovania prebieha v nasledujúcich krokoch¹¹:

1. Výskum dostupných informácií od expertov na danú agendu, ktoré sú relevantné pre rozhodnutie.
2. Analýza rizík spojených s rozhodovaním – aké škody môže spôsobiť zlé rozhodnutie alebo naopak nekonanie?
3. Výber a vytvorenie vhodného modelu rozhodovania.

¹¹ Zdroj: <https://simplicable.com/new/decision-analysis>, Dátum referencie: 19.11.2020

4. Overenie vytvoreného modelu rozhodovania na prípadových štúdiách z praxe – do procesu overenia musia byť zapojení aj experti na danú agendu. Z tohto procesu môžu vyplynúť aj dodatočné alebo zmenové požiadavky na analytický model, ktorý je súčasťou modelu rozhodovania.
5. Zavedenie systému neustáleho zlepšovania rozhodovania na základe minulých rozhodnutí.

7.2.3 Rámec pre zlepšenie rozhodovania

Obrázok 8: Rámec pre zlepšenie rozhodovania



Úloha alebo rozhodovací proces

Zdroj: AJAY AGRAWAL, JOSHUA GANS, AVI GOLDFARB: PREDICTION MACHINES

page
05

Popísaný rámec pre lepšie využívanie údajov pri rozhodovaní poskytuje prehľadný návod, ako štruktúrovať dátovo orientovaný projekt.

Tabuľka 19: Podpora rozhodovania v agendách verejného zdravotníctva

Komponent	Príklad 1: Odporúčaný personalizovaný preventívny program - podpora rozhodovania v rámci úlohy návrhu druhu a typu prevencie	Príklad 2: Prediktívny štátny dozor - plánovanie trás osôb, vykonávajúcich štátny zdravotný dozor
Predikcia	Predpovedaj, aké ochorenia hrozia danej komunite a s akou mierou dokáže komunita dodržiavať preventívne opatrenia, a aký bude očakávaný vplyv prevencie na danú komunitu, ktorá indikuje nábeh na chronické ochorenia v budúcnosti.	Predpovedaj pravdepodobnosť nedodržania hygienických nariadení v danom čase a v danom zariadení spoločného stravovania alebo v danej prevádzke poskytujúcej stravovacie služby.
Úsudok	Porovnaj: rôzne prístupy k prevencii a ich šancu na úspech v danej komunite na základe splnenia predpokladov úspechu.	Porovnaj: čas potrebný na odhalenie ďalšej prevádzky zásadne porušujúcej hygienické opatrenia pri rôznych prístupoch plánovania inšpekcie.

Komponent	<i>Príklad 1: Odporúčaný personalizovaný preventívny program - podpora rozhodovania v rámci úlohy návrhu druhu a typu prevencie</i>	<i>Príklad 2: Prediktívny štátny dozor - plánovanie trás osôb, vykonávajúcich štátny zdravotný dozor</i>
Akcia	Rozhodnutie o odporúčanom type prevencie pre danú komunitu.	Plánované trasy osôb, vykonávajúcich štátny zdravotný dozor v danom čase.
Výsledok	Zmena životného štýlu danej komunity a zvrátenie negatívnych trendov aspoň niektorých premenných, ktoré predpovedali vznik chronických ochorení.	Počet odvrátených nákaz z nesprávneho zaobchádzania s potravinami a jedlom v zariadeniach spoločného stravovania alebo v prevádzkach poskytujúcich stravovacie služby. Zvyšovanie miery dodržovania hygienických nariadení (vďaka vnímaniu prevádzok, že štátny dozor funguje efektívne).
Vstupné dáta	<ul style="list-style-type: none"> — Interné dáta ÚVZ z agendy prevencie — Dáta z externých aplikácií (napríklad Fitbit, Apple Health) — Dáta z randomizovaných kontrolovaných štúdií 	<ul style="list-style-type: none"> — Interné dáta ÚVZ z agendy kontroly prevádzok poskytujúcich stravovacie služby — Dáta ministerstva vnútra o priestupkoch — Sťažnosti (napríklad z riešenia Odkaz pre starostu) — Počasie
Spätná väzba	Vyladenie algoritmu na základe aktuálnych výsledkov.	Vyladenie algoritmu na základe aktuálnych výsledkov.

Tabuľka 20: Príklady návrhu podpory rozhodovania

Komponent	<i>Príklad 1: Odporúčaný alternatívny trest - podpora rozhodovania v rámci úlohy návrhu druhu a typu trestu v trestnom konaní</i>	<i>Príklad 2: Prediktívna polícia - plánovanie trás policajných hliadok (pre mestskú alebo poriadkovú políciu)</i>
Predikcia	Predikuj, s akou mierou sa dokáže odsúdený vrátiť do spoločnosti a aká je miera prípadnej recidívy.	Predikuj pravdepodobnosť spáchania trestného činu, alebo priestupku (napríklad výtržníctva) v danom čase a v danej lokalite
Úsudok	Porovnaj: náklady na väzňa v nápravnom zariadení voči nákladom pri monitoringu odsúdeného, voči nákladom pre spoločnosť, ak odsúdený počas alternatívneho trestu spácha ďalší trestný čin.	Porovnaj: náklady, ak pôjde hliadka na miesto kde sa nič nestane voči nákladom spojených s nezachytenou výtržnosťou respektíve trestným činom.
Akcia	Rozhodnutie o odporúčanom type trestu a jeho výške (štandardný alebo alternatívny trest).	Plánované trasy hliadok (súradnice) v danom čase.

Komponent	<i>Príklad 1: Odporúčaný alternatívny trest - podpora rozhodovania v rámci úlohy návrhu druhu a typu trestu v trestnom konaní</i>	<i>Príklad 2: Prediktívna polícia - plánovanie trás policajných hliadok (pre mestskú alebo poriadkovú políciu)</i>
Výsledok	Správanie odsúdeného počas doby trvania trestu.	Počet spáchaných priestupkov a trestných činov v rámci danej lokality.
Trénovanie	<ul style="list-style-type: none"> — Historické údaje o povahe trestných činov — Psychologický profil páchateľov — Historické súdne spisy 	<ul style="list-style-type: none"> — Historické štatistiky o trestných činoch a priestupkoch — Historické informácie o pohybe hliadok
Vstupné dáta	<ul style="list-style-type: none"> — Psychologický profil páchateľa — Súdny spis 	<ul style="list-style-type: none"> — Dostupné zdroje — Dátum
Spätná väzba	Redefinícia algoritmu na základe aktuálnych výsledkov.	Redefinícia algoritmu na základe aktuálnych výsledkov.

8 Manažment zmeny

- popis manažmentu zmeny.

8.1 Organizácia založená na údajoch

Transformácia na organizáciu založenú na údajoch je proces, ktorý si vyžaduje kultúrnu zmenu a odlišné myslenie, čo sa nedá dosiahnuť zo dňa na deň. Zahŕňa prispôbenie sa novým technológiám, procesom a pracovným postupom, čo si vyžaduje čas a úsilie. Organizácie založené na údajoch si uvedomujú, že úspech sa dosahuje iteratívne a zameriavajú sa na dlhodobé hľadisko. Tri hlavné princípy, ktoré umožňujú organizácie založené na údajoch:

1. Myslieť inak – Dátoví lídri si uvedomujú, že riadenie údajov si vyžaduje iné myslenie. To zahŕňa kritické myslenie, ľudský úsudok a zameranie na inovácie.
2. Rýchle zlyhanie, rýchlejšie učenie - Dátoví lídri chápu, že jednotlivci a organizácie sa učia prostredníctvom skúseností, čo často znamená pokusy a omyly. Organizácie, ktoré sú pripravené na rýchlejšie iteratívne učenie a rýchlo zlyhajú, rýchlejšie sa učia, získajú prehľad a vedomosti efektívne.
3. Zameranie sa na dlhodobé hľadisko - Dátoví lídri chápu transformáciu ako úsilie, ktoré sa rozvíja v priebehu času.

Napriek desaťročiu investícií a prijatiu Chief Data Officers (CDO) sa mnohým organizáciám stále nedarí stať sa riadenými údajmi kvôli kultúrnemu odporu voči zmenám. Prieskum medzi vedúcimi pracovníkmi z rebríčka Fortune 1000¹² zistil, že viac ako 90% opýtaných spoločností uviedlo kultúru ako svoju najväčšiu prekážku. Správa navrhuje, aby vedúci predstavitelia prehodnotili, ako ich organizácie zaobchádzajú s údajmi, a pamätali na to, že táto transformácia je dlhodobý proces. Prieskum tiež zistil, že firmy majú problém získať hodnotu zo svojich investícií do veľkých dát a AI, čo znižuje ich šancu stať sa organizáciami založenými na údajoch. V dôsledku týchto výziev sa počet organizácií, ktoré sa identifikujú ako organizácie založené na údajoch, za posledné roky znížil napriek rastúcim investíciám do veľkých dát a iniciatív v oblasti umelej inteligencie. Existuje celý rad možných vysvetlení zlyhania veľkých firiem pri dosahovaní cieľa stať sa organizáciami založenými na údajoch. Najväčšími výzvami, ktorým čelia bežné spoločnosti, aby sa stali organizáciami založenými na údajoch, sú kultúrne výzvy týkajúce sa:

- organizačného zosúladenia – keď zamestnanci nepovažujú rozhodovanie založené na údajoch za pokrokové alebo v ich najlepšom záujme. Zamestnanci sa môžu brániť iniciatívam založeným na údajoch, pretože sa obávajú neistoty zamestnania alebo majú pocit, že ich odborné znalosti a znalosti sú podkopané. Okrem toho môžu byť dátové projekty drahé a vyžadujú značné zdroje, čo vedie k ďalšej potenciálnej prekážke,
- biznis procesov - ak rozhodovacie procesy a biznis procesy nie sú podporované v rámci firemnej kultúry, členovia tímu sa môžu zdráhať prijať riešenia a stratégie založené na údajoch,
- komunikácie - komunikácia je dôležitá pre budovanie dôvery a porozumenia údajom v rámci organizácie, ako aj medzi jednotlivcami a tímami. Bez jasného pochopenia toho, o čo sa organizácia založená na údajoch usiluje, môžu byť akékoľvek procesy a rozhodnutia zamerané na údaje ľahko nesprávne interpretované.

¹² <https://www.businesswire.com/news/home/20210104005022/en/NewVantage-Partners-Releases-2021-Big-Data-and-AI-Executive-Survey>

-
- zručností ľudí - ak zamestnancom chýbajú potrebné zručnosti a sebadôvera potrebné na efektívne využívanie a interpretáciu údajov, podniky môžu mať ťažkosti s prechodom na organizáciu viac založenú na údajoch, a
 - odporu alebo nedostatku porozumenia na umožnenie zmeny.

Okrem toho zlyhanie niektorých významných digitálnych transformácií mohlo spôsobiť, že vedúci predstavitelia spoločností váhali s realizáciou transformačných iniciatív. Mnohí vedúci pracovníci podnikov vyjadrili frustráciu z nedostatku agility zo strany technologických firiem a ich produktov, ktoré používajú. Dalším možným dôvodom je, že organizácie sa príliš zameriavajú na technológie ako prvý krok k tomu, aby sa stali orientovanými na údaje, bez toho, aby sa primerane zaoberali ľudskou stránkou údajov. Organizácie musia prehodnotiť spôsoby, akými uvažujú o údajoch ako o obchodnom aktíve, a zamerať svoje iniciatívy v oblasti údajov na jasne identifikované problémy s veľkým vplyvom. Transformácia organizácie na organizáciu založenú na údajoch je dlhodobý proces, ktorý si vyžaduje trpezlivosť a statočnosť a organizácie, ktorá sa nesmie vzdať úsilia, keď sa výsledky nedostavia okamžite.

8.2 Organizačné zmeny

Odporúčame nasledujúce zmeny modernizácie organizačnej štruktúry pre realizáciu zmeny a dátovej transformácie:

- Odborné sekcie by mali byť orientované na riešenie problémov a hľadanie agilných riešení. V praxi to znamená posun výkonu verejnej moci smerom k regulácií 2.0, teda sledovanie merateľných ukazovateľov v online čase a zmenu s tým súvisiacich postupov na metodologickej úrovni.
- Odporúčame vytvoriť analytickú jednotku. Takéto jednotky sú už takmer na všetkých ministerstvách a ukazuje sa, že sú kľúčové pre správny návrh politík a stratégií. Ide však len o prvý krok. Funkčnú analytickú jednotku je vhodné doplniť Implementačnou jednotkou (takzvaná "Delivery unit") pre zabezpečenie vhodnej a včasnej realizácie navrhnutých opatrení a politík a inovačnou jednotkou, ktorá dokáže realizovať experimenty v praxi a zistiť, čo naozaj funguje a prečo. Verejná správa tak môže prejsť od ideologického návrhu politík k pragmatickejšiemu a empirickejšiemu prístupu.
- Pre manažment dátovej transformácie je nutné posilniť schopnosti v oblasti dát, ideálne keď vznikne interná dátová kancelária s jasne definovanou a silnou rolou CDO - "Chief Data Officer". Dátová kancelária by mala manažovať transformáciu jednotlivých procesov pomocou podpory dátovými nástrojmi, ale i zabezpečenie samotných dát, ktoré sú palivom. Dátová kancelária tak bude poskytovať riešenia na mieru ostatným organizačným útvarom.

Aby boli tieto zmeny rozpočtovo neutrálne, je nutné šetriť priamo na výkone agendy a podporných činnostiach. Dobrou správou je, že dátová transformácia umožňuje výrazne znížiť nároky na personál pre veľké množstvo procesov, keďže inteligentné algoritmy do istej miery slúžia ako substitúcia kognitívnej práce, ale i ako komplementárne doplnenie schopností používateľov. Môžeme tak hovoriť o vzniku nových superúradníkov vybavených podporou dátových algoritmov. V princípe si však nemyslíme, že pôjde o jeden typ posunu kompetencií pri práci úradníka ale definujeme štyri základné kariérne smery, ktorými sa môžu pracovníci vo verejnej správe vydať:

- Osobný poradca - dôraz na ľudské vnímanie situácie a empatiu - úradník bude pomáhať klientom riešiť ich životné situácie ako poradca schopný hľadať efektívne a personalizované riešenia na mieru,
- Dátový expert - dôraz na spracovanie dát - úradník bude monitorovať situáciu a odporúčať preventívne opatrenia na jej zlepšenie respektíve reagovať v prípade krízy,
- Praktik - dôraz na kolaboráciu, flexibilitu a participáciu - úradník sa bude venovať organizovaniu a interakcii s veľkým množstvom účastníkov a záujmov,

-
- Expert - špičkový odborník, ktorý dokáže poskytovať podklady pre ďalšie rozhodovanie a využívať pomoc algoritmov.

Pri transformácii inštitúcie verejnej správy je potrebné premyslieť základné organizačné delenie a ich funkcie. Pri tomto návrhu uvažujeme o troch základných funkciách organizácie vo verejnej správe.

- **Návrh politík a regulácií:** predstavuje základnú úlohu medzi problémami v rámci spoločnosti a hospodárstva, ktoré je potrebné riešiť v rámci výkonu verejnej moci. V rámci tejto funkcie sa navrhujú opatrenia a ich parametre a definujú pravidlá pre účastníkov trhu respektíve občanov. Najdôležitejšie je definovať a zaviesť také pravidlá, ktoré fungujú, to znamená prinášajú pozitívnu zmenu podľa mandátu inštitúcie.
- **Implementácia zmien a dynamické riadenie:** zlepšenie výkonu verejnej správy a efektívnejšia implementácia politík si vyžaduje schopnosť dosiahnuť reálne výsledky, ako i neustále hľadanie a implementáciu vhodných nástrojov. Implementácia zmien musí fungovať dynamicky a agilne, pričom za hlavné schopnosti, ktoré je potrebné rozvinúť je možné považovať: zabezpečenie dátových tokov a experimentovanie (aby bolo možné nájsť riešenie, ktoré funguje najlepšie v praxi).
- **Prevádzka a výkon agentúry:** znamená v prvom rade maximálnu automatizáciu činností, kde je to možné (napríklad back-office, samoobslužné služby), zavádzanie asistentov pri rozhodovaní a posudzovaní (napríklad zhody s predpismi). Zároveň je možné časť zamestnancov preorientovať na iný typ úloh: poradenstvo pre občanov a podnikateľov a organizovanie zapojenia občianskej spoločnosti.

8.2.1 Návrh politík a regulácií

Je vhodné, aby inštitúcia verejnej správy bola organizovaná spôsobom, ktorý umožní jasné rozdelenie zodpovednosti za oblasti výkonu verejnej moci. Preto základnú regulačnú funkciu by mali stále realizovať odborné sekcie, ktoré by mali byť doplnené analytickou jednotkou, ktorá im

Odborné sekcie

- Zodpovedajú za realizáciu jednotlivých politík a výkon mandátu.
- Každá odborná sekcia by mala mať nastavené správne merateľné ukazovatele pre výsledky a výstupy.
- Je potrebné, aby fungovali na princípoch "Data-driven state": navrhovali politiky na základe faktov a dôkazov, potrebujú mať k dispozícii dátové modely, ktoré v reálnom čase znázorňujú vývoj predmetnej oblasti.
- Odborné sekcie sú biznis vlastníkami rozvojových projektov a na základe výsledkov experimentov vydávajú metodické usmernenia pre výkon verejnej moci.
- Odborné sekcie navrhujú stratégiu pre výkon verejnej moci a zodpovedajú sa realizáciu reforiem.
- Odborné sekcia priamo zodpovedajú prípadnej politickej úrovni.

Analytická jednotka

- "Interný think-tank", ktorý dokáže vypočítať náklady a prínosy jednotlivých politík a ponúknuť nezávislý pohľad oproti odborným sekciam (ktoré môžu byť príliš angažované v jednotlivých politikách).
- Zodpovedá za monitoring a výpočet kľúčových výkonnostných ukazovateľov.

-
- Zodpovedá za prognózy budúceho vývoja.
 - Radí pri návrhu stratégie pre reformu danej oblasti-
 - Radí pri návrhu nových opatrení (na základe najlepšej skúsenosti zo zahraničia).

8.2.2 Implementácia zmien a dynamické riadenie

Inštitúcia verejnej správy musí vedieť fungovať v dynamickom prostredí a reagovať na zmeny, politické priority, nové hrozby a príležitosti a neustále zvyšovať kvalitu poskytovaných služieb. Práve dynamický aspekt realizácie reforiem verejnej správy si vyžaduje najväčšie zmeny v organizácii inštitúcie verejnej správy. Navrhujeme rozdeliť tradičné oddelenie a vytvoriť špecializované, na misiu zamerané jednotky, ktoré pomôžu s praktickou realizáciou digitálnej transformácie:

- Dátová kancelária ako hlavný realizátor dátových inovácií.
- Inovačné laboratórium pre skúšanie nových technológií a realizáciu experimentov.
- Dizajn digitálnych služieb pre zavedenie užívateľskej prívetivosti.
- Implementačná jednotka posilní dohľad nad realizáciou navrhovaných opatrení.

Dátová kancelária a monitoring

- Základ výkonu verejnej moci bude v budúcnosti postavený na dátach a ich využití v praxi. Preto zriadenie Dátovej kancelárie predstavuje zásadnú organizačnú inováciu, ktorú dokáže previesť inštitúcia do 21. storočia.
- Hlavnou úlohou Dátovej kancelárie bude nastaviť toky dát v rámci organizácie (vrátane jednotlivých aspektov dátovej politiky, ako je kvalita údajov, publikovanie otvorených údajov a podobne).
- Odporúčame zriadiť rolu Chief Data Officer a posilniť úlohu Dátového kurátora.
- Dátová kancelária pomáha pri identifikácii oblastí, kde sa môžu použiť dátové inovácie, dátovú vedu a modely (podpora rozhodovania, automatizácia), navrhuje a realizuje ich využitie. V prípade, že sa riešenie osvedčí, môže byť prevádzkované v rámci IT.
- Dátová kancelária spravuje prístup k dátovým zdrojom.

Inovačné laboratórium pre riešenie problémov

- Inovačné laboratórium slúži na praktické overovanie navrhovaných politík (napríklad formou regulačných "sandboxov" alebo realizáciou RCT a behaviorálnych intervencií).

Dizajn digitálnych služieb (behaviorálne inovácie)

- Ak inštitúcia poskytuje digitálne služby, je vhodné venovať zvýšenú pozornosť ich dizajnu a návrhu v súlade s používateľskou prívetivosťou.
- Odporúčame zriadiť pozíciu hlavného dizajnéra služieb, ktorý bude mať na starosti obsah a formu digitálnych služieb tak, aby v maximálnej miere dokázali pomáhať s dosahovaním cieľov príslušných politík.
- Jednotka dizajnu digitálnych služieb zodpovedá za implementáciu Jednotného dizajnu manuálu a za kontinuálne zlepšovanie digitálnych služieb.

Implementačná jednotka

- Implementačná jednotka dohliada nad realizáciou navrhovaných opatrení (zmeny verejných politík, reformy, implementácie informačných systémov a technológií).
- Odporúčame organizovať implementačnú jednotku ako programovú kanceláriu (pre plánované reformy).

8.2.3 Prevádzka a výkon agendy

Výkon agendy je tradične chápaná ako priamy výkon verejnej moci, ktorý sa dotýka zainteresovaných subjektov, ako občania a podnikatelia. Pod výkonom agendy chápeme riešenie správnych konaní pri základných službách štátu, ako je vedenie evidencií, poskytovanie nárokov (napríklad sociálnej podpory) alebo výber daní. Každá agenda spadá vždy pod jednu inštitúciu. Pod prevádzkou chápeme najmä zabezpečenie podporných funkcií, ako je účtovníctvo, prevádzku IT alebo riadenie ľudských zdrojov.

Výkon agendy

Dnešný stav výkonu agendy vo verejnej správe môžeme vo všeobecnosti označiť ako zastaralý. Ak sa používajú IT systémy, tak vo veľkej miere ako transakčné a evidenčné systémy. Ponuka verejných služieb sa vyznačuje vysokou administratívnou záťažou. Základný problém pri výkone agendy je, že proces je nastavený pre takzvané obdobie informačného nedostatku a základná idea spočíva v rámci konania získať všetky potrebné dokumenty, založiť ich do spisu a na základe pravidiel a pozbieraných vstupov vykonávať kvalifikované rozhodnutie, napríklad pri stavebnom konaní. Navrhujeme tri základné opatrenia, ktoré dokážu prispôsobiť výkon agendy súčasným možnostiam:

- Automatizovaná obsluha: podľa vzoru súkromných služieb (napríklad nákup leteniek) je možné veľkú časť procesov automatizovať (na úrovni "front-office" aj "back-office"), napríklad digitálne služby by mali byť založené na samoobsluže pre jednoduché situácie (presťahovanie, vybavenie dávky v nezamestnanosti, vybavenie prídavkov na dieťa, vyplnenie daňového priznania). Ideálne je využitie technológií chatbotov.
- Riešenie expertných úloh a prípadov: pri riešení jednotlivých prípadov sa dá tiež výrazne lepšie zvýšiť efektivita intervencií, napríklad vďaka zavedeniu predikčných algoritmov pre odhaľovanie podvodov alebo budúcich problémov. V prípade komplikovaných povolení a rozhodnutí je možné posúdiť žiadosť akým spôsobom spĺňa požadované štandardy. V prípade skúmania veľkých dát o nejakej oblasti (napríklad úrovni hygieny) je možné odbúrať administratívne povinnosti a sústrediť sa na preventívne opatrenia.
- Odborné poradenstvo: každý občan alebo podnikateľ, ktorý rieši svoju životnú situáciu by mal získať partnera, ktorý mu pomáha v jeho probléme.

Navrhované zmeny vo výkone agendy povedú k zníženiu potreby po ľudských zdrojoch a ich substitúciou inteligentnými algoritmi. Ušetrené zdroje je možné investovať práve do budovania zmenových kancelárií a jednotiek. Základné odporúčané opatrenie pre výkon agendy sú:

- Automatizácia obslužných činností a vytvorenie špecializovaného front-office vo forme klientskeho centra.
- Zriadenie poradenského centra pre významné skupiny klientov - posun úradníkov do role konzultantov životných situácií.
- Automatizácia evidenčných činností - a centralizácia evidenčných činností.
- Integrácia odborných algoritmov do práce expertov (v spolupráci s Dátovou kanceláriou), vytvorenie regionálnych centier excelencie.

Prevádzka

Prevádzkové činnosti nesúvisia priamo s realizáciou cieľov a mandátu organizácie, ale pomáhajú zabezpečovať základnú funkčnosť. Je potrebné tieto činnosti organizovať tak, aby bolo možné efektívne využívať zdroje a využiť optimalizačné algoritmy.

V prípade prevádzky máme nasledujúce odporúčania:

- V maximálnej miere automatizovať a centralizovať podporné činnosti (ako je účtovníctvo a verejné obstarávanie).
- S HR oddelenia odčleniť Manažment kvality ľudských zdrojov.

9 Použitá literatura

Artificial Intelligence Risks and Algorithmic Regulation, Pedro Rubim Borges Fortes, Pablo Marcello Baquero and David Restrepo Amariles, *European Journal of Risk Regulation* (2022), 357-372

Algorithmic Regulation, K. Yeung and M. Lodge, Oxford University Press (2019)

Algorithmic Regulation: A Critical Interrogation, K. Yeung, *Legal Studies Research Paper Series* (2017)

L. Ulbricht and K. Yeung, Algorithmic Regulation: A maturing Concept for Investigating Regulation of a through Algorithms (2022) 16(1) *Regulation & Governance*

Fair Transparent and Accountable Algorithmic Decision-making Process, Lepri, Oliver, Letuozé, Pentland & Vinck, *Philosophy & Technology* (2018)

The Legitimacy Gap of Algorithmic Decision-making Process in the Public Sector: Why it arises and how to address it, König & Wenzelburger, *Technology in Society* (2021)

Uncertainty, Risk and the Use of Algorithms in Policy Decisions, A case study on Criminal Justice in the US, Hartmann & Wenzelburger (2020)

A Theory of Justice, J. Rawls (1999)