

Analýza a návrh možností výskumu, vývoja a aplikácie umelej inteligencie na Slovensku

Dielo č. 2 – Manuál pre firmy na zavedenie umelej
inteligencie

11. december 2019

Analýza a návrh možností výskumu, vývoja a aplikácie umelej inteligencie na Slovensku

Dielo č. 2 – Manuál pre firmy na zavedenie umelej inteligencie

Autori zo Slovenskej technickej univerzity v Bratislave:

Mária Bieliková, Michal Kompan, Martin Labaj, Peter Lacko, Zdenka Lenartová, Róbert Móro, Viera Rozinajová, Jakub Ševcech

Zástupcovia odbornej verejnosti, ktorí sa podieľali na posudzovaní jednotlivých výstupov:

Roman Behúl, Juraj Bezděk, Martin Drobný, Emil Fitoš, Gabriel Fedorko, Andrej Greguš, Pavol Halpert, Lukáš Hatala, Dalibor Kačmář, Tomáš Koctúr, Ivo Kovačič, Pavol Kubán, Mário Lelovský, Stanislav Levársky, Daniel Minárik, Milan Oselský, Michal Papučík, Karol Stračár, Erich Šašinka, Marek Šebo, Filip Vittek, Petra Zappe, členovia Spolku pre spoločenské a etické dopady IT E-tika

Technická a organizačná podpora:

Jitka Božíková, Juraj Kadáš, Branislav Pecher, Andrej Vitek

Tento manuál bol vypracovaný pre Úrad podpredsedu vlády SR pre investície a informatizáciu autorským kolektívom zo Slovenskej technickej univerzity v Bratislave na základe Zmluvy o dielo č. 1024/2019 zo dňa 29. 10. 2019. Počas tvorby tejto štúdie boli jednotlivé výstupy posudzované expertným tímom združeným pod Slovenským centrom pre výskum umelej inteligencie – Slovak.AI, ktorého členom je aj Slovenská technická univerzita v Bratislave. Všetky závery a komentáre v správe odzrkadľujú názory a postoje autorského kolektívu, ktoré sa opierajú o výsledky analýz opísaných v správe a o diskusie s odborníkmi na problematiku umelej inteligencie spolupracujúcimi na tejto správe. Všetky údaje v tejto správe, ak nie je uvedené inak, sú aktuálne k dátumu odovzdania správy.

© 2019 Slovenská technická univerzita v Bratislave, Úrad podpredsedu vlády SR pre investície a informatizáciu. Všetky práva vyhradené.

Celé dielo alebo akákoľvek jeho časť nemôžu byť použité, zverejnené alebo ďalej šírené bez predchádzajúceho písomného súhlasu vlastníkov diela.

Obsah

1 Manažérske zhrnutie	V
2 Analýza aktuálneho stavu nasadzovania umelej inteligencie v podnikoch v Slovenskej republike .1	
2.1 Index digitálnej ekonomiky a spoločnosti 2019 – správa o Slovensku	1
2.2 Prieskum o umelej inteligencii na Slovensku	1
3 Analýza dopadov robotizácie a automatizácie na trh práce	9
3.1 Národné stratégie a súvisiace dokumenty	10
3.1.1 Koncepcia inteligentného priemyslu pre Slovensko	10
3.1.2 Akčný plán inteligentného priemyslu SR 2018 – 2020.....	11
3.1.3 Stratégia digitálnej transformácie Slovenska 2030.....	13
3.1.4 Akčný plán digitálnej transformácie SR na roky 2019 – 2022.....	14
4 Zavedenie umelej inteligencie vo firmách	17
4.1 Všeobecné pojmy a typy umelej inteligencie'	17
4.1.1 Hlavné charakteristiky umelej inteligencie	17
4.2 Prostriedky umelej inteligencie'	18
4.2.1 Neurónové siete.....	19
4.2.2 Strojové učenie	19
4.2.3 Fuzzy logika	19
4.2.4 Genetické algoritmy – genetické programovanie.....	20
4.2.5 Expertné systémy	20
4.3 Prínosy a postupy zavedenia umelej inteligencie	20
4.3.1 Hlavné impulzy pre zavedenie umelej inteligencie.....	20
4.3.2 Voľba pilotných projektov.....	21
4.3.3 Zloženie tímu.....	21
4.3.4 Harmonogram pilotného projektu.....	22
4.4 Predpoklady pre zavedenie umelej inteligencie v podnikoch'	23
4.5 Domény, v ktorých sa umelá inteligencia nasadzuje do praxe	25
4.6 Doménovo orientované príklady, predpoklady nasadenia a prínosy	28
4.6.1 Optimalizácia výroby.....	28
4.6.2 Riadenie kvality, výstupná a laboratórna kontrola a analýza	31
4.6.3 Prediktívna údržba	36
4.6.4 Inteligentná automatizácia nevýrobných procesov.....	42
4.6.5 Energetický manažment	46
4.6.6 Marketing a podpora predaja	55
4.6.7 Online predaj	63
4.6.8 Podpora zákazníkov a používateľov	67

5 Zodpovedný prístup k umelej inteligencii.....	73
5.1 Etická stránka umelej inteligencie.....	73
5.2 Etické a právne riziká.....	73
5.3 Implementačné a prevádzkové riziká.....	74
6 Odporúčania na podporu nasadzovania umelej inteligencie v slovenských podmienkach	77
6.1 Odporúčania pre hospodársku politiku a riadenie inovácií	77
6.1.1 Excelentnosť a inteligentná špecializácia.....	77
6.1.2 Diverzifikácia priemyselnej výroby	79
6.2 Potenciál umelej inteligencie v strategických hospodárskych oblastiach	81
6.2.1 Kybernetická bezpečnosť.....	81
6.2.2 Zdravotníctvo	82
6.2.3 Poľnohospodárstvo.....	83
6.2.4 Verejná správa	84
6.2.5 Životné prostredie, ochrana klímy a energetika	85
6.2.6 Ďalšie oblasti, ktoré majú potenciál na zavedenie umelej inteligencie.....	86
6.2.7 Umelá inteligencia vo vnorených systémoch	87
6.3 Odporúčania pre oblasť ľudských zdrojov.....	88
6.4 Odporúčania pre operačné programy a partnerskú dohodu	95
Príloha 1 Príklady riešení umelej inteligencie implementovaných autormi štúdie	103
A. Kooperácia medzi firmami	103
B. Analýza porúch pomocou umelej inteligencie	106
C. Anonymizovaný príklad (marketing a podpora predaja)	114
D. Anonymizovaný príklad (podpora predaja, reporting)	116
E. Anonymizovaný príklad (marketing)	119
Príloha 2 Zoznam expertov a externých konzultantov	131
Príloha 3 Metodika dotazníkového prieskumu.....	133

1 Manažérske zhrnutie

Technologický pokrok ruší zabehané paradigmy myslenia, mení spôsob nakupovania, stravovania, práce, komunikácie a zábavy. Tradičné štruktúry, o ktoré sa opiera naša spoločnosť a hospodárstvo, sa menia. Slovenská ekonomika nie je výnimkou a stojí pred výzvou zásadnej transformačnej zmeny.

V čase koexistencie prvkov tradičnej industriálnej a novej, tzv. digitálnej a internetovej ekonomiky ako aj spoločnosti, stojíme jednou nohou v minulosti a druhou v budúcnosti. Je to čas víťazov a porazených. Firiem a ľudí so žiadanými novými technológiami, zručnosťami a myslením. Ale aj tými, ktorí nedokážu držať krok s vývojom a svoje doterajšie pozície strácajú.

Slovensko v záujme svojej budúcej prosperity musí pokračovať vo využívaní najmodernejších strategických technológií ako je umelá inteligencia, ale súčasne podporovať a participovať na ich ďalšom vývoji.

Autori dokumentu si s plnou vážnosťou uvedomujú obrovský potenciál, konkurenčnú výhodu a pozitívne prínosy, ktoré umelá inteligencia (ďalej aj „AI“) znamená pre našu krajinu a spoločnosť, ale samozrejme aj s ňou spojené možné riziká. S týmto vedomím zodpovedne pristúpili k tvorbe predkladaného dokumentu.

Dokument má splniť dva hlavné ciele: **prvým cieľom** je vytvoriť manuál pre zavedenie AI, ktorý má pomôcť slovenským firmám zvýšiť ich konkurencieschopnosť vďaka využívaniu umelej inteligencie. **Druhou ambíciou** je načrtnúť oblasti s najväčším potenciálom pre vývoj, výskum a aplikáciu riešení AI, ktoré by zo Slovenska vytvorili modelovú krajinu disruptívnych (prelomových) *hi-tech* riešení v danej oblasti.

Cieľ č. 1:

Manuál predstavuje návod na použitie umelej inteligencie v podnikaní na našej lokálnej úrovni. Opisuje technológie, ktoré sú už k dispozícii a ich možnosti využitia za účelom ich pretavenia do konkurenčnej výhody. Opisuje reálne situácie a možnosti pre firmy. Cieľom bolo poskytnúť firmám praktický návod, ako uchopiť zavedenie umelej inteligencie v komerčnom sektore. Nejde o aktuálny stav teoretických vedeckých poznatkov o umelej inteligencii, ale o niečo, čo je dostupné už tu a teraz. Týmto prístupom berieme do úvahy primárny cieľ: zvýšiť konkurencieschopnosť slovenských firiem.

Kľúčové odporúčania pre Cieľ č. 1:

Manuál je užitočným nástrojom, ktorý umožní slovenským firmám začať s prvými krokmi smerom k zavedeniu umelej inteligencie do oblastí, ktoré vyhodnotia ako kľúčové. Z praktických dôvodov je žiaduce, aby bol osvetový charakter manuálu podporený aj dostupnosťou informácií o možných partneroch a riešiteľoch. Spôsob akým sa manuál a doplňujúce informácie budú šíriť, by mal smerovať k čo najväčšiemu pokrytiu cieľových firiem takými kanálmi, ktoré sú im blízke. Poznatky, riešenia a spoločnosti pôsobiace v oblasti umelej inteligencie sa stále menia. Bude to treba zohľadniť jednak pri výbere distribučných kanálov, ako aj pri režime dopĺňania a inovovania obsahu. Odporúčania sú určené pre subjekty zabezpečujúce riadenie inovácií na Slovensku.

Hodnota, ktorú AI ponúka, je nespochybniteľná a nepredstavuje módnú záležitosť. AI dokáže zlepšiť reálne produkty a procesy, pomôže robiť lepšie informované rozhodnutia a súčasne vykonávať dôležité, aj keď do veľkej miery neviditeľné, úlohy.

Technológie AI majú potenciál rozšíriť a vylepšiť schopnosti zamestnancov prostredníctvom inteligentných strojov. Pri tejto zmene je dôležitá etická stránka. Schopnosť AI dopĺňať, ovplyvňovať či nahrádzať ľudské chápanie a rozhodovanie prináša množstvo spoločenských otázok. A z toho vyplývajúcej obáv, napr. zo straty zamestnania. Tieto by nemali byť brzdou pre ďalší vývoj AI a jej zavádzanie, ale skôr by mali byť prítomné pri rozhodovaní a využívaní potenciálu AI.

Systémy s prvkami AI už dnes automatizujú štruktúrovanú a opakovateľnú prácu, poskytujú rozsiahlu analýzu údajov prostredníctvom strojového učenia a komunikujú so zákazníkmi a zamestnancami prostredníctvom inteligentných agentov.

Aj slovenské firmy musia experimentovať s týmito technológiami a rozvíjať svoje vlastné odborné znalosti a akumulovať skúsenosti. Tento návod poskytuje neoceniteľného sprievodcu skutočnou AI v reálnom svete.

Cieľ č. 2:

Autori súčasne považujú za nutné zdôrazniť, že obmedzené zdroje slovenskej spoločnosti pre maximalizáciu pozitívnych prínosov AI technológií vytvárajú potrebu definovania limitovaného počtu strategických priorít v oblasti výskumu umelej inteligencie.

Kľúčové odporúčanie pre Cieľ č. 2:

Je potrebné zriadiť komunitu odborníkov z praxe, výskumníkov, stratégov a politických predstaviteľov, ktorí dokážu nájsť potrebnú zhodu na zadefinovanie prioritných oblastí excelencie vychádzajúcej z pridanej hodnoty prírodného a ľudského kapitálu SR, priemyselnej a kultúrnej tradície a globálnych trendov. Odporúčanie je určené pre subjekty, ktoré zodpovedajú za výskum a vývoj, hospodársku politiku a riadenie inovácií.

Dielo sa začína prieskumom stavu umelej inteligencie na Slovensku ([Kapitola 2](#)). Z jeho výsledkov vyplýva, že vytvorenie manuálu je správnym krokom, dopyt po praktických informáciách je jasne zdokumentovaný. Prieskum indikuje, že respondenti vidia najväčší potenciál pre využitie AI v zdravotníctve, doprave, výrobnom priemysle, finančných inštitúciách či v marketingu a predaji. Z nami mapovaných domén využitia AI v priemysle majú respondenti najväčší záujem o inteligentnú procesnú automatizáciu, marketing a retail, inteligentné chatboty a online predaj.

V [Kapitole 3](#) s názvom *Analýza dopadov robotizácie a automatizácie na trh práce* sa venujeme ľudským zdrojom. Tento širší pohľad má svoj význam. Digitálna transformácia – čiže implementácia digitálnych technológií do rozličných odvetví – bude čím ďalej tým viac postavená na nástrojoch umelej inteligencie. Budeme potrebovať kvalifikovaných ľudí nielen v pri vývoji týchto nástrojov, ale aj pri hľadaní vhodných oblastí pre jej nasadzovanie, samotnej implementácie a tiež pri jej k zmysluplnom využívaní.

Ak si položíme otázku, či dnes majú firmy k dispozícii ľudí, ktorých by mohli alokovať na implementáciu nových projektov, odpoveď znie, že len v minimálnom množstve. Narážame na všeobecný nedostatok kvalifikovaných ľudí v priemysle a tento problém sa dá riešiť iba súborom komplexných opatrení, ktoré musia zahŕňať riešenia v oblasti inštitucionálneho vzdelávania, celoživotného vzdelávania, ale aj importom talentov zo zahraničia.

Jadrom tohto dokumentu je [Kapitola 4](#), ktorá je napísaná tak, aby sa jednoduchým preformátovaním dala zmeniť na *Manuál pre zavedenie umelej inteligencie vo firmách*. Manuál bude použiteľný pre malé a stredné podniky, ktoré majú záujem vyriešiť konkrétne problémy.

Praktický prístup nás viedol k tomu, aby sme opísali riešenia pre osem rozličných typov problémov alebo domén, pre ktoré je k dispozícii vždy iná skupina odporúčaní:

- Optimalizácia výroby;
- Riadenie kvality, výstupná a laboratórna kontrola a analýzy;
- Prediktívna údržba;
- Inteligentná automatizácia nevýrobných procesov;
- Energetický manažment;
- Marketing a podpora predaja;
- Online predaj;
- Podpora zákazníkov a používateľov.

Manuál bude k dispozícii na stránke [Úradu podpredsedu vlády SR pre investície a informatizáciu](#), ako aj na stránke Slovenského centra pre výskum umelej inteligencie – [slovak.AI](#), prípadne na ďalších portáloch inštitúcií, ktoré sa venujú rozvoju umelej inteligencie na Slovensku, ako aj na účely širšej podpory digitálnych technológií. Aby sa výstupy manuálu dostali k cieľovej skupine výrobných a spracovateľských podnikov, štruktúrované informácie z manuálu budú publikované aj na portáli výrobnéj kooperácie [www.spolupracuj.me](#). Na ňom budú informatívne podklady doplnené a rozšírené aj o ponuky IT spoločností, ktoré disponujú riešeniami, kompetenciami a expertmi na umelú inteligenciu. Zároveň by sa manuál mal dostať aj do akademickej sféry, aby motivoval k výskumu a následnému transferu znalostí do priemyslu – aj prostredníctvom slovenského Centra excelentnosti pre umelú inteligenciu, ktoré je súčasťou Akčného plánu digitálnej transformácie Slovenska na roky 2019 – 2022 vypracovaným Úradom podpredsedu vlády SR pre investície a informatizáciu a schválený vládou SR. Predstavenie manuálu odbornej verejnosti (firmám) bude podporené propagačnými akciami, workshopmi a ďalšími propagačnými nástrojmi.

Pre každú z ôsmich domén zovšeobecňujeme predpoklady pre zavedenie AI. V podstate ide o otázky, ktoré by si firma mala položiť ešte predtým, než sa rozhodne pre konkrétny postup a s ním súvisiace časové a finančné investície. Čo by si teda mala firma vopred vyjasniť?

- **Proces**, ktorý chce firma zaviesť, transformovať alebo optimalizovať;
- **Dáta**, ktorých existencia a dostupnosť je podmienkou pre nasadzovanie AI riešenia;
- **Aplikácie**, buď ktoré sú zdrojové alebo naopak cieľové pre *end-to-end* proces, a na ktoré sa bude treba integrovať;
- **Infraštruktúra**, ktorú bude firma potrebovať, myslené sú predovšetkým koncové zariadenia potrebné pre zber dát, senzory, ale aj výpočtový výkon, ak hrá v danom riešení rolu;
- **Ľudia**, ktorých bude treba alokovať po dobu implementácie na práce na zadaní pre riešiteľov, na asistovanie v prípade učiacich sa systémov a pri prevádzke nasadeného riešenia;
- **Organizačné opatrenia**, ktoré bude potrebné prijať, vytvorenie dočasných alebo trvalých tímov, zmena kompetenčného modelu, prípadná externalizácia či *curve-out* služby či procesu.

[Kapitola 5](#) rozoberá riziká spojené s využívaním umelej inteligencie. Hovorí jednak o všeobecne platných etických otázkach a následne zovšeobecňuje riziká identifikované v [Kapitole 4](#) pri jednotlivých doménach nasadenia AI.

[Kapitola 6](#) má odporúčací charakter a nazerá na strategický potenciál umelej inteligencie. Snažíme sa identifikovať priestor, v ktorom môže Slovensko v budúcnosti dosiahnuť excelentnosť. Excelentnosťou rozumieme aplikovanie výsledkov výskumu a vývoja do úspešných inovácií, pričom meradlom úspešnosti je primárne ekonomická návratnosť vložených prostriedkov. Treba otvorene povedať, že tu modelujeme proces, ktorý na iných kontinentoch zabezpečuje rizikový kapitál. Aby sme dokázali správne alokovať zdroje, musíme brať do úvahy aspoň nasledovné faktory:

- **Ľudské zdroje.** Prítomnosť odborníkov schopných vyvíjať a inovovať, pričom inováciou rozumieme úspešné nasadzovanie riešenia v praxi;
- **Rastový potenciál.** Čím viac firiem sa bude chcieť profilovať v danej doméne, tým väčšia je šanca, že z nej urobíme kompetitívnu výhodu Slovenska;
- **Kontinuálna spätná väzba.** Túto spätnú väzbu musí poskytnúť trh. Tak ako nie je zmysluplný aplikovaný výskum, ktorého výsledky nikto neaplikuje, nejestvuje ani úspešná inovácia, ktorá nemá svojich odberateľov a zákazníkov;
- **Škálovateľnosť.** Ak bude mať riešenie potenciál, skôr či neskôr sa oň budú zaujímať technologickí investori. Ich vstup je žiaduci a je v záujme expanzie. Pravidlá financovania tomuto nesmú brániť, naopak, musia to podporovať;
- **Ochrana pred *brain drainom*.** Úspešným riešiteľom môže byť aj startup, *spin-off* z univerzity alebo inej firmy. Pravidlá narábania s verejnými zdrojmi by mali zabezpečiť, aby sa pridaná hodnota čo najdlhšie vytvárala na Slovensku.

Podkapitoly [6.3](#) a [6.4](#) majú charakter praktických odporúčaní pre oblasť riadenia inovácií, ľudských zdrojov a pre prípravu operačných programov v období 2021 – 2027¹.

¹ Príkladom, z ktorého si aj Slovensko môže zobrať ponaučenie, môže byť americký štát Michigan. Nachádza sa v ňom Detroit, niekdajšie štvrté najväčšie mesto Spojených štátov. Michigan sa podobá Slovensku predovšetkým podielom automobilového priemyslu na celkovom hospodárstve štátu. Slovensko sa preto často označovalo aj ako „Detroit Európy“. Tri najväčšie americké automobilky – Ford, General Motors a Chrysler – sídlia v Detroite.

Úpadok regiónu sa tu začal prejavovať už od 70. rokov 20. storočia. Počas ekonomickej recesie v rokoch 2009 až 2010 došlo viac-menej ku kolapsu výroby. General Motors a Chrysler zbankrotovali a Chrysler bol prevzatý európskym koncernom FIAT. V roku 2013 skrachovalo aj samotné mesto Detroit a ocitlo sa pod nútenou správou.

Medzičasom však v štáte a v priemyselnej výrobe došlo v rokoch 2011 až 2019 k zmene trendu. Michigan sa zameral na niekoľko politík, ktoré mu pomohli zvrátiť smerovanie ku katastrofe. Výsledky sa dajú demonštrovať na vývoji nezamestnanosti. V Detroite nezamestnanosť klesla z 13 % (2011) na 4,1 % (september 2019), v štáte Michigan za rovnaké obdobie nezamestnanosť klesla z 10,6 % na 4,2%.

Opatrenia, vďaka ktorým sa podarilo dosiahnuť zmenu:

- Diverzifikácia výroby. Podiel automobilového priemyslu na celkovej priemyselnej výrobe v Michigane je zhruba polovičný oproti roku 2011. Rastúcimi sektormi sú dodávky pre letectvo, obranu, kybernetickú bezpečnosť, mobilitu a predovšetkým pokročilá výroba (advanced manufacturing), v ktorej je dominantným technologickým trendom aditívna výroba, čiže využívanie 3D tlače;
- Dane a regulácie. V rámci vnútorného trhu sú z dlhodobého hľadiska konkurenčnou hrozbou pre stále veľmi významný michiganský automobilový priemysel, predovšetkým autonómne vozidlá a elektromobily, za ktorými stojí silný kapitál zo Silicon Valley. Pre Michigan je preto strategickou otázkou prilákanie týchto investorov do svojho geografického priestoru. Na to slúžia celkovo nízko nastavené daňové hladiny, daňové stimuly a regulácie, ktoré by za žiadnych okolností nemali ísť nad rámec toho, čo sa požaduje na federálnej úrovni;

V [Prílohe 1](#) sú uvedené konkrétne príklady nasadenia AI u zákazníkov. Podrobnosť informácií je limitovaná povoleniami na zverejňovanie, ktoré sa riešiteľom podarilo získať. Vo väčšine prípadov totiž platí, že technické a ekonomické parametre inovatívneho projektu sú predmetom obchodného tajomstva.

-
- Ľudský kapitál. Michigan prostredníctvom niekoľkých programov investuje do rozvoja STEM vzdelávania (STEM = vedecké, technické, inžinierske predmety a matematika). Od roku 2011 počet študentov informatických a technických odborov vzrástol o 50 %. K tomu treba prirábať opatrenia v oblasti realitného trhu, ktorý pred desiatimi rokmi prešiel rovnako ťažkou krízou;
 - Energetika. Michigan urobil veľa pre zníženie cien energií, ale aj pre to, aby energetická náročnosť výroby trvalo klesala. Robí opatrenia pre pokles spotreby uhľovodíkových palív a podporuje rozvoj obnoviteľných zdrojov;
 - Doprava. Štát investuje do opráv a údržby cestnej siete, ako aj do železničnej a vodnej dopravy, pričom aktívne vyhľadáva verejno-súkromné partnerstvá (PPP);
 - Industry 4.0. Firmy v Michigane prechádzajú intenzívnou digitálnou transformáciou. Kľúčovými pojmami sú inteligentný internet vecí (IIoT), umelá inteligencia a cloud.

Príklad Michiganu je vhodné brať do úvahy v kontexte ponúkaných návrhov v tomto dokumente pre elimináciu štrukturálnych rizík slovenského priemyslu, ale aj v kontexte možnej inteligentnej špecializácie krajiny. Konkrétne oblasti, do ktorých sa investovalo v Michigane, však treba brať len ako inšpiratívny príklad. Tiež treba poznamenať, že opatreniami sa dosiahli významné zmeny v meste Detroit, avšak [nie také optimistické, ako sa očakávalo](#).

2 Analýza aktuálneho stavu nasadzovania umelej inteligencie v podnikoch v Slovenskej republike

2.1 Index digitálnej ekonomiky a spoločnosti 2019 – správa o Slovensku²

V oblasti integrácie digitálnych technológií podnikmi skončilo Slovensko na 21. mieste spomedzi krajín EÚ. Jeho postavenie a skóre sa v porovnaní s DESI 2018 znížilo, pričom skóre je hlboko pod priemerom EÚ. Na predchádzajúce pokroky dosiahnuté v tejto oblasti sa nepodarilo nadviazať, a tak jediné výrazné zlepšenie nastalo vo využívaní sociálnych médií podnikmi (nárast z 13 % na 17 %). Nižší podiel (13 %) predajov online malými a stredne veľkými podnikmi (ďalej aj „MSP“), ako aj podiel elektronického obchodu na ich obrate klesol na 11 %. V roku 2018 išlo o pokles z 12 %, dosiahnutých v roku 2017. Ide o jediný ukazovateľ, ktorý presahuje priemer EÚ.

Slovenské podniky podporujú využívanie nových technológií, index využívania digitálnych technológií však svedčí o tom, že každá druhá firma na Slovensku disponuje veľmi nízkou mierou digitalizácie (52 % v porovnaní s priemerom EÚ, ktorý je na úrovni 46 %) a iba 13 % firiem je vysoko digitalizovaných (priemer EÚ je 18 %).

Slovensko sa snaží opätovne naštartovať digitalizáciu podnikov v rámci Akčného plánu inteligentného priemyslu prijatého v októbri 2018 (pozri aj [Podkapitolu 3.1.2](#)). Plán je v súlade so stratégiou pre digitalizáciu európskeho priemyslu uverejnenou v roku 2016. Jeho cieľom je zvýšiť konkurencieschopnosť slovenských podnikov, podporovať technický rozvoj, spájať jednotlivé firmy s univerzitami a zabezpečiť dostupnosť tých správnych talentov na trhu práce. Obsahuje 35 opatrení rozdelených do piatich oblastí: výskum a inovácie, kybernetická bezpečnosť, trh práce a vzdelávanie, štandardizácia a propagácia. Vláda predpokladá jeho úplnú realizáciu do konca roka 2020.

Slovensku patrí vo výrobnom sektore 15. miesto na svete v intenzite robotizácie so 151 priemyselnými robotmi na 10-tisíc zamestnancov. Nedávny prieskum Industry4UM³ ukázal, že podniky majú stále väčší záujem o tzv. priemysel 4.0¹¹. 33 % opýtaných sa pripravuje zaviesť, alebo už zaviedlo príslušnú stratégiu. Očakávajú, že digitalizácia zefektívni ich fungovanie, zlepši vnútorné procesy a digitálne technológie pomôžu vyrovnáť nedostatok kvalifikovanej pracovnej sily. 56 % opýtaných uviedlo, že ich podnik zriadil či onedlho zriadi špecializovaný tím, ktorý sa bude zaoberať riešeniami priemyslu 4.0.

2.2 Prieskum o umelej inteligencii na Slovensku

V rámci prípravy štúdie sme zrealizovali dotazníkový prieskum⁴, ktorým sme sa snažili zmapovať aktuálny stav využívania a vývoja systémov umelej inteligencie (ďalej aj „AI“) na Slovensku.

Dotazník vyplnilo 247 respondentov. Z geografického hľadiska najväčší počet respondentov je z Bratislavského kraja. Za ním nasledujú spoločnosti z Banskobystrického, Žilinského a Trenčianskeho


² Index digitálnej ekonomiky a spoločnosti (DESI) - Správa o krajine za rok 2019 – Slovensko [Dostupné online](#).

³ Združenie inteligentného priemyslu – Industry4UM. Prieskum Industry 4.0 v SR [Dostupné online](#).

⁴ Konkrétne znenie otázok je v [Prílohe 3](#).


kraja). Najnižšie zastúpenie v prieskume majú spoločnosti z Prešovského kraja (pozri **Obrázok 2.1**). Dotazník bol vyplnený prevažne majiteľmi spoločností a generálnymi riaditeľmi spoločností.

Približne 20 % respondentov sú zástupcovia firiem z oblasti informačných a komunikačných spoločností, tzv. IKT firmy. Zvyšní respondenti sú firmy naprieč celým hospodárstvom od maloobchodu a veľkoobchodu, práva, poradenstva a účtovníctva, zdravotníctva, strojárstva a iné.



Obrázok 2.1 Respondenti podľa krajov. Zdroj: vlastný prieskum

Na Slovensku sú spoločnosti, ktoré umelú inteligenciu priamo vyvíjajú a implementujú do svojich produktov a riešení, ako aj spoločnosti, ktoré už vytvorili dopyt po takýchto službách. Stále je však veľká skupina spoločností, ktorá umelú inteligenciu ešte nepoužíva (pozri **Obrázok 2.2**).




Obrázok 2.2 Rozdelenie firiem podľa kontaktu s AI. Zdroj: vlastný prieskum

Firmy vyvíjajúce umelú inteligenciu

Pri bližšom pohľade na skupinu, ktorá AI vyvíja (pozri **Obrázok 2.3**), vieme povedať, že firmy vyvíjajú umelú inteligenciu najviac v oblastiach ako inteligentná procesná automatizácia, inteligentných agentov a botov, AI je využívaná aj v marketingu, pri podpore predaja a v prediktívnej údržbe a optimalizácii výroby a logistiky.

V najväčšej miere ide o B2B riešenia. Najväčším odberateľom je zatiaľ finančný sektor a samotný IT sektor. AI riešenia sa v súčasnosti využívajú aj v doprave a logistike, obchode a marketingu a energetike.




Obrázok 2.3 Sektory aplikácie umelej inteligencie (firmy vyvíjajúce AI). Zdroj: vlastný prieskum

Čo sa týka konkrétnych metód, ktoré firmy využívajú (pozri **Obrázok 2.4**), najviac ide o strojové učenie (ďalej aj angl. „*machine learning*“), ďalej sú to metódy vyhľadávania a optimalizácie, AI aplikácie, platformy, softvérové služby, inteligentné agenty a boty, spracovanie prirodzeného jazyka a počítačové videnie.


Vývoj umelej inteligencie je náročný aj v súvislosti s výpočtovou infraštruktúrou, dve tretiny našich respondentov pri vývoji umelej inteligencie využívajú vlastnú výpočtovú infraštruktúru a jedna tretina využíva zdieľanú infraštruktúru, t. j. cloudové služby od medzinárodných spoločností (Google, Amazon, Microsoft, atď.).

Okrem kvalitných a relevantných dát a potrebnej infraštruktúry je pri vývoji a nasadzovaní AI dôležité uplatňovať určité etické a spoločenské princípy. Dôležitosť posudzovania etiky sme v dotazníku merali pomocou vyjadrení spoločností na 5-stupňovej škále, kde hodnota 1 znamenala, že spoločnosť nepovažuje otázky etiky za dôležité a hodnota 5 znamenala, že etika je pri nasadzovaní AI kľúčová (pozri **Obrázok 2.5**).

Medzi slovenskými spoločnosťami sa dostala dôležitosť etiky na priemernú úroveň – 3,58. Slovenské spoločnosti si jej dôležitosť uvedomujú a považujú ju skôr za viac dôležitú, čo naznačuje aj početnosť jednotlivých zvolených odpovedí.



Obrázok 2.4 Použité metódy umelej inteligencie. Zdroj: vlastný prieskum




Obrázok 2.5 Dôležitosť etiky pri nasadzovaní a vývoji AI. Zdroj: vlastný prieskum

Firmy, ktoré umelú inteligenciu používajú

Spoločnosti, ktoré používajú umelú inteligenciu v rámci externe dodaných riešení alebo produktov sa vyjadrili, že zavedenie umelej inteligencie malo pozitívny dopad na ich efektivitu, aj keď vo veľkej miere

efekt ešte nevedia vyčíslieť a teda posúdiť dopad na ROI (z angl. *Return on Investment* – návratnosť investície).

Umelú inteligenciu zväčša nasadzujú (podobne ako firmy, ktoré ju vyvíjajú) do oblastí ako inteligentná procesná automatizácia, AI v oblasti marketingu a podpory predaja, inteligentné agenty a boty, online predaj a optimalizácia výroby a prediktívna údržba (viď. **Obrázok 2.6**).



Obrázok 2.6 Oblasti nasadzovania umelej inteligencie (spoločnosti, ktoré AI používajú). Zdroj: vlastný prieskum

Plán rozvoja a potenciál AI

V horizonte 1 až 3 rokov sú plánované oblasti AI podobné súčasnosti, v ktorých dominuje inteligentná procesná automatizácia, AI v marketingu a podpore predaja a inteligentné agenty a boty. Vo voľných odpovediach sa však objavuje umelá inteligencia v oblastiach ľudských zdrojov, zdravotníctva (asistenčné systémy pri rozhodovaní), pri vzdelávaní žiakov či aplikáciách založených na spracovaní geopriestorových dát pre monitorovanie zmien krajiny a miest.

Spôsob, akým chcú jednotlivé zapojené spoločnosti zabezpečiť v horizonte 1 až 3 rokov rozvoj umelej inteligencie je znázornený na nasledujúcom grafe (pozri **Obrázok 2.7**). Väčšina spoločností chce riešiť rozvoj AI nákupom od tretích firiem (26 %), trochu nižší je podiel spoločností, ktoré to chcú dosiahnuť interným vývojom šitým na mieru (23 %). Dôležitú úlohu takisto zohrajú partnerstvá s akademickou obcou (18 % respondentov), ktorá sa vo svojom výskume zameriava na oblasť umelej inteligencie a získavanie externých expertov.


Čo by, naopak, slovenským spoločnostiam pomohlo vo väčšom využívaní umelej inteligencie?

V značnej miere je to administratívne nenáročná finančná podpora pri testovacích riešeníach tzv. *proof of concept*⁵. Okrem toho by slovenské spoločnosti uvítali rozšírenie povedomia o umelej inteligencii ako takej a prehľad o existujúcich riešeníach vo svete a na Slovensku, a to v zrozumiteľnej podobe a prípadne pre určitú špecifickú oblasť podnikania.

Firmy potrebujú väčšie množstvo AI expertov, preto je nevyhnutné nielen zvýšenie počtu absolventov v odbore umelá inteligencia a dátová analytika, ale súčasne je dôležitá aj potreba vytvorenia ponuky


⁵ Častokrát sú riešenia všeobecne použiteľné a firmám by pomohlo nájsť partnera, kde môžu technológie v praxi nasadiť a vyskúšať si ich pri akceptovateľných podmienkach, ktoré by neboli finančne náročné.

AI kurzov/workshopov pre manažerov, majiteľov spoločností a ich zamestnancov, doménových expertov a všeobecnú verejnosť.



Obrázok 2.7 Plán rozvoja umelej inteligencie v horizonte 1–3 rokov. Zdroj: vlastný prieskum

Firmy vyvíjajúce AI častokrát identifikovali ako problém úroveň vedomostí o umelej inteligencii a jej možnostiach od svojich potenciálnych zákazníkov, ktorí by vplyvom lepšej osvetovej kampane vedeli lepšie formulovať svoje vlastné potreby a možnosti. Prehľad početností jednotlivých možností nájdete na nasledujúcom grafe (pozri **Obrázok 2.8**).



Obrázok 2.8 Najväčšia pomoc pre zlepšenie využitia AI . Zdroj: vlastný prieskum

Odpovede na otvorené otázky

Medzi voľnými odpoveďami, ktoré firmy mohli v rámci tejto otázky dopĺňať, sú uvedené ďalšie možnosti pomoci pre tento segment. Rozvoju umelej inteligencie by pomohlo reálne a konkrétne zadanie zo strany štátu, prípadne spoločenská objednávka, ktorá by finančne pokryla vývoj umelej inteligencie pre aplikáciu v reálnom živote občanov. Impulzom pre širšiu implementáciu AI by mohlo byť aj zmapovanie potrieb firiem, na ktoré by sa mohli použiť AI riešenia.


Otvorenejšie dáta a zdieľanie údajov by takisto pomohli rozvoju AI, a to nielen vo forme samotných údajov, ktoré majú k dispozícii verejné inštitúcie, ale aj pre určité konkrétne sektory. Pre efektívne nasadenie AI v určitom sektore je potrebné získať taký objem dát, ktoré nie je možné získať iba od 1 spoločnosti, ale od čo najväčšieho počtu subjektov v danom sektore.

Častou voľnou odpoveďou respondentov bolo, že pracovný trh neponúka dostatočné množstvo expertov so zameraním potrebným pre umelú inteligenciu. Pomohlo by šírenie osvedy medzi študentmi pri výbere ich študijných smerov, ktoré by slovenskému trhu dodali viac pracovnej sily. Väčší dôraz na matematické vedomosti absolventov, vyhodnocovanie informácií, prácu s dátami a modernými technológiami je potrebné preniesť minimálne na úroveň stredných škôl. Vítanou pomocou by bol aj prehľad firiem, ktoré sa zaoberajú vývojom v tejto oblasti, prehľad ich produktov, prehľad kurzov a študijných smerov univerzít.⁶

Respondentov sme sa pýtali, ktorý sektor hospodárstva má podľa nich potenciál pre rozvoj a aplikáciu AI (pozri **Obrázok 2.9**). Sektory mali výberom ohodnotiť možnosťami ako „*veľký potenciál/skôr väčší potenciál/neviem sa vyjadriť/skôr menší potenciál/takmer žiadny potenciál*“. Jednotlivým možnostiam

⁶ Detailnejší popis voľných odpovedí je uvedený v [Prílohe 3](#).

sme priradili hodnotu od -2 (takmer žiadny potenciál), cez 0 (neviem sa vyjadriť) až po 2 (veľký potenciál). Následne sme sa pozreli na priemer jednotlivých oblastí. Dáta sme očistili od neobjektívnych hodnotení (t. j. vyradili sme hodnotenia pre tie oblasti, ktoré boli zhodné s pôvodom respondenta).



Obrázok 2.9 Oblasti, ktoré majú podľa respondentov pre Slovensko najväčší potenciál pre rozvoj a aplikáciu AI.
Zdroj: vlastný prieskum

Podľa respondentov dotazníka má najväčší potenciál pre aplikáciu umelej inteligencie sektor zdravotníctva, finančných inštitúcií, výrobného priemyslu, dopravy a obchodu a marketingu (mimo oblasti IKT, kde spadajú spoločnosti, ktoré vyvíjajú samotné systémy umelej inteligencie). Zaujímavé je, že názory na jednotlivé oblasti s najväčším potenciálom sa vo veľkej miere zhodujú – či ich hodnotili firmy, ktoré vyvíjajú umelú inteligenciu alebo tie, ktoré ju používajú.

Medzi častými odpoveďami v možnosti „Iné“ sa objavovalo školstvo, resp. vzdelávanie a oblasť štátnej správy a verejných služieb, ktoré tam patria (napríklad v oblasti bezpečnosti verejných priestorov, služieb občanom, kvality ciest a cestných značení).

Umelá inteligencia má veľmi široké uplatnenie – môžeme konštatovať, že takmer v každej oblasti bežného života. Je však potrebné správne zadefinovanie problému a dostupnosť relevantných a kvalitných dát s ohľadom na etické princípy.

3 Analýza dopadov robotizácie a automatizácie na trh práce

Umelá inteligencia, automatizácia a robotizácia (ďalej aj „AI/A/R“) v budúcnosti zruší celé priemyselné odvetvia. Odhady o tom, koľko pracovnej sily by sa mohlo nahradiť automatizáciou, sa pohybujú v rozmedzí od 9 % do 47 %. Poradenská spoločnosť McKinsey predpokladá, že do roku 2030 by roboty mohli obrať o prácu až 800 miliónov pracovníkov po celom svete⁷.

Na Slovensku by podľa údajov OECD mala robotizácia v nasledujúcich rokoch nahradiť približne tretinu súčasných pracovných pozícií.

Regióny, ktoré sa vyznačujú nízkou ohrozenosťou z automatizácie sú tie, kde sú ľudia s vyšším vzdelaním, majú väčší počet pracovných miest v službách a sú viac urbanizované. Automatizácia pracovných pozícií sa líši aj v regionálnom meradle. Na Slovensku je najviac ohrozených pozícií na západe krajiny, a to až 40 % súčasných pracovných miest.

Predchádzajúcej generácii zručnosti získané v škole vystačili na 26 rokov. Dnes je to len na 4,5 roka. Zručnosti sa teda stávajú zastaranými skôr ako kedykoľvek predtým. Univerzity musia tomu prispôbiť svoje zameranie a orientovať sa na celoživotné vzdelávanie.

65 % detí nastupujúcich do základných škôl bude mať pracovné miesta, ktoré ešte neexistujú, a na ktoré ich vzdelávanie nedokáže pripraviť. Vzdelávanie sa teda musí zodpovedajúcim spôsobom prispôbiť, čo by predovšetkým znamenalo menšie zameranie na „prenos vedomostí“ a viac na schopnosť učiť sa „pre seba“.

Pracovné pozície, ktoré si vyžadujú interakciu s ľuďmi a využitie sociálnej inteligencie či prácu v nepredvídateľnom prostredí budú v prvej vlnе len ťažko automatizovateľné. Naopak, pracovné miesta, ktoré zahŕňajú rutinné činnosti alebo presne štruktúrované akcie v predvídateľnom prostredí budú veľmi rýchlo zautomatizované a vo svojej podstate úplne zaniknú.

Medzi najviac ohrozené pracovné miesta patria pozície montážnikov, telemarketérov, skladníkov, pokladníkov, pekárov, vodičov nákladných aut, prekladateľov či taxikárov.

Menej ohrozené profesie, ktoré nie sú odsúdené na zánik, ale budú vyžadovať oveľa menej pracovníkov zahŕňajú pozície rôznych asistentov, poradcov, účtovníkov a daňových kontrolórov, pretože väčšina ich úloh sa zautomatizuje.

Relatívne „bezpečné“ pracovné miesta predstavujú profesie ako učiteľ, zdravotná sestra, lekár, zubár, vedec, podnikateľ, programátor, inžinier, sociálny pracovník, umelec, kaderník či fyzioterapeut.

V množstve prípadov samotné profesie nezaniknú, ale výrazným spôsobom bude automatizovaná vykonávaná práca. Napríklad rádiológom, ktorí analyzujú lekárske snímky, budú pomáhať expertné systémy schopné okamžite vyhodnocovať milióny snímok pacientov z celého sveta. Ale výslednú správu pre ošetrojúceho lekára podpíše rádiológ. Vo svete financií budú brokerom pomáhať algoritmy AI, ktoré budú vyhodnocovať výsledky kvantitatívnej analýzy a prijímať strategické investičné rozhodnutia. Ale samotné rozhodnutie urobí správca fondu. Právnikom bude zase AI pomáhať

⁷ Bughin, J. Seong, J. Manyika, J. Chui, M. Joshi, R.: Notes from the AI frontier – Modeling the impact of AI on the world economy. McKinsey global institute. 2018. [Dostupné online](#).

analyzovať tisíce dokumentov vo fáze prípravy na pojednávanie, ale bude to právnik, ktorý poradí klientovi a predloží prípad na súd.

Optimistický scenár ďalšieho vývoja predpokladá, že zautomatizované pracovné miesta budú nahradené novými, ktoré budú omnoho lepšie využívať ľudský potenciál. Pesimistický výhľad očakáva, že stále väčší počet ľudí sa stane nielen nezamestnanými, ale nezamestnateľnými. A tiež, že rastúca ponuka lacnej strojovej práce nakoniec zníži ľudské platy hlboko pod životné náklady.

3.1 Národné stratégie a súvisiace dokumenty

V ďalšom texte analyzujeme strategické materiály na Slovensku so zameraním na dopady digitálnej transformácie na trh práce a návrhy, ako tieto dopady zmierniť a súčasne využiť potenciál nastupujúcich zmien.

Slovenská republika sa v súvislosti s nastupujúcimi procesmi digitálnej transformácie a rozvojom digitalizácie tiež pripravuje na možné dopady na všetky odvetvia hospodárstva a tento vývoj by sa mal intenzívne prejavovať najmä v oblastiach ako sú školstvo a pracovné prostredie a ich rozvoj, riadenie a legislatíva.

Slovenská vláda pri snahe pripraviť sa na dopady digitálnej transformácie v oblastiach výskumu, energetiky, výroby, trhu práce a ďalších odvetví pripravila viacero strategických materiálov a akčných plánov. **Medzi kľúčové patria:**

- [Konceptia inteligentného priemyslu pre Slovensko](#), Ministerstvo hospodárstva SR, 2016;⁸
- [Akčný plán inteligentného priemyslu SR 2018-2020](#), Ministerstvo hospodárstva SR, 2018⁹;
- [Stratégia digitálnej transformácie Slovenska 2030](#), Úrad podpredsedu vlády SR pre investície a informatizáciu, 2019¹⁰;
- [Akčný plán digitálnej transformácie SR na roky 2019 – 2022](#), Úrad podpredsedu vlády SR pre investície a informatizáciu, 2019¹¹.

3.1.1 Konceptia inteligentného priemyslu pre Slovensko

Konceptia sa zameriava na výzvu vykonať dôsledné analýzy potrieb Slovenska v rámci jednotlivých priemyselných a technologických oblastí. Slovenskí výrobcovia a podnikatelia potrebujú držať krok s novými trendmi vyplývajúcimi zo štvrtej priemyselnej revolúcie. Avšak na rozdiel od problémov a výziev identifikovaných vo vyspelých priemyselných krajinách, ktoré sa dajú aplikovať aj v prípade Slovenska, Slovensko čelí niekoľkým výzvam navyše vyplývajúcim z úrovne hospodárskeho a technologického rozvoja v krajine.

8 Ministerstvo hospodárstva: Konceptia inteligentného priemyslu pre Slovensko. 2016. [Dostupné online](#).

9 Ministerstvo hospodárstva SR: Akčný plán inteligentného priemyslu SR 2018-2020. 2018. [Dostupné online](#).

10 Úrad podpredsedu vlády SR pre investície a informatizáciu: Stratégia digitálnej transformácie Slovenska 2030. 2019. [Dostupné online](#).

11 Úrad podpredsedu vlády SR pre investície a informatizáciu: Akčný plán digitálnej transformácie SR na roky 2019-2022. 2019. [Dostupné online](#).

Medzi hlavné identifikované problémy, ktorým čelia priemyselné firmy pri rozvoji digitalizácie, patrila aj „slabá podpora výskumných priorít a rozvoja školstva“.

Kľúčovou oblasťou, v ktorej boli Konceptiou identifikované problémy, v ktorých má Slovensko priestor na výrazné zlepšenie, bola oblasť rozvoja vzdelávacieho systému.

3.1.2 Akčný plán inteligentného priemyslu SR 2018 – 2020

Cieľom *Akčného plánu inteligentného priemyslu SR 2018 – 2020* (ďalej aj „Akčný plán“ alebo „AP IP“) je podpora pre priemyselné podniky, podniky služieb a obchodu bez ohľadu na ich veľkosť, zameraná na vytvorenie lepších podmienok na implementáciu digitalizácie, inovatívnych riešení a zvýšenie konkurencieschopnosti: znížením byrokratickej záťaže, úpravou legislatívy, definovaním štandardov, zmenou vzdelávacích programov a trhu práce, spolufinancovaním výskumu, vytváraním Centier digitálnych inovácií (ďalej aj „*Digital Innovation Hubs*“), atď. Akčný plán poskytuje súbor opatrení, ktoré by mali byť realizované do konca roku 2020.

Účel Akčného plánu:

- Realizácia opatrení na zmeny v obsahu vzdelávania zodpovedajúce potrebám inteligentného priemyslu;
- Prepojenie nadnárodných spoločností, veľkých podnikov a malých a stredných podnikov s univerzitnými inkubátormi a vedeckými parkami na finančnej, technologickej a mentorskej báze s cieľom zvýšiť znalosti študentov a absolventov technických univerzít a tým zabezpečiť ich konkurencieschopnosť na trhu práce, resp. možnosť vlastného podnikania. Tieto firmy, resp. startupy sa stanú partnermi priemyselných odvetví a dokonale spoja automatizovaný hodnotový reťazec;
- Realizácia opatrení na zmenu štruktúry zamestnancov na trhu práce, rekvalifikácia, pripravenosť absolventov, dopady na trh práce;
- Zníženie bariér implementácie prvkov inteligentného priemyslu (najmä európska a národná legislatíva, technická normalizácia, bezpečnosť, právne aspekty);
- Podchytenie potenciálu rastu produktivity a konkurencieschopnosti, ktoré inteligentný priemysel prináša;
- Podpora/naštartovanie investícií do digitálnych technológií;
- Podpora tvorby a rozvoja inteligentných tovární;
- Zapojenie všetkých typov podnikov so zvýšenou podporou pre malé a stredné podniky;
- Celospoločenská osвета.

Z obsahovej štruktúry Akčného plánu je zrejmé, že trh práce a vzdelávanie dostali v tomto materiáli vysokú prioritu.

Sekcia „*Trh práce a vzdelávanie*“ popisuje situáciu v týchto doménach nasledovne:

- Vzdelaná pracovná sila zvyšuje produktivitu práce a vie sa pružnejšie prispôbovať zvyšujúcim sa pracovným nárokom a zmenám v požadovaných zručnostiach. V súčasnosti však prepojenie prípravy a rozvoja ľudských zdrojov s potrebami a požiadavkami trhu práce je nedostatočné, prevláda orientácia vzdelávania novej pracovnej sily do oblastí nekorešpondujúcich s potrebami spoločnosti a hospodárskej praxe najmä v oblasti inteligentného priemyslu a znalostnej spoločnosti;

- Štvrtá priemyselná revolúcia, známa aj ako digitálna transformácia, znamená komplexnú zmenu vnímania aj v oblasti trhu práce a vzdelávania. S automatizáciou a optimalizáciou procesov, ktoré so sebou prináša, klesne dopyt po niektorých povolaniach, ak nezanikne úplne a súčasne sa budú vytvárať nové povolania;
- Je potrebné, aby vzdelávací systém na všetkých úrovniach vzdelávania, vrátane rekvalifikácií a celoživotného vzdelávania, pripravil svojich absolventov tak, aby v rozsahu svojej odbornej kvalifikácie boli schopní úspešne zvládať všetky aspekty pracovných procesov, vrátane aplikovania požiadaviek na dôstojné pracovné podmienky v inteligentnom priemysle;
- Je dôležité aktívne prepojiť odbornú verejnosť so študentmi a absolventmi technických univerzít formou prednášok, workshopov, seminárov, školení podnikateľských zručností a mentoringu priamo na univerzitnej pôde, a to v univerzitných inkubátoroch, čím sa zvýši praktické vzdelávanie absolventov;
- Pevné pracovné zaradenia a pevné pracovné časy sa stávajú čoraz menej dôležitými. Tento vývoj ponúka nové príležitosti, ale aj riziká. Predstavuje nové výzvy pre zamestnancov a spoločnosti;
- Avizovaný moderný systém prípravy pracovníkov na povolania súčasnosti a blízkej budúcnosti (známy ako Práca 4.0) znamená celoživotné vzdelávanie od útlej mladosti do staroby;
- Súhrn cieľov v danej oblasti, cieľový stav, smerovanie aktivít a ich opodstatnenie, nadväznosť na ciele EÚ;
- Popis prínosov plynúcich z konkrétnych navrhovaných opatrení.

Identifikácia hlavných bariér:

1. Neefektívny systém celoživotného vzdelávania, do ktorého sa na Slovensku zapája menej ako 3 % dospelých, kým priemer EÚ je 10,8 %.
2. Nesúlad medzi nadobudnutými vedomosťami počas formálneho štúdia a potrebami trhu práce.
3. Nedostatočná znalosť potrieb pracovného trhu zo strany vzdelávacieho systému a nepripravenosť vysokých a stredných škôl, ale ani základných škôl na zmeny požiadaviek trhu práce.
4. Nedostatok kvalifikovanej pracovnej sily v kľúčových odvetviach národného hospodárstva.
5. Nepružný trh práce, chýbajúca podpora flexibilných foriem práce.
6. Absentujúce národné dokumenty:
 - Trh práce – Práca 4.0
 - Digitálne vzdelávanie
 - Digitálna gramotnosť

V AP IP boli publikované aj závery štúdie Maďarskej asociácie remeselných korporácií, ktorá v spolupráci s partnerskými inštitúciami z krajín V4, Talianska a Nemecka vypracovala štúdiu, ktorá sa na základe dotazníkového prieskumu medzi malými a strednými podnikmi v zúčastnených krajinách snaží identifikovať najdôležitejšie vplyvy digitalizácie a aspektov Priemyslu 4.0 na segment malých a stredných podnikov. Uvedená štúdia *Vplyv digitalizácie a aspektov Priemyslu 4.0 na malé a stredné*

podniky¹² vznikla v rámci projektu financovaného z prostriedkov Medzinárodného vyšehradského fondu.

Dotazníkový prieskum hľadal odpovede na otázky o tom, čo si malé a stredné podniky v zúčastnených krajinách predstavujú pod pojmom digitalizácia, či ju používajú a či ju považujú za dôležitú. Skúmal aj to, či podniky poznajú národné stratégie Priemyslu 4.0, či už o nich počuli a ako v tejto súvislosti vidia systém poskytovania služieb a financovania.

Hlavné zistenia:

- Digitalizácia nie je možnosťou, ale je nezvratným procesom, pričom treba citlivo pristupovať k rozsahu, v akom by bola pre malé podniky potrebná, a zohľadniť fakt, že je závislá od druhu profesie. Existujú profesie, ktoré sa bez nej nezaobídu, ale aj profesie, ktoré sú viac spojené s fyzickou prácou, kde je menej potrebná;
- Trendy naznačujú, že digitalizácia a robotika sa zaradia do všetkých oblastí života, na základe čoho zaniknú niektoré profesie, no na druhej strane vzniknú profesie nové. V budúcnosti by preto digitálnymi zručnosťami mali disponovať všetci;
- Na digitalizáciu a robotizáciu nemôžu malé podniky pozeráť len ako na problém, predstavuje pre nich aj príležitosť;
- Malé podniky trpia značným nedostatkom informovanosti o celkovom priebehu uvedených procesov, a preto potrebujú nepretržitý a rozsiahly prístup k zdrojom informácií o tom, čo pre nich tieto procesy budú znamenať v budúcnosti, význam najdôležitejších aspektov Priemyslu 4.0 bude ovplyvňovať celé spektrum podnikov, vrátane ich zástupcov a dodávateľských reťazcov.

3.1.3 Stratégia digitálnej transformácie Slovenska 2030

Stratégia digitálnej transformácie Slovenska 2030 (ďalej aj „Stratégia“) je rámcovou a nadrezortnou vládnuou stratégiou, ktorá definuje politiku a konkrétne priority Slovenska v kontexte už prebiehajúcej digitálnej transformácie hospodárstva a spoločnosti pod vplyvom inovatívnych technológií a globálnych megatrendov digitálnej doby.

Stratégia predstavuje kľúčový a rozhodujúci materiál pre Slovensko na začiatku 21. storočia, kedy zákonite dochádza k transformácii industriálnej spoločnosti na spoločnosť informačnú. Pokrýva časové obdobie od roku 2019 do roku 2030 a bola tvorená v rámci rozbehnutých a čiastočne riadených procesov digitalizácie, informatizácie a agendy jednotného digitálneho trhu Európskej únie (ďalej aj „EÚ“), ako aj v kontexte globálnych priorít širokej digitálnej transformácie.

Stratégia teda dáva prvoradý dôraz na súčasné inovatívne technológie, ako sú umelá inteligencia, internet vecí (Internet of Things, ďalej aj „IoT“), technológia 5G, veľké dáta a analytické spracovanie dát, blockchain a supervýkonné počítanie (*High-Performance Computing*, ďalej len „HPC“), ktoré sa stanú novým motorom ekonomického rastu a posilňovania konkurencieschopnosti.

Na národnej úrovni je preto nevyhnutné akcelerovať naštartované procesy, prepojiť národné strategické opatrenia s globálnymi trendmi, ako aj realizovať nové politiky, ktoré vychádzajú z najaktuálnejších prierezových priorít EÚ, ako aj zo špecifických potrieb Slovenska.

¹² Slovenský živnostenský zväz: Vplyv digitalizácie priemyslu 4.0 na malé a stredné podniky. [Dostupné online](#).

Digitálna transformácia prináša primárne spoločenskú a nielen technologickú výzvu, ktorá sa dotýka všetkých občanov Slovenska. Cieľovou entitou je občan, ktorý by mal mať jednoduchší a kvalitnejší každodenný život na pracovisku a v súkromí, ako aj občan – podnikateľ, ktorému by mal štát maximálnou možnou mierou znížiť administratívne bremeno a podporiť ho primeranými stimulmi. Informačné a digitálne technológie musia byť preto rozvíjané a používané pre skvalitnenie života obyvateľov a na optimalizovanie ich prínosu pre hospodársky, sociálny a environmentálny rast krajiny s dôrazom na trvalo udržateľný rozvoj. Práve preto je strategickým cieľom štátu pristupovať k téme digitalizácie hospodárstva a spoločnosti koncepčne a uplatňovať nadrezortný princíp s cieľom výrazne pokročiť v digitálnej transformácii.

Z pohľadu oblasti trhu práce a vzdelávania Stratégia identifikuje „*zlepšenie vzdelávania, predpokladov zamestnanosti a digitálnych zručností pre modernú dobu*“ ako jednu z troch prioritných oblastí, na ktoré je potrebné sa zamerať.

Predstavená SWOT analýza potenciálu ľudského kapitálu dobre analyzuje jeho súčasný stav (pozri **Obrázok 3.1**).

Ľudský kapitál



Obrázok 3.1 SWOT analýza potenciálu „Ľudského kapitálu“

3.1.4 Akčný plán digitálnej transformácie SR na roky 2019 – 2022

Akčný plán digitálnej transformácie SR na roky 2019 – 2022 (ďalej aj „APDT SR“) priamo nadviazal na Stratégiu a pokrýva opatrenia, ktoré je možné začať realizovať v krátkodobom časovom horizonte, t. j. od tretieho kvartálu 2019 do 2022. Ich financovanie je naviazané ešte na programové obdobie 2014 – 2020.

Úspešné naplnenie opatrení APDT SR vyžaduje širokú politickú podporu nad hranicu mandátu súčasnej vlády. Opatrenia sú rozdelené na nasledujúce strategické oblasti (strategické ciele), v ktorých dokáže Slovensko dosiahnuť v sledovanom časovom horizonte výrazný úspech.

Reálne sú to aj oblasti tzv. technologických megatrendov alebo zmien, v ktorých už dnes Slovensko čiastočne zaostáva a ďalšie zaostávanie môže mať za následok vylúčenie Slovenska z prístupu

k medzinárodným konzorciám a zoskupeniam a tým obmedzenie alebo zamedzenie prístupu k európskym štrukturálnym fondom v novom programovom období.

Je veľmi dôležité, aby s podporou vlády vyjadrenou v APDT SR už v roku 2019 vznikli a svoju činnosť naplno rozbehli dôležité centrá podpory digitálnych zručností a vývoja a výskumu v prioritných oblastiach pre program Digitálna Európa. Celkový rozpočet programu bude 9,2 miliárd Eur a ak chce Slovensko čerpať prostriedky, musí byť pripravené so svojimi centrami vývoja a výskumu. Predstava Európskej komisie je, že do priamo riadeného programu sa budú môcť zapojiť len konzorciá, skupiny výskumných centier alebo zosieťované subjekty národného alebo medzinárodného významu.

Konkrétne sú to:

- Digitálna koalícia SR;
- Centrum excelencie pre výskum a vývoj umelej inteligencie;
- Európsky Digitálny inovačný hub;
- Centrum pre vývoj HPC – superpočítačov – Národné superpočítačové kompetenčné centrum;
- Centrum pre vývoj technológie Blockchain.

Podchytené oblasti v APDT SR pokrývajú všetky oblasti vízie digitálnej transformácie Slovenska, t. j. hospodárstvo, spoločnosť a vzdelávanie, verejná správa, rozvoj územia a výskum:

- Podpora digitálnej transformácie škôl a vzdelávania na skvalitnenie a zlepšenie predpokladov zamestnanosti a získanie digitálnych zručností a kompetencií potrebných pre digitálnu éru;
- Vytvorenie základov pre moderné údajové a digitálne hospodárstvo;
- Zlepšenie schopnosti verejnej správy inovovať a využívať údaje;
- Rozvinutie výskumu v oblasti umelej inteligencie a jeho aplikácie v praxi.

Strategický cieľ *Podporíme digitálnu transformáciu škôl a vzdelávania na skvalitnenie a zlepšenie predpokladov zamestnanosti a získanie digitálnych zručností a kompetencií potrebných pre digitálnu éru* pozostáva z dvoch tém:

- Vzdelávanie a digitálne zručnosti;
- Modernizácia a otvorenie trhu práce.

Kvalitné vzdelávanie je základom každej úspešnej spoločnosti a moderného štátu, je východiskovým bodom pre budúcu prosperitu krajiny. Súčasná doba si nevyhnutne vyžaduje čoraz vyššiu digitálnu gramotnosť ľudí všetkých vekových kategórií. Nakoľko sa tento trend vzhľadom na súčasný vývoj bude iba stupňovať, je dôležité skvalitniť vzdelávacie procesy a predovšetkým ich prispôbiť požiadavkám digitálnej doby. Toto platí pre všetky stupne vzdelávania žiakov a študentov, ako aj vzdelávania zamestnancov a ďalšieho vzdelávania dospelých a seniorov.

Slovenské firmy ako aj verejnú správu dlhodobo trápí nedostatok pracovnej sily so základnými, ale i pokročilými digitálnymi zručnosťami, s dostatkom skúseností pri využívaní technológií alebo nedostatočné technické zázemie a vzdelanie.

4 Zavedenie umelej inteligencie vo firmách

4.1 Všeobecné pojmy a typy umelej inteligencie^{13, 14}

4.1.1 Hlavné charakteristiky umelej inteligencie

Umelá inteligencia je inteligencia demonštrovaná neživými systémami – na rozdiel od tej, ktorú prejavuje človek. Jeden z pohľadov na umelú inteligenciu je snaha reprodukovať správanie človeka s využitím prostriedkov informatiky, najmä logiky a algoritmov a do určitej miery aj schopnosti ukladania skúseností prostredníctvom dát. To znamená vnímať zmyslami svet, rozumieť a reagovať na reč, učiť sa, plánovať a riešiť problémy. Keďže ide o počítač, ktorý túto reprodukciu vykonáva, je to softvér, ktorý zabezpečuje túto inteligenciu.

Mnoho prístupov umelej inteligencie si kladie za cieľ viac či menej napodobňovať schémy ľudského (prípadne vo všeobecnosti biologického) správania, vyhodnocovania a analýzy podnetov prostredia, prípadne tvorivej činnosti. Umelá inteligencia sa rozvíja na cieľoch, ktoré máme ambíciu očakávať od inteligentného systému) a hľadá v rôznych vedných disciplínach dostupné riešenia.

Pôvodne bola snaha priekopníkov umelej inteligencie zameraná na úplné skopírovanie a následne zdokonalenie ľudského umu. Čoskoro sa však tento cieľ ukázal ako v blízkej budúcnosti nerealizovateľný a ohraničil sa na ambíciu využívať umelú inteligenciu na činnosti, v ktorých človeku síce nechýba inteligencia, ale z hľadiska množstva dát a nutnosti ich rýchlo spracovávať dokáže byť stroj (softvér) podstatne rýchlejší. Dnes sa jednotlivé výskumné tímy snažia o vytvorenie parciálnych algoritmov na riešenie najmä nedeterministických problémov.

Aplikovanie umelej inteligencie:

- Rozpoznávanie reči;
- Rozpoznávanie obrazu;
- Triedenie vzoriek;
- Navigácia v známom a neznámom teréne;
- Sledovanie cieľov procesov;
- Riadenie chodu robotov;
- Riadenie a plánovanie napr. výrobných procesov;
- Analýza a predpovedanie štatistických postupností (napr. obchodných, burzových informácií);
- Spracovanie a analýza dát z prostredia (prostredie výrobného podniku ale aj geológia, meteorológia, seizmika, zdravie človeka...);
- Kombinatorika;
- Reprezentácia zozbieraných dát;
- Dolovanie údajov – *data mining* – extrakcia vhodných dát;

¹³ Scherk, J., Pöschbacker-Tröscher, G., Wagner, K.: Künstliche Intelligenz – Artificial Intelligence. (Umelá inteligencia). 2018. Zdroj 1: *Künstliche Intelligenz – Artificial Intelligence*, Auftraggeber: BMVIT, Bundesministerium für Verkehr, Innovation und Technologie. Autori: Johannes Scherk, B.S.C., Mag. Gerlinde Pöschbacker-Tröscher, Karin Wagner, BSc.. Máj 2018.

¹⁴ Künstliche Intelligenz im Unternehmen, Deutschland. (Umelá inteligencia v podniku v Nemecku, Stratégia spolkovej vlády Nemecka). PwC Deutschland. 2018.

- Hranie hier, atď.

Jedným z najväčších problémov v oblasti umelej inteligencie je problém prezentovania poznatkov, pretože človek využíva na prezentovanie svojich vlastných poznatkov nielen zmysly, ale aj intuíciu, ktorá nie je zatiaľ strojom vlastná.

4.2 Prostriedky umelej inteligencie^{15, 16}

Umelá inteligencia je považovaná za kľúčovú technológiu budúcnosti a skrýva v sebe výrazný národohospodársky potenciál. Táto príručka má slúžiť aj na vysvetlenie, ako tento potenciál uchopiť a konkrétne, ako uchopiť kľúčové aspekty umelej inteligencie, najmä v priemyselných firmách, ale aj iných odvetviach.


Príručka taktiež uvádza hlavné trendy vývoja umelej inteligencie, ktoré prináša výskum a vývoj napríklad na univerzitách a vo výskumných centrách. Príručka je postavená na poznaní súčasného stavu vývoja týchto technológií a tiež realisticky načrtáva aj ich potenciál implementácie vo firmách.

Všeobecne sa od systémov umelej inteligencie očakáva také správanie, ktoré je vlastné predovšetkým človeku. Pri nasadení AI je pritom rozhodujúca schopnosť úspešne sa vysporiadať s novou situáciou, spracovávať nové dáta a informácie a z existujúceho poznania vecí generovať a vykonať potrebné závery a rozhodnutia. Presne táto schopnosť odlišuje systémy umelej inteligencie od IT systémov založených na klasických pravidlách, ktoré ale pri najmenšej zmene nastavenej úlohy musia byť nanovo naprogramované.

Nasledujúci prehľad prostriedkov umelej inteligencie poskytuje základné rozdelenie AI z pohľadu konkrétnych nástrojov umelej inteligencie a tiež aj z pohľadu vybraných konkrétnych služieb, v ktorých vieme nasadiť jednotlivé nástroje. Ďalšie kapitoly obsahujú aj konkrétne nástroje, ktoré sú pri danej službe z hľadiska použitia nosné. Prakticky je to uvedené v [Kapitole 4.6](#).

¹⁵ Potenziale der künstlichen Intelligenz in produzierenden Gewerbe in Deutschland – Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi) im Rahmen der zum Technologieprogramm PAiCE Platforms (Additive Manufacturing). iIT- Institut für Innovation a Technik GmbH, Berlín, Nemecko.

¹⁶ AI Talent in the European Labour Market. [Dostupné online](#).



Obrázok 4.1 Základné rozdelenie funkcionalít AI

4.2.1 Neurónové siete

Základnou vlastnosťou neurónových sietí (z angl. *neural networks*) je schopnosť abstrakcie pravidiel medzi vstupnými a výstupnými hodnotami prezentovanými vo vhodnej forme s následnou aplikáciou získaných pravidiel. Neurónové siete sú motivované biologickými neurónovými sieťami. Používajú sa najmä na klasifikáciu a zhlukovanie. Aplikácie nájdeme v regulačnej a simulačnej technike, na rozpoznávaní vzoriek (napr. obrázkov a písma), pri spracovaní prirodzeného jazyka, v analýze dát a znalostných systémov, predpovediach počasia, riadení, marketingu či optimalizácii.

4.2.2 Strojové učenie

Strojové učenie (z angl. *machine learning*) je všeobecný pojem pre získavanie poznatkov zo skúseností. Systém sa učí z príkladov a môže ich zovšeobecniť po dokončení fázy učenia a reagovať na rôzne vstupné hodnoty (situácie) bez toho, aby bol na ne explicitne naprogramovaný. Na tento účel algoritmy strojového učenia vytvárajú modely založené často na metódach štatistickej analýzy. V strojovom učení ide o to, že sa hľadajú pre jednotlivé pojmy ich charakteristické vlastnosti. Z celého radu možných aplikácií je možné uviesť: automatizované diagnostické metódy, rozpoznávanie podvodov s kreditnými kartami, analýzy na akciových trhoch, klasifikáciu nukleotidových sekvencií, rozpoznávanie reči a textu, ako aj autonómne systémy.

4.2.3 Fuzzy logika

Fuzzy logika je odbor matematiky odvodený z teórie *fuzzy* množín, v ktorom sa logické výroky ohodnocujú stupňom príslušnosti (tiež index vágnosti), ktorého hodnoty sú v intervale od 0 do 1. V klasickej výrokovej logike sa výroky ohodnocujú buď ako pravdivé, alebo nepravdivé – v binárnom vyjadrení ako 1 alebo 0. Fuzzy logika umožňuje matematicky vyjadriť pojmy ako „trochu“, „dosť“ alebo „veľa“. Presnejšie, umožňuje vyjadriť čiastočnú príslušnosť k množine. Fuzzy logika je vhodnejšia pre

množstvo reálnych rozhodovacích úloh. Používa sa napríklad v umývačkách riadu, pračkách, autopilotoch, parkovacích senzoroach, atď.

4.2.4 Genetické algoritmy – genetické programovanie

Genetické programovanie využíva metódy podobné biologickej evolúcii pri vytváraní počítačových programov, ktoré čo najlepšie riešia danú úlohu. Používajú sa evolučné operátory (najčastejšie výber, rekombinácia a mutácia) a populácia riešení na získanie globálne optimálneho rozčlenenia údajov. Pri riešení úloh genetickým prístupom sú kandidáti riešení kódovaním na spôsob chromozómov. Hlavnou aplikačnou oblasťou je riešenie optimalizačných úloh.

4.2.5 Expertné systémy

Expertný systém je program alebo systém kooperujúcich programov, ktorý rozhoduje alebo rieši v istej špecializovanej oblasti (financie, medicína) s použitím znalostí a pravidiel definovaných expertmi z príslušnej oblasti. Typické pre expertné systémy je explicitná reprezentácia znalostí, často tak, že im rozumie človek (človek je častokrát aj zdrojom týchto znalostí). Naproti tomu systémy založené na strojovom učení majú znalosti reprezentované v modeli, ktorý nie je pre človeka priamo interpretovateľný.

4.3 Prínosy a postupy zavedenia umelej inteligencie¹⁷

4.3.1 Hlavné impulzy pre zavedenie umelej inteligencie

Vo svete sa veľmi často stretávame s prípadmi, v ktorých firmy hodnotia tému AI ako relevantnú, ale stále nevedia v tomto smere navrhnúť nič konkrétne. Ak ich predstava o nasadení AI nenadobudne konkrétnejšie predstavy, môžu byť časom vyradené z hospodárskej súťaže. Európa je aj v tejto oblasti vystavená konkurenčným nevýhodám, najmä voči konkurentom z Ázie a USA.

AI umožňuje firmám vytvárať nové obchodné modely. Aplikácie AI sú rôzne, od automatizácie, cez chatboty, až po nové služby, produkty a obchodné modely. Základom pre nasadenie AI je v súčasnosti analýza dát pre rozhodovanie (70 %) a automatizáciu procesov (63 %) – toto sú dve najdôležitejšie aplikácie.

Aj malé firmy môžu využiť niektoré príklady zavedenia AI vo veľkých firmách. Prieskum v Nemecku ukázal, že spoločnosti sú primárne zamerané na AI, zamestnávajú viac ako 500 ľudí (83 %) a/alebo generujú tržby až do 1 miliardy Eur (72 %). O niečo viac ako polovica pridružených spoločností sú poskytovatelia služieb (51 %).

V sektoroch ako sú financie, poisťovníctvo a zdravotníctvo môže byť návratnosť investícií do aplikácií AI obzvlášť vysoká. V týchto odvetviach si už mnoho strán na mnohých miestach medzi sebou vymieňa veľké množstvo údajov vo veľkom počte opakujúcich sa procesov. Okrem toho, finančné inštitúcie a poisťovací priemysel sú s využitím umelej inteligencie relatívne oboznámení, pretože používajú systémy AI na predchádzanie podvodom a praniu špinavých peňazí.

¹⁷ Fraunhofer: Trends für die künstliche Intelligenz. Fraunhofer Gesellschaft e.V. 2017. [Dostupné online.](#)

Veľké podniky s vysokým obratom sa dokážu prirodzene ľahšie zhostiť investície do AI. Táto príručka má ale napomôcť aj menším firmám, ako a za akých predpokladov môžu využiť nástroje umelej inteligencie v prospech svojej činnosti a zvýšiť konkurencieschopnosť aj v rámci európskeho trhu.

Ako každý významný transformačný proces, aj AI transformácia firmy je aj pri najlepšej exekúcii niekoľkoročným projektom. Navyše, podobne ako digitálna transformácia, toto úsilie nemá a ani by nemalo mať konkrétny, ľahko dosiahnuteľný cieľový stav, ide skôr o postupné a systematické približovanie sa ideálu firmy, ktorá naplno využíva potenciál, ktorý AI ponúka.

Jeden z najvýznamnejších myšlienkových lídrov v oblasti AI, Andrew Ng (v roku 2013 zaradený časopisom Time medzi 100 najvplyvnejších ľudí sveta), prirovnáva nástup AI k nástupu internetu či elektriny. Nie každý kamenný obchod s vlastnou webovou stránkou môžeme považovať za online spoločnosť. Rovnako nie každú firmu s implementáciou *deep learning* technológie môžeme považovať za AI firmu. V publikácii *AI transformation playbook*¹⁸ Ng ponúka 5-fázový plán AI transformácie, určený prevažne pre veľké globálne firmy s valuáciou nad 500 mil. USD.

Nakoľko väčšina slovenských firiem so skutočne zmysluplným využitím AI na podporu kľúčových biznis procesov ešte iba začína, v tejto kapitole sa obmedzíme na prvú fázu zo spomínaných piatich: realizáciu pilotných projektov, ktoré pomôžu firme získať potenciál potrebný na budovanie či rozširovanie interného AI tímu a ďalekosiahle zmeny naprieč organizáciou.

4.3.2 Voľba pilotných projektov

AI transformácia vyžaduje okrem iných zdrojov aj podporu všetkých dôležitých oddelení firmy a komplexné zmeny infraštruktúry, procesov a organizačnej štruktúry. Prínos týchto opatrení často nie je okamžite evidentný. Skorý úspech pilotných projektov je preto absolútne kľúčový pre zaistenie podpory celej iniciatívy naprieč spoločnosťou.

Pilotné AI projekty nemusia riešiť najpálčivejšie výzvy, ktorým firma čelí. Musia však byť dostatočne prínosné a zmysluplné, aby sa ľudia v organizácii zoznámili s AI a pochopili, že investícia do ďalších AI projektov má zmysel. Pre udržanie podpory je vhodné voliť také projekty, ktoré prinesú hmatateľné výsledky do 6 až 12 mesiacov.

4.3.3 Zloženie tímu

Nevyhnutná je spolupráca AI tímu a ostatných interných tímov. Práve správna forma zapojenia interných tímov, spoločne s profesionalitou AI tímu sú kľúčovými faktormi úspechu projektu. Správne zloženie projektového tímu sa do istej miery líši v závislosti od aplikačnej domény, špecifiká uvádzame v nasledujúcich kapitolách. Základná odporúčaná štruktúra je však pre všetky domény rovnaká, pričom viaceré z rolí môžu byť zároveň obsadené tými istými ľuďmi:

AI tím – novozaložený alebo externý tím, ktorý nemusí nutne mať hlbokú doménovú znalosť. Absolútne nevyhnutná je expertíza nielen v tvorbe AI algoritmov, ale aj v reáliách ich uvedenia do prevádzky a integrácie do infraštruktúry podniku. AI projekty sa výrazne líšia od tradičných softvérových či automatizačných projektov, skúsenosti z týchto oblastí, preto rozhodne nie sú postačujúce.

¹⁸ AI Transformation Playbook - How to lead your company into the AI era. [Dostupné online.](#)

Projektový tím musí mať aspoň jedného senior experta s niekoľkými rokmi praxe v pokročilom AI tíme, ktorý úspešne viedol implementáciu projektov s istým minimálnym rozsahom. Ak takýto expert nie je dostupný, je pre potreby pilotného projektu výrazne odporúčaná spolupráca s externým dodávateľom. Aj v prípade využitia externého tímu je však účasť na projekte príležitosťou na vzdelanie interných zamestnancov, ktorí neskôr môžu tvoriť interný AI tím.

Nositeľ projektu – jasne určená osoba zodpovedná interne za úspešnú exekúciu projektu. V prípade nejasnej štruktúry zodpovednosti a komunikačnej matice smerom na AI tím hrozí spomalenie exekúcie projektu z dôvodu nedostatočnej súčinnosti interných tímov.

Zástupca používateľov (interného klienta) – najmä v úvodnej fáze návrhu je nutné intenzívne zapojenie zástupcu oddelení, ktoré budú mať z výsledkov projektu úžitok a budú riešenie používať. Nedostatočné prispôsobenie riešenia skutočným potrebám používateľa je častým dôvodom zlyhania (nielen) pri AI projektoch. Pre AI projekty je však príznačná ich dynamická povaha a vyššia miera zmeny pôvodných indikatívnych zadaní. Preto je nevyhnutná istá miera prítomnosti zástupcu používateľov minimálne pri významných projektových míľnikoch.

Doménoví experti – doménový expert môže byť totožný so zástupcom používateľov. Úlohou doménového experta je poskytovať AI tímu podporu pri procese pochopenia štruktúry a významu dát, ako aj širších reálií predmetného procesu či technológie. Kvalitný AI tím s podporou doménového experta je pre úspešný projekt oveľa prínosnejší ako tím stredne zdatných AI expertov, ktorí sú zároveň doménovými expertami.

Interné IT a iné technologické tímy – ich zapojenie je nutné hlavne v úvode (návrh integrácie riešenia) a závere projektu (samotná integrácia riešenia). Okrem IT môže ísť aj o hardvérových inžinierov, technikov strojov či konštruktérov. V *big data* projektoch je možná aj aktívna účasť interného *big data* tímu, hlavne v roli tzv. dátových inžinierov, ktorí zodpovedajú za integráciu jednotlivých dátových zdrojov a niekedy aj za transformáciu dát do požadovaného formátu, špecifikovaného AI tímom

4.3.4 Harmonogram pilotného projektu

Základné fázovanie AI projektov by malo kopírovať nasledovnú štruktúru:

1. Analýza uskutočniteľnosti (2 – 5 týždňov)

Predmetom tejto fázy je identifikácia ideálne viacerých kandidátskych projektov a ich špecifikácia, ako aj posúdenie uskutočniteľnosti prostredníctvom expertnej analýzy, analýzy dát či zhotovenia jednoduchého prototypu.

Skúsený AI expert vie identifikovať možné skryté úskalia vyplývajúce z povahy dát, variability prevádzkových podmienok či potenciálnych zmien, ako aj navrhnúť nečakane jednoduché riešenia možných problémov. Častým dôvodom zlyhania je práve to, že sa neskúsený tím pokúša o zostrojenie príliš ťažko zostrojiteľného riešenia. Takéto tímy často podcenia variabilitu skutočných dát a v ďalších fázach zostroja riešenie, ktoré funguje iba v laboratórnych podmienkach. Ďalším bežným zlyhaním je použitie nevýpovednej či dokonca úplne chybné metodiky evaluácie výkonnostných parametrov prototypu, ktorá zvykne (často nepriamo) umelo navyšovať úspešnosť prototypov.

Medzi fázami 1 a 2 je často potrebný určitý čas určený najmä na zber, doručenie či anotáciu dát interným tímom. Ešte predtým je z uskutočniteľných projektov nutné vybrať tie, ktoré sa budú implementovať.

2. Vývoj AI (4 – 15 týždňov)

Predmetom tejto fázy je vývoj AI jadra riešenia – iteratívny proces vývoja, tréningu, evaluácie a ďalšieho vývoja, spojený s vizualizáciou a analýzou dát, či testovaním hypotéz. Výsledkom tejto fázy je spravidla zatiaľ nezaintegrovaný model a vyhodnotenie jeho úspešnosti, často vykonané iba tzv. *offline* (vykonané na jednorazovo exportovanej vzorke produkčných dát). Skúsený AI tím si iniciatívne pýta súčinnosť interných tímov a dokáže v prípade nepredvídanej zmeny či štúdiou uskutočniteľnosti neodhalenej komplikácie včas prispôbiť parametre či dokonca výstupy riešenia. V prípade uspokojivého naplnenia kritérií sa môže začať ďalšia fáza.

3. Integrácia (2 – 12 týždňov)

Predmetom tejto fázy je zavedenie riešenia do prevádzky – dátová integrácia, dizajn, tvorba a integrácia užívateľských rozhraní – GUI (grafické užívateľské rozhranie, z angl. *Graphical User Interface*), implementácia automatického spúšťania predikcií a evaluácie a v prípade potreby aj automatického tréningu AI. Výsledkom je finálne riešenie, po zaškolení obsluhy a administrátorov spustené do (pilotnej) prevádzky. Na rozdiel od tradičných IT systémov, ktoré môžu byť vo veľa prípadoch úplne prebraté interným IT, je správa AI riešení náročnejšia na expertízu správcu. Dohodnutie istého režimu monitoringu riešenia zo strany AI tímu zaručí stabilitu aj pri zmenách povahy dát, vyvarovanie sa chýb plynúcich zo zlej interpretácie výsledkov či medzivýsledkov a plné využívanie potenciálu tréningu riešenia na stále zväčšujúcej sa báze dát.

4. Vyhodnotenie projektu

Pre úspech projektu je nutné už v začiatkoch definovať ciele a merateľné metriky úspechu, ktoré značia tvorbu biznis hodnoty. Výpovedná hodnota týchto metrík musí byť odsúhlasená interným klientom. Po uplynutí istého času od spustenia do prevádzky môže vďaka tomu byť projekt vyhodnotený. Zároveň takéto transparentné nastavenie kritérií úspechu umožňuje zladenie očakávaní jednotlivých aktérov a znásobuje vlnu pozitívnej energie, ktorá v prípade úspechu následne podporuje interný dopyt po ďalších AI riešeniach.

4.4 Predpoklady pre zavedenie umelej inteligencie v podnikoch^{19, 20}

Z hľadiska predpokladov sme popísali 6 kľúčových predpokladov, ktoré firma musí vyhodnotiť, aby mohla uvažovať o nasadení AI riešení.

1. Proces

Firma musí byť schopná jasne identifikovať procesy, ktoré chce transformovať alebo optimalizovať. Jednotlivé kroky procesov musia byť jednoznačne definované.

Napriek tomu, že využitie umelej inteligencie umožňuje voľnejší opis rozhodovacích podmienok, jednotlivé úkony v rámci procesu musia byť definované pomerne exaktne. Pokiaľ ide o potenciál umelej inteligencie s využitím strojového učenia, musia procesy nastaviť tiež spôsoby získavania

¹⁹ Institut für Innovation + Technik: Potenziale der künstlichen Intelligenz in produzierenden Gewerbe in Deutschland – Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi) im Rahmen der zum Technologieprogramm PAiCE Platforms (Additive Manufacturing). Publikované v IiIT- Institut für Innovation + Technik GmbH, Berlín, Nemecko.

[Dostupné online.](#)

²⁰ AI Talent in the European Labour Market. [Dostupné online.](#)

informácií tak, aby bolo možné využiť jednak uložené historické dáta a jednak riadiť procesy na báze online dát, s ktorými už AI bude schopná pracovať. Procesy využívajú schopnosť AI vlastného učenia sa a adaptácie na interné a externé vplyvy, schopnosť anticipovať budúci vývoj, schopnosť optimalizovať a schopnosť učenia sa z historických a aktuálnych dát.

2. Dáta

Existencia a dostupnosť dát je podmienkou pre nasadzovanie AI riešenia. Možnosť nasadiť umelú inteligenciu je veľmi často otázkou množstva a kvality dát, ktoré má používateľ umelej inteligencie k dispozícii. Ideálne sú dáta v štruktúrovanej podobe, predovšetkým ak sú generované viacerými spôsobmi a z viacerých zdrojov prostredníctvom technickej infraštruktúry, teda z rozličných už nasadených informačných systémov a IoT komponentov senzorov.

Iným spôsobom získania štruktúrovaných dát sú čiarové kódy, QR kódy či RFID technológie. Mobilné zariadenia možno použiť na jednoznačnú identifikáciu prevádzkových zariadení, materiálu. Údaje z centrálného úložiska môžu byť dostupné pracovníkom na intranete, alebo prenosom prostredníctvom web aplikácií, PDA, tabletov či mobilných aplikácií.

Umelá inteligencia je schopná uskutočniť aj prevod dát z neštruktúrovanej podoby na štruktúrovanú. Pri optimalizácii administratívnych úloh sa často využíva spracovanie prirodzeného jazyka (*Natural Language Processing – NLP*), vďaka ktorému je možné spracovať veľké množstvo textových informácií. Taktiež je možné využiť dáta z naskenovanej dokumentácie.

3. Aplikácie

Umelá inteligencia je zväčša nadstavbou alebo ďalšou vrstvou, ktorá sa nasadzuje za účelom optimalizácie už existujúcich aplikácií. Niektoré sú z hľadiska dát zdrojové alebo naopak cieľové pre *end-to-end* proces a bude ich treba integrovať. Dôležité bude rozhodnúť, či je vhodnejšie riešiť už integráciu s existujúcimi aplikáciami, alebo niektoré aplikácie nahradiť úplne novými. Fungovanie výrobných procesov sa prípad od prípadu zásadne líši. Pri každom sa dá predpokladať iné vybavenie strojov, odlišné budú aj jeho informačné systémy. Vo výrobných formách sa najčastejšie stretneme s aplikáciami a skratkami MES (*Manufacturing Execution System*), PLM (*Product Lifecycle Management*), ERP (*Enterprise Resource Planning*), systémy pre zber dát ako sú MES, SCADA (*Supervisory Control And Data Acquisition*) často obohatené o ďalšie údaje z ERP, CMMS (*Computerized Maintenance Management System*), EAM (*Enterprise Asset Management*). Firma môže disponovať viacerými aplikáciami od rôznych výrobcov.

4. Infraštruktúra

Do infraštruktúry zahrňame koncové zariadenia potrebné pre zber dát, senzory, ale aj potrebný výpočtový výkon, čiže počítače.

Klasické IT, čiže počítače, bývajú v súčasnosti priamo vo fabrikách nahradzované cloudovými riešeniami, zákazník si zakúpi službu nejakého softvérového riešenia a nezaobrá sa technickou infraštruktúrou, na ktorej toto riešenie beží.

Pomerne novým prvkom je infraštruktúra súvisiaca s internetom vecí (IoT). Sem zahrňame podnikové zdroje dát, čiže senzory, riadiace jednotky, aplikácie, databázy, ale aj architektonické prvky ako IoT brány na zber, spracovanie a prenos dát do podnikovej siete, IoT platforma na analýzu a vizualizáciu dát, v niektorých prípadoch aj *Edge Computing*, čo je hardvérový produkt – zariadenie IoT brány –

doplnené o analytické softvérové nástroje obsahujúce všetky nevyhnutné funkcie pre riadenie dát, zhromažďovanie a spracovanie dát, ich dočasné ukladanie a analýzu dát a udalostí v reálnom čase.

5. Ľudia

Úspech zavedenia AI z pohľadu ľudských zdrojov vyžaduje dobrú súhru viacerých kvalifikácií IT odborníkov (napríklad dátových vedcov, biznis analytikov, softvérových inžinierov a iných špecialistov) s vlastními procesov, čiže s inžiniermi z výroby, pracovníkmi kvality a údržby, marketingovými pracovníkmi. Bude stúpať význam ľudí schopných riešiť najmä otázky kybernetickej bezpečnosti.

Čo sa týka prevádzky, riešenia umelej inteligencie majú rôznu mieru autonómie vo vzťahu k ľudskej práci – niektoré sú plne autonómne, iné ľudí odbremení len čiastočne.

6. Organizácia

Z pohľadu organizácie práce pôjde o vytvorenie dočasných alebo trvalých tímov, možno o zmeny kompetenčného modelu, prípadne externalizáciu služby či procesu. Vo firmách bude potrebné nastaviť a budovať tímovú kultúru adekvátnu náročnosti zavedených riešení a miere zmien, ktoré tieto riešenia prinesú. Vhodné je mať aspoň externé pracovníka, ktorý sleduje potenciál podporných finančných mechanizmov a sleduje túto oblasť vo svojej doméne v rámci EÚ, ale i v celosvetovom meradle.

4.5 Domény, v ktorých sa umelá inteligencia nasadzuje do praxe

Tvorcovia príručky si uvedomujú, že na Slovensku už nie je možno hlavným problémom nedostatok znalostí z oblasti moderných digitálnych technológií, medzi ktoré patrí aj samotná umelá inteligencia. Na týchto témach pracuje rad odborníkov, ktorí sa zapájajú do projektov minimálne v európskom priestore. Štúdia *Podpora umelej inteligencie na Slovensku* podrobne zmapovala výstupy vedy a výskumu v oblasti AI na Slovensku.

Ďalším krokom je dnes poskytnúť slovenskému priemyslu nielen informácie, ale aj praktické návody, ako tieto poznatky uchopiť. Ako zrozumiteľné a uchopiteľné sa nám javí popísať ťažiská pri využití AI tiež podľa konkrétnych domén, v ktorých je ich využitie z pohľadu ponuky technológií a riešení už dobre pripravené.

Tento zoznam domén nie je zďaleka konečný, avšak v každej z nich existujú riešenia, ktoré sú k dispozícii na slovenskom IT trhu. Úvodom je stručná charakteristika riešení aj s naznačením, pre aké typy spoločností a činností sú systémy AI vhodné.

Optimalizácia výroby

Vhodné pre firmy z oblasti výrobného a spracovateľského priemyslu, ktoré disponujú dátami v rôznych informačných systémoch, predovšetkým výrobných. Zmysluplné využívanie AI teda predstavuje pokračovanie alebo nadstavbu už naštartovaného procesu automatizácie.

Pod optimalizáciou výroby rozumieme širokú rôznorodú skupinu umelej inteligencie a matematického modelovania s cieľom efektívneho nakladania so zdrojmi (teda aj nákladmi pri vstupe), maximalizácie výstupov (teda efektívnosti procesov) a minimalizácie negatívnych výstupov daného procesu.

Často tu nehovoríme o jednom monolitickom riešení, ako skôr o súbore čiastkových menších riešení, či dokonca úzkej spolupráci zmiešaného tímu, v ktorom dátoví analytici priebežne poskytujú dátami podloženú validáciu pre rôznorodé hypotézy a rozhodnutia doménových expertov.

Riadenie kvality, výstupná a laboratórna kontrola a analýza

Vhodné pre firmy rozličného typu, v ktorých kontrola, hlavne v sériovej a masovej výrobe, hrá významnú rolu a v ktorých je možné nahradiť vizuálnu kontrolu výrobkov, či už v priebehu výroby alebo na výstupe už hotového výrobku.

Plná automatizácia pomocou *vision* systému na báze umelej inteligencie je možná tam, kde pre odhalenie defektu alebo analýzu vzorky postačuje čisto vizuálna kontrola bez potreby ďalšej analýzy. Ide najmä o sériovú výrobu, v ktorej nasadenie AI prispieva k odhaleniu počtu reklamácií.

Kľúčom k nasadeniu AI je mať dostatok referenčných vzoriek a identifikátorov pre strojové rozhodovanie. Technologicky pôjde o nasadenie tzv. *machine vision* systémov, ktorých základom je už vyšší stupeň AI fungujúci na neurónových sieťach.

Prediktívna údržba

Vhodné pre rozličné firmy, v ktorých dostupnosť a spoľahlivosť strojov a zariadení má rozhodujúci význam pre prevádzku strojov, výrobných a montážnych liniek, a zároveň je možné tieto ukazovatele monitorovať pomocou inteligentných snímačov, ktoré dokážu kedykoľvek zobrazíť stav zariadenia.

Prediktívna údržba je špeciálnym prípadom preventívnej stratégie a je zameraná na včasné identifikovanie varovných príznakov pomocou zberu prevádzkových parametrov zariadení a softvérových nástrojov, ktoré ich analyzujú a upozornia na blížiacu sa poruchu. Údržba bude včas informovaná a následne vykoná profylaktický zásah len na častiach, ktorých stav bol zaznamenaný ako potenciálne rizikový.

Presné diagnostické informácie o stavoch prístrojov a zariadení umožňujú prevádzkovému personálu s určitou presnosťou rozhodnúť, či je na zabránenie vzniku hroziacej poruchy potrebný okamžitý zásah, alebo či môžu pokračovať v činnosti až do nasledujúceho riadne naplánovaného odstavenia. Činnosti založené na predikcii zvyšujú spoľahlivosť kritických prvkov a výsledkom je skrátenie drahých prerušení prevádzky.

Inteligentná automatizácia nevýrobných procesov

Vhodné pre spoločnosti, ktoré (zväčša nevýrobné) procesy vyhodnotia ako opakovateľné, nevyžadujúce vyšší stupeň ľudskej kreativity.

Dôležitým predchodcom používania umelej inteligencie v mnohých prípadoch je robotická procesná automatizácia (RPA), avšak nejde o fyzického robota, ale softvér, ktorý čiastočne alebo plne vykonáva úlohy administratívneho pracovníka. RPA sa týka širokej škály procesov, ktoré vykazujú prvky opakovateľnosti a nevyžadujú ľudskú invenciu od evidencie až po prípravu manažérskych rozhodnutí, triedenie pošty, vystavenie a zaslanie objednávky na schválený nákup, atď.

Pri optimalizácii administratívnych úloh sa často využíva spracovanie prirodzeného jazyka (*Natural Language Processing – NLP*), vďaka ktorému je možné spracovať veľké množstvo textových informácií a previesť ich do štruktúrovanej podoby, t. j. do podoby, s akou informačné systémy dokážu ďalej pracovať. Využitím pokročilých metód analýzy textu je možné napr. automaticky identifikovať duplicitné alebo veľmi podobné záznamy. Z textu je tiež možné automaticky extrahovať dodatočné informácie (metadáta), ktoré v danom čase neboli vyplňané, prípadne ich opakované zadávanie zdržuje.

V prípade, že dáta nie sú dostupné v digitálnej podobe, aj tu je možné využiť umelú inteligenciu pri extrakcii dát z naskenovanej dokumentácie a využitia techník, ako sú OCR, prípadne aj v kombinácii s ďalšími metódami pre identifikáciu správnych miest. V dnešnej dobe sú však zvyčajne informácie dostupné v digitálnej podobe a stačí ich len správne analyzovať.

Energetický manažment

Energetický manažment je určený pre všetky spoločnosti, v ktorých hrá významnú rolu spotreba energie v budove alebo vo výrobnom procese. Výsledkom je zníženie nákladov na energiu pre klienta, lepšie prostredie pre užívateľov budovy alebo ochrana životného prostredia vďaka zníženiu uhlíkovej stopy.

Energetický manažment (EM) z pohľadu úspor energie môžeme charakterizovať ako systematický proces monitorovania, kontrolovania a vykonávania opatrení smerujúcich k optimalizácii spotreby energie za účelom zníženia energetickej náročnosti a zlepšenia energetickej účinnosti. Vychádzame z princípu „*nemôžete riadiť to, čo nemeriate*“.

EM tiež poskytuje cenné sekundárne informácie, ktoré môžu byť použité pre rozpočtové prognózy, porovnávanie, a čo je dôležité, pre energetického manažéra i overovanie úspor nielen energií, ale aj vody, stlačeného vzduchu, a technických plynov, inteligentné riadenie osvetlenia, kúrenia a ventilácie, meranie teploty a vlhkosti, monitoring prítomnosti výbušných a nebezpečných plynov, detekciu zadymenia a mnohé ďalšie.

Marketing a podpora predaja

Určené pre retail, ale aj pre firmy, ktoré si samy zabezpečujú odbyt svojich výrobkov formou maloobchodu. Maloobchod má k dispozícii obrovské množstvo dát, či už štruktúrovaných alebo neštruktúrovaných, interných alebo externých, čo vytvára obrovské množstvo príležitostí pre využitie nástrojov pokročilej analytiky alebo umelej inteligencie.

Umelá inteligencia v retaili sa však opiera hlavne o neštruktúrované dáta (e-mailová komunikácia, telefonické hovory, komunikácia s call centrami, videá, príspevky na Facebooku, diskusie a iné formy online komunikácie). Tieto dáta vie využiť strojové učenie ako jednu z metód umelej inteligencie.

Kľúčové ciele sú zvýšenie tržieb a hrubej marže, zníženie nákladov (zamestnanci, skladové zásoby) a zvýšenie spokojnosti zákazníka.

Online predaj

Vhodné pre spoločnosti, ktoré predávajú online, ale aj pre tie, ktoré s takouto formou obchodovania chcú začať. Vzhľadom na to, že nástroje umelej inteligencie sú dnes pomerne rozšírené, sú aj cenovo dostupné a existuje aj množstvo nízkonákladových alternatív.

Témy ako *big data*, umelá inteligencia, strojové učenie alebo blockchain patria momentálne medzi veľmi skloňované a výrazne sa dotýkajú všetkých vertikál v rámci všetkých odvetví.

Inovatívnymi lídrami a vzormi v tomto odvetví sú spoločnosti ako Amazon, Apple, Farfetch alebo Alibaba. Ak sa pozrieme na príbehy týchto spoločností, ich úspech bol založený hlavne na správnej práci s dátami. Amazon sa aj napriek tomu, že veľkú časť jeho tržieb tvorí maloobchodný predaj, považuje za technologickú firmu.

Podpora zákazníkov a používateľov

Vhodné pre všetky spoločnosti, ktoré na diaľku obsluhujú svojich klientov, a ktoré sa venujú telemarketingu, alebo ktoré poskytujú dištančné služby svojim vlastným pracovníkom napríklad formou helpdesku. Ide o nasadenie virtuálneho digitálneho asistenta (tzv. *Chatbot*), ktorý pomocou umelej inteligencie napodobňuje komunikáciu človeka. Chatbot môže byť doplnený o znalostné vyhľadávanie v poskytnutých dokumentov alebo o poskytovanie informácií z databáz, informačných systémov, alebo dokáže prepojiť používateľa na živého agenta v call centre.

Umelú inteligenciu je možné nasadiť napríklad v prípadoch: systém automatizovaného rozpoznávania reči, rozpoznanie prirodzeného jazyka, rozpoznávanie textových dát (meno, priezvisko, číslo objednávky), riadenie dialógu pomocou dialógového manažéra, systém prevodu reči na text, atď.

4.6 Doménovo orientované príklady, predpoklady nasadenia a prínosy

4.6.1 Optimalizácia výroby

Popis

Pojmom *Optimalizácia výroby* označujeme širokú, heterogénnu skupinu aplikácií umelej inteligencie a matematického modelovania, motivovaných cieľom úspory zdrojov, maximalizácie pozitívnych výsledkov a minimalizácie alebo ohraničenia negatívnych výsledkov.

Podľa rozsahu aplikácie ich môžeme rozdeliť do týchto skupín:

- Čiastková optimalizácia – optimalizácia procesu alebo prevádzky stroja;
- Holistická optimalizácia výroby – zvyšovanie efektivity výroby ako celku pri zohľadnení externých faktorov, ktoré výrobu priamo, ale aj nepriamo ovplyvňujú (logistika, sklad, objednávkový systém, mapa fyzických limitácií popisovaného systému).

Medzi často sa vyskytujúce ciele patria:

- Efektivita využívania zdrojov – efektívnejšia prevádzka, eliminácia plytvania;
- Plynulosť výroby – eliminácia odchýlok, odstránenie úzkych miest a zvýšenie taktu;
- Model fyzických limitov popisovaného systému – modelovanie materiálových tokov a priepustnosti výrobných ostrovov.

Súvisiacimi témami sú tiež prediktívna údržba strojov, energetický manažment (znižovanie spotreby energií) a manažment kvality (znižovanie miery výskytu nekvalitných výrobkov, zvyšovanie kvalitatívnych parametrov výrobkov). Väčšina zákonitostí uvedených v tejto kapitole je uplatniteľná aj pri optimalizácii nákupu, predaja, logistiky či iných procesov.

Práve systémy optimalizácie výroby sú výraznou časťou holistického konceptu Industry 4.0, ktorého ťažiskom je dôraz na prepojenosť systémov, využívanie dát a optimalizáciu procesov v podniku a s ním súvisiacim obchodným ekosystémom.

Predpoklady

1. Proces

Pre optimalizáciu je vhodný proces, pri ktorom existuje silný predpoklad, že jeho optimálnym využitím možno dosiahnuť zlepšenie jeho výsledkov. Nutným predpokladom je spravidla (domnelá) existencia závislosti medzi parametrami (nastavením) procesu a jeho súčasnými či budúcimi výsledkami. Tento zdanlivo triviálny predpoklad mnoho procesov nespĺňa, čo akékoľvek snahy vopred odsudzuje na neúspech. Vhodné je, samozrejme, vybrať proces, pri ktorom zlepšenie výsledkov prináša výrazné ekonomické benefity.

Vhodným kandidátom je napríklad proces, pri ktorom už pred aplikáciou pokročilého riešenia na báze umelej inteligencie existoval pracovník a/alebo expertný systém, ktorý vykonával rozhodnutia s cieľom optimalizácie tohto procesu (napríklad plánovanie výroby, interná logistika, atď.).

2. Dáta

Ak už existuje systém/pracovník, zodpovedný za optimalizáciu daného procesu, do riešenia by mali vstupovať minimálne všetky podkladové dáta, ktoré má systém/pracovník k dispozícii. Je vhodné doplniť aj akékoľvek dodatočné dáta, pri ktorých je predpokladaná súvislosť s výsledkami procesu.

Nevyhnutnou kategóriou dát sú dáta ilustrujúce výsledky procesu (v prípade manažmentu kvality napr. počty a typy defektov). Obvyklým zdrojom týchto dát je databáza MES systému alebo *historian* databáza na SCADA úrovni. Neveľmi vhodné je využitie dát vpisovaných manuálne, nakoľko obsahujú chyby a ich použitie spravidla znemožňuje plnú automatizáciu procesu. Najvhodnejším zdrojom dát o kvalite sú výsledky automatických systémov kontroly kvality, akými sú napríklad *machine vision* systémy pre vizuálnu inšpekciu výrobkov.

Pri nedostatočnej kvantite či kvalite dát je vhodné extrapolovať nameranú vzorku dát voči dátam zakúpeným na trhu (dátová banka, anonymizované dáta od poskytovateľa platformových služieb, atď.).

3. Aplikácie

Je potrebná integrácia so zdrojom dát. V prípade, ak má systém poskytovať iba podklad pre rozhodnutie ľudského experta, je nutné iba zabezpečenie vhodného užívateľského rozhrania (grafy, tabuľky, semaforey atď.). V prípade, ak má byť výsledkom automatizácia rozhodovania, je nutná integrácia rozhraní riešenia na riadiace systémy daného procesu (MES, SCADA, Historian DB, atď.). V prípade čisto analytických, jednorazovo doručených výsledkov (napríklad kľúčové faktory spôsobujúce nízku kvalitu), samozrejme, nevzniká akákoľvek potreba integrácie výstupov, avšak je nutná spätná propagácia na vstup preto, aby zabezpečila správne fungovanie algoritmov strojového učenia.

Alternatívou je napríklad aj distribuovaná forma umelej inteligencie, ktorú najčastejšie nájdeme v oblastiach *embedded AI*, v ktorých sa o prepočítavanie váhy vzťahov stará výrobca zariadenia, pričom obnovovanie konfigurácie je nutné zabezpečiť prevádzkovateľom zariadenia alebo na základe zmluvy o prevádzke systému s dodávateľským subjektom.

4. Infraštruktúra

Potrebné je sprístupnenie dát v databázach podniku (získavaných z rôznych zdrojov). Pre dodatočný zber dát je možná inštalácia senzorov. Pre potreby prezentácie výsledkov je vhodné sprístupniť výsledky a dodatočné informácie, riešenia na obrazovkách v rámci podnikovej siete.

Pri návrhu infraštruktúry umelej inteligencie netreba zabúdať na AI čipy, ktoré sú už súčasťou zariadení, napríklad priemyselné kamery, adaptívne regulátory, atď. a zohľadniť tieto výpočtové/kontrolné kapacity pri návrhu systému.

5. Ľudia

Pre úspech projektu je absolútne nevyhnutné a vhodné skoré zapojenie procesných inžinierov, pracovníkov kvality a/alebo iných manažérov zodpovedných za daný proces pri definovaní cieľov, čiastkových úloh, ale aj pri poskytovaní odborných vedomostí implementačnému tímu. V prípade, že sa od nich vyžaduje nasledovanie odporúčaní systému, alebo existuje riziko narušenia funkcie systému zavinením ľudského faktora, je takisto nutné zaškolenie radových pracovníkov a operátorov dotknutých liniek.

Profily na strane zadávateľa:

- Vedúci výroby a procesní inžinieri spolupracujú s dátovými vedcami na určení problémov a cieľov;
- Operátori na základe školení vykonávajú komplementárne úlohy a fungujú ako eskalačný stupeň;
- Informatici zodpovedajú za prevádzku výpočtovej techniky a sieťovej infraštruktúry;
- Niektoré z požadovaných pozícií môžu byť poskytnuté zástupcami tretích strán, externými konzultantmi.

Profily na strane dodávateľa:

- Dátoví inžinieri spravujúci dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;
- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- Architekti IT spravujúci základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Vývojári aplikácií nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Programátori a ďalší IKT špecialisti zodpovedajú za implementáciu hardvérových, ale aj softvérových riešení;
- Experti na vizualizáciu a interpretáciu dát.

6. Organizácia

Pre úspech projektu je prínosná častá interakcia odborného tímu a implementačného tímu. Dôležitými faktormi ovplyvňujúcimi technický úspech, ale aj budúcu využiteľnosť riešenia, sú pravidelné stretnutia, vhodne nastavené mílniky a prezentácie čiastkových cieľov projektu, jasná komunikačná matica, ale hlavne dostatočná alokácia odborného tímu, proaktívne tvarovanie požiadaviek a včasné reagovanie na podnety od implementačného tímu.

Prínosy a riziká

1. Kvalitatívne prínosy

- Upevnenie kultúry dosahovania merateľných výsledkov a vykonávanie rozhodnutí na základe dát (*data-driven*), zvýšenie tlaku na optimálnosť ostatných procesov;
- Popis kognitívnych častí výrobného procesu a interakčnej schémy priamo nesúvisiacich kontrolných procesov na úrovni systému (behaviorálna mapa systému), ktorá slúži na flexibilné presmerovanie toku materiálu v prípade výpadkov časti systému.

2. Kvantitatívne prínosy

- Priame úspory zdrojov (eliminácia/uvoľnenie kapacity pracovníkov, úspora energií) – vyčísliteľné v ekonomickej hodnote týchto úspor;
- Zlepšenie výsledkov (zvýšenie kvality, zlepšenie parametrov výrobkov, zníženie opotrebovania strojov) – vyčísliteľné v ekonomickej hodnote týchto zlepšení, pričom výpočet by mal obsahovať aj zohľadnenie hodnoty zníženia rizík, napríklad zníženie rizika reklamácií;
- Dobudovanie častí dátovej infraštruktúry, ktoré môžu byť využívané inými projektami z oblasti Industry 4.0 – vyčísliteľné ako hodnota položiek, ktoré môžu byť opätovne použité pre ostatné projekty a zároveň sú pre tieto projekty nevyhnutné.

Keďže ide o váženie viacerých zdrojov ekonomickej hodnoty a využitie metodiky kalkulácií, ktoré sú špecifické pre jednotlivé podniky, vydať odporúčanie na ROI nie je jednoduché. Prvé analytické zistenia však možno získať už počas niekoľkých dní práce špecialistov, čo značí pri úspešnom projekte, vhodnej validácii a implementácii odporúčaní návratnosť v horizonte niekoľkých mesiacov.

3. Riziká

Treba si uvedomiť, že pri väčšine projektov je pred riadnou analýzou dát možné určiť očakávanú úspešnosť optimalizácie iba rámcovo. Už jednoduchá analýza dát skúseným dátovým analytikom vie očakávané výsledky projektu pomerne dobre ohraničiť, preto je vysoko odporúčané začať zbežnou analýzou dát a dopadov, pokojne aj pre viacero projektov naraz a následne vybrať projekt sľubujúci najvyššie prínosy. Práve technická a metodická schopnosť na základe analýzy dát vytvoriť analýzu dopadov je výsadou skutočne skúsených dátových analytikov. Preto sa v žiadnom prípade neodporúča nechať tento kľúčový bod projektu na juniorský tím.

Počas implementácie je najväčším rizikom nedostatok komunikácie medzi odborným a implementačným tímom a z toho vyplývajúce nedostatočné napasovanie riešenia na reálne procesy a potreby zamestnancov podniku. Motiváciou je často úspora času expertov (obzvlášť externých implementačných tímov) a s tým spojených nákladov. Potenciálna cena stratenej príležitosti spôsobená nedostatkom interakcie a zladenia požiadaviek, ale aj nedostatočným zaškolením pri preberaní riešenia je však spravidla výrazne vyššia.

Ak produktové plány a stratégie obsahujú AI funkcionality, pri plánovaní AI stratégie pre výrobný podnik je rozumné prizvať dodávateľov technológií a vyzvať ich na predloženie plánov rozvoja ich produktových línií a zohľadniť ich pri návrhu celkového AI projektu.

4.6.2 Riadenie kvality, výstupná a laboratórna kontrola a analýza

Popis

Umelá inteligencia založená na neurónových sieťach je kľúčovým softvérovým komponentom tzv. *machine vision* systémov, ktoré majú veľké možnosti uplatnenia vo výrobných podnikoch, ale aj

laboratóriách a nemocniciach. Vision systém je v kontexte kontroly kvality a laboratórnej analýzy prístroj, ktorý automatizuje proces kontroly kvality alebo iného vyhodnocovania výrobkov a vzoriek. Expertných pracovníkov, ktorí obvykle kontrolu kvality či laboratórnu analýzu vykonávajú buď dopĺňa (AI asistent), alebo ich nahrádza čiastočne, či dokonca úplne.

Vision systém je zostavený z nasledovných komponentov:

- Mechanika – hardvérové komponenty a riadiaci systém zabezpečujúci manipuláciu s výrobkom, pohyby a akcie snímacej sústavy a orchestrácia jednotlivých komponentov prístroja;
- Snímacia sústava – kamery, resp. iné senzory zachytávajúce vzorku do digitálnej podoby, osvetlenie, odtienenie od vonkajších elementov;
- Softvér – sústava softvérových komponentov, ktoré zabezpečujú funkčnosť používateľského rozhrania, komunikáciu s niektorými nadradenými systémami, no predovšetkým vyhodnotenie výrobku/vzorky.

Správna mechanika, ako aj snímacia sústava sú mimoriadne dôležité. Jadrom systému je však bezpochyby softvér, konkrétne jeho komponent, ktorý zabezpečuje vyhodnotenie výrobku/vzorky.

Existuje široké spektrum komerčne využívaných vision systémov – s variabilitou snímania (multispektrálne, UV, 3D, rôzne typy mikroskopov a NDT prístrojov), mechaniky aj aplikácie (analýza biologických materiálov, tkanív, živých organizmov, archeologických nálezov, hornín, forenzných vzoriek, atď.). Pre prehľadnosť sa v ďalšom texte obmedzíme na vision systémy pre povrchovú vizuálnu kontrolu výrobkov v priemysle, ktoré sú jednoznačne najčastejšie aplikovanou technológiou.

Obmedzíme sa na systémy postavené na neurónových sieťach, ktoré hlavne po roku 2012 a nasledovnom rozmachu technológie umelej inteligencie systematicky nahrádzajú staršie algoritmické expertné systémy. Dôvodom je ich spoľahlivosť, presnosť, robustnosť na variácie v okolitých podmienkach a na variabilitu vzhľadu výrobkov, ale aj schopnosť zlepšovať sa. Technologická revolúcia spojená s využívaním umelej inteligencie navyše otvorila úplne nové možnosti aplikácie, ktoré boli s využitím klasických algoritmických expertných systémov považované za úplne nevhodné pre automatizáciu.

Z pohľadu typu riešenia má nákupca niekoľko možností:

- Riešenie (stroj) na kľúč – nákup sériového/konfekčného riešenia alebo zákazkový vývoj. Dodávateľ spravidla za súčinnosti priemyselného podniku dodá všetky tri komponenty spojené do fungujúceho celku a pomôže s integráciou do výrobného procesu;
- Softvér – ak už má podnik nasadenú mechaniku a vhodne zvolenú snímaciu sústavu, je možné vykonať iba vývoj a integráciu *machine vision* softvéru.

Čo sa týka softvéru, v prípade riešenia na kľúč aj čisto softvérového vývoja má podnik na výber z nasledujúcich možností:

- Vlastný vývoj pomocou *open source* knižníc – pre dosiahnutie uspokojivej kvality je potrebná výrazná expertíza a časová investícia vlastného tímu zameraného na umelú inteligenciu. Preto je táto možnosť spravidla relevantná iba pre vývojové centrá najväčších svetových priemyselných korporácií;
- Využitie štandardizovaných komerčných nástrojov a knižníc – vhodné riešenie najmä pre jednoduché a jednoznačné zadania. Podnik obdrží licenciu a užívateľské rozhranie,

prostredníctvom ktorého zaškolený pracovník zabezpečuje tzv. tréning umelej inteligencie. Nevýhodou je nízka miera podpory, nutnosť vysokej alokácie interných zamestnancov a rigidnosť týchto konfekčných systémov;

- Zákazkový vývoj – hybridný spôsob, dodávateľ zabezpečí iniciálny vývoj až do okamihu nasadenia a prostredníctvom dedikovaného rozhrania v prípade potreby umožní zákazníkovi ďalšie tréňovanie riešenia. Táto populárna možnosť je odporúčaná pri väčšine netriviálnych zadaní a takisto v prípade, ak podnik nemá ešte nasadený vision systém na báze umelej inteligencie. Výhodou je vysoká pravdepodobnosť úspechu, vysoko presné špecializované riešenie a nízke vyťaženie interných zdrojov. Nevýhodou je o niečo vyššia cena.

Prevažnej časti zákazníkov, používajúcej AI v procesoch výroby, ide zväčša o vývoj na mieru s počiatočným výskumom a tvorbou prototypu pre demonštráciu funkčnosti u konkrétneho zákazníka a na základe dosiahnutých výsledkov a požiadaviek sa následne pristúpi k návrhu finálneho riešenia.

Predpoklady

1. Proces

Automatizovaným procesom je vizuálna kontrola výrobkov či vzoriek. Plná automatizácia pomocou vision systému na báze umelej inteligencie je možná tam, kde je pre odhalenie defektu alebo analýzu vzorky postačujúca čisto vizuálna kontrola bez nutnosti dodatočnej napr. hmatovej analýzy. Z hľadiska nákladov je vhodné nasadenie na kontrolu tvarovo nie príliš zložitých výrobkov (teda takých, ktorých relevantné plochy je možné nasnímať s malým počtom kamerových pozícií). Z hľadiska ROI je vhodné nasadenie v sériovej výrobe obzvlášť tam, kde kontrola zamestnáva viacero pracovníkov. Vhodným dôvodom pre nasadenie býva aj nedostatočná spoľahlivosť a konzistentnosť ľudskej vizuálnej kontroly kvality. Nasadenie umelej inteligencie v týchto prípadoch prispieva k zníženiu objemu reklamácií.

2. Dáta

Podnik musí zabezpečiť dostatok vzoriek podľa typu riešenia – buď fyzických exemplárov výrobku alebo digitálnych snímok. Vzorky musia obsahovať jednak bezchybné, ale aj defektné kusy, ktoré by mali zahŕňať všetky očakávané typy defektov a všetky variácie výrobku pre korektné a aj chybné kusy. Potrebné počty sa pohybujú od niekoľko desiatok, stoviek až tisícok exemplárov, v prípade zákazkového vývoja softvéru spravidla menej, ako pri iných formách vývoja. Najmä v prípade výroby s nízkou chybovosťou je ale nutné nastaviť proces na zber defektných kusov, nakoľko obzvlášť zber vzoriek s raritnými defektami často trvá mesiace.

3. Aplikácie

Nadradeným systémom je spravidla riadiaci systém výrobnéj linky. Vo vnútri vision systému prebieha komunikácia PC, PLC (priemyselný počítač) a snímacej sústavy. Pre pohyb vzorky, ako aj jej vyradenie, komunikuje PLC s mechanickým komponentom.

Výstupy sú spravidla prezentované v používateľských rozhraniach a ukladané do rôznych podnikových informačných systémov.

4. Infraštruktúra

V prípade nasadenia AI na úzko a jasne definovanú úlohu s nízkou komplexnosťou a nízkymi nárokmi na rýchlosť vykonávania je veľakrát možné použiť aj existujúcu výpočtovú infraštruktúru. V prípade

viacnásobnej aplikácie je potrebné uvažovať o kvalitnej sieťovej infraštruktúre – prenos dát po 10 Gbps a viac. V prípade rozoznávania obrazu je nutné zabezpečiť kvalitné snímacie zariadenia s certifikáciou pre prácu vo výrobných prostrediach.

Okrem použitia kamier, ktoré musia byť vybrané podľa konkrétnej situácie, by v prípade komplexných úloh mal byť súčasťou infraštruktúry aj výkonný počítač, ktorý bude dáta z kamier vyhodnocovať, pri externom dodávateľovi dodaný a integrovaný do funkčného celku s ostatnými komponentami.

5. Ľudia

Počas vývoja je nutná súčinnosť pracovníkov:

- Vyššie spomínané zachytávanie vzoriek potrebných pre vývoj systému;
- Anotácia vzoriek prostredníctvom dedikovaného rozhrania (do istej miery môže byť zabezpečená dodávateľom).

Po nasadení je vhodné alokovať niekoľko hodín mesačne zodpovedného pracovníka na analýzu výsledkov systému. V závislosti od kvality iniciálneho nasadenia je tento objem práce zo začiatku vyšší, po niekoľkých mesiacoch je už analýza či kontrola spravidla potrebná iba pri očakávanej zmene podmienok.

Profily na strane zadávateľa:

- Vedúci výroby a pracovníci zodpovední za nastavenie kvalitatívnych parametrov, spolupracujúci s dátovými vedcami na určení problémov a cieľov;
- Pracovníci výstupnej kontroly, ktorí participujú pri tréningu AI systémov;
- Technici zodpovedajú za nastavovanie a prevádzku senzorov/kamier;
- Informatici zodpovedajú za prevádzku výpočtovej techniky a sieťovej infraštruktúry.

Niektoré z požadovaných pozícií môžu poskytnuté zástupcami tretích strán, externými konzultantmi alebo dodávateľom.

Profily na strane dodávateľa:

- Dátoví vedci a špecialisti na vision systémy ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- Vývojári aplikácií nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Technici a konštruktéri zodpovedajú za nastavovanie a prevádzku senzorov/kamier, mechanických komponentov a ich integráciu;
- Programátori a ďalší IKT špecialisti zodpovedajú za implementáciu riešenia tak po stránke softvéru aj hardvéru.

6. Organizácia

V prípade interného vývoja je potrebná úplná alokácia špecialistov na umelú inteligenciu a *machine vision* (spracovanie obrazu a videa) po dobu niekoľkých mesiacov.

Počas vývoja je potrebné rátať s čiastočnou alokáciou jedného alebo dvoch (z dôvodu krížovej kontroly anotácií) zodpovedných a motivovaných pracovníkov na vyššie spomínaný zber vzoriek a hlavne anotovanie dát. Výška alokácie závisí od formy vývoja a riešenia.

Prínosy a riziká

1. Kvalitatívne prínosy

Po zavedení vision systému na báze umelej inteligencie možno očakávať:

- Zvýšenie konzistentnosti vizuálnej kontroly vďaka eliminácii ľudského faktora – žiadne výkyvy v závislosti od času, pracovnej zmeny, atmosféry na pracovisku, či iných faktorov, stabilný výkon 24/7;
- Vysoká a stabilná úspešnosť, zvýšenie presnosti, precíznosti, rozlišovacej schopnosti;
- Exaktnejší proces kontroly, dáta pre ďalší výskum či ďalšie zlepšovanie výroby či samotnej kontroly kvality;
- Odolnosť voči chybám, vyhľadateľnosť chýb a transparentné reklamácie. Všetko ako výsledok digitalizácie procesu, ktorý spočíva v existencii spoľahlivého záznamu pre každý výrobok.

Ďalšími prínosmi býva úspora miesta či eliminácia nepopulárnej práce (platí obzvlášť pre prípady spolupráce pracovníkov s vision systémami).

2. Kvantitatívne prínosy

Systém nahrádza a šetrí ľudské zdroje a predovšetkým redukuje náklady na nízкокvalifikovanú pracovnú silu. Kalkulácia by mala brať do úvahy ušetrené náklady vo všetkých zmenách.

Ďalší zdroj úspor je zníženie počtu nekvalitných exemplárov, nákladov na reklamácie a zníženie ich volatility. Tu je na mieste výpočet podľa vlastnej metodiky využívanej v podniku.

Z dôvodu vysokej variability vision systémov a širokého rozpätia cien nie je možné stanoviť jednoduché odporúčania pre rozhodnutie o rentabilite. Už pri jednoduchom výpočte prostredníctvom nákladov na platy je však jasné, že úspora môže byť výrazná, pri ROI na úrovni 1 – 4 rokov. Cena vision systémov na kľúč sa pohybuje v desiatkach tisíc, pre zložité systémy niekedy aj v stovkách tisíc eur.

Príklad: ak si predstavíme, že systém zníži počet pracovníkov v oblasti kontroly z 10 na 1 (napríklad elimináciou troch pracovníkov v trojzmennej prevádzke) a teda pri predpokladanej priemernej mzde 1 300 Eur * 1,3 = 1 690 Eur (superhrubá mzda), ročne to predstavuje 182 520 Eur.

3. Riziká

Medzi rizikové scenáre patria:

- Je potrebný intenzívnejší dohľad dedikovaného pracovníka v prvých týždňoch po nasadení systému kým umelá inteligencia ešte nemusí byť dostatočne natrénovaná;
- Neočakávaná zmena výrobných podmienok (optických podmienok, typu defektov, vzhľadu výrobkov, atď.) vyvolá zníženú spoľahlivosť riešenia, ktorá je však riešiteľná pomerne nenáročným čiastočným dotrénovaním;
- V prípade neodborných manuálnych zásahov do systému tiež hrozí (spravidla neúmyselné) degradovanie softvérového systému manipuláciou s tréningovými vzorkami a anotáciami či neodborným rozhodovaním. Táto možnosť je obzvlášť markantná pri vlastnom vývoji alebo použití štandardných knižníc. Skúsený dodávateľ alebo interný expert preto výrazne obmedzuje možnosti manipulácie iných ľudí s jadrom systému.

Vo všeobecnosti však platí, že na rozdiel od starších algoritmickej expertných systémov je softvér na báze umelej inteligencie mimoriadne adaptabilný a ľahko upravovateľný (stačí doplniť databázu vzoriek a anotácií používaných na tréning umelej inteligencie). Pri správnom inštalácii a nastavení a nejakom čase v prevádzke je vision systém so softvérom na báze umelej inteligencie mimoriadne stabilným a spoľahlivým systémom.

4.6.3 Prediktívna údržba

Popis

Pri údržbe strojov a zariadení je hlavným cieľom zabezpečiť bezporuchovú prevádzku po čo najdlhšiu dobu a maximalizovať životnosť našich zariadení. Pri preventívnej údržbe sa snažíme dosiahnuť tento cieľ nastavením pravidelných servisných intervalov, v rámci ktorých vykonávame drobné opravy a kontrolu príslušných zariadení.

Kritickým miestom tohto prístupu je však určenie toho správneho intervalu. Príliš časté servisné zásahy zvyšujú náklady na údržbu a majú tiež dopad na produkciu, keďže počas takéhoto zásahu nie je možné daný stroj prevádzkovať. Pokiaľ nemáme záložný stroj, výroba stojí. Ak však pravidelný servis zanedbáme, môže dôjsť až k nenávratnému poškodeniu a v niektorých prípadoch dokonca s následkami na zdravie a život pracovníkov. Pri preventívnej údržbe sú tieto cykly určené empiricky s istou toleranciou a akceptáciou rizika.

Prediktívna údržba (PdM, z angl. *Predictive Maintenance*) sa snaží adresovať práve problém určenia správneho momentu pre údržbu s využitím pokročilých štatistických metód a umelej inteligencie. Na rozdiel od preventívnej údržby je údržba každého zariadenia posudzovaná a plánovaná na základe aktuálneho stavu zariadenia, pričom prostredníctvom rôznych modelov sa snažíme odhadnúť čas a dátum poruchy. Následne je možné predĺžiť či skrátiť údržbové cykly podľa reálneho stavu daného zariadenia.

Na to, aby bolo možné skutočne presne určiť stav zariadenia je potrebné používať rôzne diagnostické postupy. Preventívnu údržbu je, samozrejme, možné realizovať aj bez inteligentných snímačov a umelej inteligencie s využitím základných diagnostických nástrojov ako napr. ultrazvukové merania, merania akustických emisií, kvality oleja a pod. Avšak takéto diagnostické úkony sú často pomerne nákladné a nie vždy ich možno realizovať počas prevádzky. Bežným štandardom je však aplikovanie týchto metód na kritické zariadenia.

Zásadný zlom však prinášajú práve inteligentné senzory a pokročilé prediktívne modely, ktoré dokážu veľkú časť týchto diagnostických činností plne automatizovať. Zavedením automatického monitoringu je možné dramaticky zvýšiť presnosť predikcie a znížiť potrebu nákladných diagnostických kontrol nie len na najkritickejších zariadeniach, ale na všetkých dôležitých strojoch. Vďaka nepretržitému monitoringu je navyše možné identifikovať aj prípady, ktoré tradičnými spôsobmi identifikovať nebolo možné (napr. jav, ktorý sa prejaví len počas maximálneho zaťaženia stroja).

Prediktívna údržba dokáže riešiť tieto problémy:

- Predpovedať poruchu zariadenia v budúcnosti;
- Identifikovať nezvyčajné správanie zariadenia;
- Odhadnúť zostávajúcu životnosť zariadenia;
- Upozorniť na zlé nastavenie prevádzkových parametrov.

Pri zavedení prediktívnej údržby je však nutné realisticky zhodnotiť možnosti, či dané typy porúch je možné identifikovať z dostupných dát, a ktoré parametre potrebujeme zberať.

Napriek tomu, že umelá inteligencia dokáže sama nájsť aj nezrejmé súvislosti, stávka na istotu je zaviesť AI tam, kde vieme, že skúsený odborník (v prípade, že by mal dosť času, dáta všetkých meraní, atď.) dokázal poruchu predikovať sám. Strojové učenie totiž exceluje práve v úlohách, ktoré spočívajú v analýze veľkého množstva dát a dokážu to robiť výrazne rýchlejšie, lacnejšie a hlavne škálovateľne. V praxi nemôžeme na každé zariadenie prijať jedného špičkového odborníka, ktorý bude 24 hodín denne analyzovať stovky meraní za sekundu. Umelá inteligencia to dokáže bez zaváhania.

Odborníkov budeme potrebovať aj na to, aby analyzovali momenty, v ktorých umelá inteligencia zlyhá a pomohli jednotlivé modely vylepšiť. Avšak na nepretržitý monitoring je strojové učenie jasná voľba.

Ideálny postup pri zavedení prediktívnej údržby:

- 1. Identifikácia kritických zariadení a ich častí** – nie všetky zariadenia má zmysel sledovať. Zariadenia ktorých nefunkčnosť nespôsobí problém, prípadne zariadenia, pre ktoré existuje záložné riešenie, nie je nutné sledovať.
- 2. Identifikácia degradačných mechanizmov** – aký je charakter poruchy ktorú sa snažíme predikovať? Dochádza k poruche náhle, alebo ide o dlhodobý proces degradácie niektorého z komponentov?
- 3. Identifikácia kľúčových parametrov** – je potrebné určiť, ktoré parametre môžu mať potenciálny vplyv na správanie zariadenia a môžu prispieť k úspešnej predikcii. Ktoré z nich vieme efektívne merať?
- 4. Implementácia monitoringu stavu zariadení** – inštalácia potrebných senzorov, systému na zber a uchovanie týchto dát a následný monitoring. Často už len meraním prekročenia kritických hodnôt dokážeme eliminovať veľké množstvo porúch. Toto je rozumné pripraviť najskôr na malej vzorke zariadení.
- 5. Návrh predikčného algoritmu – *Proof of Concept*** – na základe vytvorenej bázy dát je možné otestovať viacero predikčných algoritmov a vybrať ten najlepší. Typickým scenárom je vytvorenie vyváženého datasetu, ktorý rozdelíme (napr. v pomere 80/20). Väčšiu časť dát použijeme na tréning a menšiu časť dát na porovnanie výsledkov jednotlivých modelov. Toto je kritická časť celého procesu a správny prístup pri príprave modelu je veľmi dôležitý pre dosiahnutie čo najlepších výsledkov. Táto časť môže byť realizovaná „v laboratórnych podmienkach“ s relatívne nízkymi nákladmi, preto je dôležité overiť si možnosti ešte pred vynaloženým veľkým investícií.
- 6. Implementácia prediktívneho modelu** – zapojenie najlepšieho modelu do produkcie. Prepojenie na *real-time* dáta a následné spracovanie a vizualizácia výstupov.
- 7. Integrácia prediktívnej údržby do procesov** – zintegrovať prediktívnu údržbu do existujúcich procesov a zdefinovať akcie, ktoré ukážu čo robiť v prípade, ak model identifikuje pravdepodobnú poruchu. Definovať procesy – čo robiť, kedy (napr. generovať zákazku, poslať notifikáciu alebo okamžité vypnutie výroby v prípade kritického problému), atď.
- 8. Meranie a vyhodnotenie prínosov** – je dôležité, aby na konci procesu bolo možné jednoznačne vyhodnotiť výsledky a prínosy riešenia.

Predpoklady

1. Proces

Základným predpokladom pre zavedenie prediktívnej údržby je mať dostatočne zmapovanú svoju technológiu, identifikovať diagnostické metódy na svojich zariadeniach, poznať typy porúch a predovšetkým príčiny a podmienky, za ktorých dané zlyhanie nastáva.

Mali by sme taktiež mať zavedený monitoring stavu zariadení, minimálne na úrovni pravidelných diagnostických činností.

2. Dáta

Zariadenia a typy porúch, ktoré chceme predikovať:

- Vytipovať zariadenia, na ktorých má prediktívna údržba zmysel;
- Identifikovať typy porúch a spôsob, ako k nim dochádza (aby bolo možné navrhnúť čo, kde a ako merať).

Pred samotným spustením prediktívneho modelu je potrebné mať vytvorenú:

- **Dostatočnú vzorku dát príkladov – tzv. Dataset**
 - Príklady musia pozostávať z nameraných hodnôt senzorov tesne pred poruchou (dĺžka časového intervalu závisí od charakteru poruchy);
 - Dataset musí obsahovať dáta, ktoré budú dostupné aj v produkcii;
 - Dataset by mal obsahovať aspoň niekoľko desiatok príkladov (ideálne zozbieraných v rôznych časoch, za rozličných prevádzkových podmienok);
 - Dataset by mal byť vyvážený, t. j. obsahovať negatívne scenáre (poruchy) aj pozitívne scenáre (bežná prevádzka aj menej bežných prevádzok bez poruchy);
 - Tento dataset na začiatku častokrát nie je dostupný, preto je rozumné projekt rozdeliť do dvoch fáz: 1. vybudujeme infraštruktúru pre zber potrebných dát a 2. až následne zapojíme do procesu prediktívne algoritmy.

Pri zhromažďovaní dát sú potrebné minimálne tieto dátové zdroje:

- Dáta z pozorovaní – prístrojovo generované dáta, dáta v reálnom čase, napríklad zo senzorov, snímačov, riadiacich jednotiek, aplikácií a databáz;
- Transakčné dáta – dáta popisujúce nejakú udalosť (jej zmenu ako výsledok transakcie). Vždy obsahujú zápis o čase vzniku prípadnej zmeny, numerickú hodnotu a referujú na jeden alebo viac objektov;
- Prevádzkové dáta – napríklad teplota a relatívna vlhkosť v technologických miestnostiach;
- Historické dáta – dáta popisujúce servisné zásahy – hlásenia o poruchách.

3. Aplikácie

Ukazovatele prevádzkovej spoľahlivosti strojov a zariadení – MTBF, MTTR, A, R(t), I, atď. – teda explicitné znalosti, majú rozhodujúci význam pre predikciu stavu strojov, výrobných a montážnych liniek. Plnia rovnakú funkciu ako inteligentné senzory, ktoré dokážu zobraziť stav zariadenia a môžu v akejkolvek dobe predikovať požiadavku na údržbový zásah ešte pred vznikom poruchy.

Fungovanie výrobných podnikov sa prípad od prípadu zásadne líši. Pri každom sa dá predpokladať iné vybavenie strojov, odlišné budú aj informačné systémy. Pre potreby prediktívnej údržby sa budú

využívať pravdepodobne MES, PLM, ERP. Firma môže disponovať všetkými, alebo iba vybranými aplikáciami, a to aj od rôznych výrobcov.

Zdroj dát:

Systémy pre zber dát ako sú MES, SCADA (*Supervisory Control And Data Acquisition*) často obohatené o ďalšie údaje z ERP, CMMS (*Computerized Maintenance Management System*), EAM (*Enterprise Asset Management*) systémov. Mnohé EAM, CMMS systémy dnes poskytujú prediktívnu údržbu ako balík (od zberu dát až po naplánovanie údržby).

Spracovanie udalostí:

Complex Event Processing je nástroj na sledovanie a spracovanie tokov dát z rôznych zdrojov v reálnom čase s cieľom identifikovať blížiacu sa hrozbu. Technológie pre spracovanie udalostí umožňujú monitorovať stav zariadení, analyzovať ich a reagovať na udalosti automatizovane a inteligentne v reálnom čase.

Zobrazovanie dát – Dashboard:

Je nevyhnutné vizualizovať v reálnom čase aktuálne hodnoty, parametre, atribúty, stavy spracovávaných dát, ďalej upozornenia a výstrahy na blížiace sa kritické udalosti.

4. Infraštruktúra

Potrebná infraštruktúra pozostáva z infraštruktúry pre zber dát a následné uloženie, spracovanie a analýzu:

- Senzory;
- Infraštruktúra pre zber dát zo senzorov a odoslanie na server (koncentrátory a pod.);
- Zberová centrála/Hub;
- Dátové úložisko;
- Analytický server.

Veľkú časť tejto infraštruktúry je možné prevádzkovať aj v cloude, tento spôsob však prináša komplikácie pri integrácii na existujúcu infraštruktúru a systémy, ktoré už máme nasadené doma (*on premise*), zabezpečenia, atď.

Pre menšie riešenia je pritom možné prevádzkovať túto infraštruktúru na virtualizovaných serveroch, bez potreby extrémne výkonného hardvéru. Návrh najvhodnejšej architektúry by mal byť súčasťou projektu a vychádzať z viacerých aspektov ako je napr. požiadavka na rýchlosť (Potrebujeme *real-time* predikciu? Stačí nám 5-minútové oneskorenie, prípadne niekoľkohodinové?), od množstva dát (počtu zariadení, množstva senzorov a intenzity/periodicity zberu) a potreby integrácie na existujúce systémy.

5. Ľudia

Pri zavedení prediktívnej údržby je kľúčové zainteresovanie odborníkov, ktorí dôkladne poznajú dané zariadenia a celú technológiu. Je nesmierne dôležitý výber správnych údajov, ktoré majú byť súčasťou modelu, výber správneho typu a umiestnenia snímačov a je potrebné poznať a rozumieť danej technológii.

Profily na strane zadávateľa:

- Vedúci výroby a údržby spolupracujú s dátovými vedcami na určení problémov a cieľov;

- Pracovníci údržby zodpovední za čiastkové úlohy participujú na tréningu umelej inteligencie;
- Operátori na základe školení vykonávajú komplementárne úlohy a fungujú ako eskalačný stupeň;
- Informatici zodpovedajú za prevádzku výpočtovej techniky a sieťovej infraštruktúry.

Niektoré z požadovaných pozícií môžu byť poskytnuté zástupcami tretích strán, externými konzultantmi.

Profily na strane dodávateľa:

- Dátoví inžinieri spravujú dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;
- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- IT architekti spravujú základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Vývojári aplikácií nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Experti na vizualizáciu a interpretáciu dát.

Programátori a ďalší IKT špecialisti sú zodpovední za implementáciu riešenia tak po stránke softvéru, ako aj hardvéru.

6. Organizácia

Pri implementácii riešenia je vhodné vytvoriť pracovné skupiny, ktoré sa budú podieľať na konfigurácii. Je dôležité vytvoriť platformu, na ktorej budú môcť technici so znalosťami technológie diskutovať s dátovými analytikmi, ktorí poznajú prediktívny model a jeho možnosti.

Prínosy a riziká

1. Kvalitatívne prínosy

- **Zníženie poruchovosti** – dobre zavedená prediktívna údržba je principiálne efektívnejšia ako preventívna, pretože je postavená nielen na skutočnom aktuálnom stave zariadenia, ale aj na historickom zaťažení a berie do úvahy aj ďalšie faktory. Každé zariadenie je pritom posudzované individuálne, čím sa významne spresňuje predpoveď zlyhania. V niektorých prípadoch môžeme očakávať zníženie poruchovosti až o 75 %;
- **Zníženie neplánovaných odstávok** – so zavedením prediktívnej údržby dokážeme často s dostatočným predstihom identifikovať zlý stav zariadenia a naplánovať údržbu. Vďaka zavedeniu prediktívnej údržby sa dajú znížiť neplánované odstávky v rozsahu 10 – 50 %;
- **Zvýšenie produkcie** – vďaka minimalizácii neplánovaných odstávok a tiež vďaka podrobnému monitoringu dokážeme z našich zariadení vyťažiť maximum;
- **Zníženie potrebného množstva náhradných dielov** – vďaka zníženiu množstva pravdepodobnosti neplánovanej poruchy môžeme obmedziť počet náhradných dielov, ktoré držíme na sklade pre prípad poruchy;
- **Predĺženie životnosti zariadení** – dobrou starostlivosťou dokážeme predĺžiť životnosť zariadení a vďaka predikcii maximalizovať ich efektívnu životnosť;

- **Predĺženie cyklov údržby** – vďaka presnejším informáciám o stave zariadení dokážeme optimalizovať cykly výmeny a údržby jednotlivých dielov na základe ich skutočného opotrebovania;
- **Zvýšenie bezpečnosti** – mnohé z úrazov v prevádzke sú zapríčinené zlyhaním niektorého zo zariadení. Znížením pravdepodobnosti zlyhania týchto zariadení automaticky znižujeme aj pravdepodobnosť týchto úrazov, ako aj následných pracovnoprávných dôsledkov.
- **Zníženie nákladov na údržbu** – bolo dokázané, že korektívna údržba (po poruche) je mnohonásobne drahšia, ako údržba pred poruchou. Zlyhanie lacnej súčiastky ako napr. ložiska či tesnenia môže mať za následok zničenie zariadenia za tisíce eur.

2. Kvantitatívne prínosy

- **Úspory** – prevencia havárií a včasná detekcia začínajúcich problémov stroja a systému zvýšia využiteľný čas prevádzky strojov závodu v priemere o 30 %. Pravidelné monitorovanie stavu strojov zníži počet neočakávaných porúch a havárií v priemere o 55 %. Priemerné skrátenie stredného času do opravy (*Mean-Time-To-Repair* – MTTR) dosiahne 60- a 30-percentnú redukciu skladu náhradných dielov;
- **Očakávaný ROI** – existujú viaceré vierohodné štúdie, ktoré potvrdzujú, že investícia do systému na prediktívnu údržbu má jednu z najkratších návratností. Dostupná odborná literatúra²¹ uvádza údaj návratnosti tri až päť rokov, čo je v porovnaní s návratnosťou iných častí technológie veľmi krátky čas.

3. Riziká

- **Charakter poruchy neumožňuje predikciu zo zbieraných dát** – je dôležité najskôr analyzovať typy porúch a následne realizovať fázu *Proof of Concept*. Každá prevádzka je iná a neexistuje univerzálne riešenie. To, čo fungovalo inde, nemusí fungovať u nás a naopak;
- **Predčasné ukončenie projektu** – manažment firiem je často nedočkavý a očakáva 100-percentné výsledky okamžite po spustení systému. Prechod na prediktívnu údržbu je však proces. Vo fáze *Proof of Concept* je cieľom overiť si, či je aplikovanie prediktívnej údržby na náš prípad možné, avšak v realite sa stretávame s veľkým množstvom výnimiek a špecifik. Spustením systému do prevádzky projekt nekončí. Je potrebné isté obdobie na odladenie a na dotréňovanie modelu na ďalšie prípady, s ktorými sa nerátalo;
- **Prílišná dôvera v silu strojového učenia** – strojové učenie nie je *magic bullet*, ktoré odhalí všetky možné poruchy. Prediktívna údržba nedokáže úplne nahradiť preventívnu údržbu a diagnostiku. Dokáže však znížiť jej potrebu a predĺžiť intervaly kontrol;
- **Riziko zlyhania projektu v prípade, že predpoklady nasadzovania nebudú naplnené** – napriek sľubným možnostiam umelej inteligencie si mnoho spoločností neuvedomuje plný potenciál strojového učenia a ďalších funkcií AI. Prečo? Paradoxne sa ukazuje, že problém je z veľkej časti v ľuďoch. Vedúci pracovníci si nemusia uvedomovať celý potenciál investícií do umelej inteligencie v spoločnosti. V dôsledku toho neposkytnú dostatok prostriedkov a zdrojov k vytváraniu spoločného a integrovaného ekosystému potrebného k úspešnému použitiu umelej inteligencie. Dôsledkom môžu byť nepresné alebo úplne chybné predikčné modely a nedosiahnutie návratu investície.

²¹ Priemyselná automatizácia a informatika. Atp journal 8/2019. 2019. [Dostupné online](#).

- **Riziko neskoršej návratnosti, ak nebudú predpoklady nasadzovania naplnené dostatočne** – dátoví vedci nemôžu efektívne pracovať, ak dlho čakajú na dáta, ktoré potrebujú analyzovať. Z tohto dôvodu môže trvať týždne alebo dokonca aj mesiace, kým možno predikčné modely nasadiť do užitočných aplikácií;
- **Vývojári aplikácií nemajú prístup k použiteľnému strojovému učeniu.** Niekedy musia byť modely strojového učenia, ktoré vývojári obdržia, preprogramované, alebo nie sú pripravené na nasadenie v aplikáciách. Keďže prístupové body môžu byť nepružné, nemožno modely nasadiť vo všetkých scenároch a škálovateľnosť je ponechaná na vývojárovi aplikácie. Dôsledkom môže byť dlhší čas na dosiahnutie očakávaného návratu investície²²;
- **Riziká z možných externalít** – veľkým problémom sú chýbajúci špecialisti, prevažne dátoví vedci. Dôsledkom môžu byť nepresné alebo úplne chybné predikčné modely a nedosiahnutie návratu investície.

4.6.4 Inteligentná automatizácia nevýrobných procesov

Popis

Inteligentná procesná automatizácia sa týka širokej škály procesov spracovania dát – od evidencie dát až po prípravu manažerských rozhodnutí. Slovo „procesná“ v tomto kontexte vyjadruje vzťah k podnikovým procesom.

Typicky ide o rôzne dáta, štruktúrované aj neštruktúrované, ktoré už sú ukladané a spracovávané jednotlivými systémami podniku alebo inštitúcie. Môže teda ísť o textové dáta v zdrojových dokumentoch, kmeňové dáta rôznych systémov a agend (ERP, CRM, SRM, WFM, HR atď.), transakčné dáta z uvedených systémov, ale aj dáta zbierané senzormi alebo inými zariadeniami (nevýrobnými aj výrobnými).

Z vecného a organizačného hľadiska teda nie je obmedzené, aké procesy v ktorých oblastiach budú automatizované. Z princípu automatizácie sú skôr dôležité kategórie ako opakovateľnosť, štandardizácia, objem dát, počet spracovateľov. Elementárne príklady predstavujú napr. zadávanie dát do systému z papierových dokumentov, prepisovanie dát z tabuliek, prepisovanie dát medzi aplikáciami, príprava dát do správ a reportov a pod.

Podstatou tejto procesnej automatizácie (tiež RPA – *Robotic Process Automation*) je náhrada manuálnej (opakovanej, rutinnej) práce používateľa, ktorý ju spravidla vykonáva s využitím klávesnice a obrazovky (PC, terminál, prípadne mobilné zariadenie). Čím väčší je podiel rutinnej práce ako zadávanie dát a prepisovanie medzi rôznymi systémami, jednoduché rozhodovanie podľa údajov, príprava dokumentov a tabuliek v určenom formáte, spracovanie dát do analýz (reportov), tým väčší je potenciál na automatizáciu.

Táto automatizácia je realizovaná s pomocou softvéru, ktorý umožňuje vykonávať operácie imitujúce prácu s klávesnicou a myšou, pričom tieto softvérové automaty, teda roboty, vedia pracovať s názvami aplikácií (okien), záložkami, názvami polí a pod. Príslušné roboty sa spúšťajú podľa procesného kontextu, teda v definovaných časoch alebo v nadväznosti na iné operácie a existenciu dát. Softvérové

²² Co je datová veda? [Dostupné online](#).

nástroje sú dostupné ako štandardné produkty alebo ako špecializované riešenia od rôznych dodávateľov.

Opísaná automatizácia v princípe kopíruje rutinnú prácu a je na mieste otázka, kde v procese je priestor na inteligenciu. Typické oblasti, ktorých sa to týka je rozoznávanie textu, spracovanie písaného jazyka, rozoznanie obrazu a rozhodnutia. Niektoré z príkladov využitia umelej inteligencie alebo strojového učenia môžu byť napr. identifikácia zákazníka a nájdenie fakturačných údajov podľa obrazu loga firmy alebo určenie správneho rozhodnutia z veľkého množstva parametrov (100 a viac).

Úspech tohto typu riešení je založený na tom, že aktuálne softvérové nástroje umožňujú veľkú časť automatizácie realizovať samotnými pracovníkmi odborných útvarov s minimálnym príspevom IT. V praxi je však oveľa častejší scenár spolupráce, pričom úloha pracovníkov odborných útvarov, ktorí sú odborníkmi na samotný podnikový proces, je v porovnaní s minulosťou výrazne vyššia. V extrémnom prípade organizácia realizuje automatizáciu vlastnými silami s použitím štandardných softvérov.

Realizácia zo strany dodávateľa teda závisí od toho, aké vlastné zručnosti a kapacity má firma či organizácia. Typicky je vhodné využiť skúsenosti dodávateľa s podobnými projektami, znalosť softvérového nástroja a skúsenosti v oblasti umelej inteligencie, ak nejde len o automatizáciu rutinných činností.

Podľa počtu automatizovaných procesov môže takýto projekt trvať 2 až 3 týždne, ak ide o overenie konceptu, až po niekoľko mesiacov, ak ide o rozsiahlu automatizáciu mnohých procesov.

Štandardné softvéry a riešenia dodáva množstvo spoločností. Podrobnejšie údaje možno získať vyhľadávaním nasledujúcich pojmov vo vyhľadávači: *Robotic Process Automation, Automation Anywhere, Atos Syntbot, Blue Prism, Ulpath, WorkFusion, WinShuttle* a iné.

Predpoklady

1. Proces

Jednotlivé kroky procesu musia byť jednoznačne definované. Napriek tomu, že práve využitie umelej inteligencie umožňuje voľnejší opis rozhodovacích podmienok, jednotlivé úkony v rámci procesu musia byť definované pomerne exaktne. Voľne definované procesy je možné automatizovať až po ich štandardizácii.

Príklad: „V prípade že ide o elektrickú poruchu, kontaktovať hlavného elektrikára“.

Rozhodovacia podmienka „ide o elektrickú poruchu“ môže byť definovaná voľne, nakoľko na identifikáciu toho, že ide o túto kategóriu, je možné využiť práve neurónovú sieť. Avšak následná akcia „kontaktovať hlavného elektrikára“ musí byť definovaná presnejšie: napr. zaslanie e-mailu na konkrétnu adresu, prípadne získať tento e-mail z organizačnej štruktúry dostupnej v informačnom systéme a pod.

2. Dáta

Typ, rozsah a kvalita potrebných dát závisí od konkrétneho procesu. Napr. pri spracovaní textu sa odporúča mať dispozíciu text z danej domény. Ideálne je mať vzorku textu obsahujúcu podobné formulácie, ktoré sa použijú na dotrénovanie jazykového modelu na konkrétnu doménu.

Pre automatickú klasifikáciu a rozhodovanie je nutné mať istý počet príkladov – tzv. vzorky dát. Pri aplikáciách, v ktorých má umelá inteligencia rozhodovať, je potrebné mať k dispozícii (alebo viesť vygenerovať) isté množstvo príkladov aj so správnym rozhodnutím.

V prípade, že nemáme k dispozícii dostatok dát, odporúča sa na začiatok poloautomatický režim, v ktorom pracovníci kontrolujú a korigujú rozhodnutia, ktoré model urobil. Tieto dáta sa následne použijú na dodatočné dotrénovanie.

3. Aplikácie

Automatizácia procesov sa väčšinou nebuduje na tzv. zelenej lúke, ale často dochádza k integrácii s existujúcimi aplikáciami. Je otázkou konkrétneho projektu, či sa ukáže byť vhodnejšie riešiť integráciu na existujúce aplikácie, prípadne niektoré aplikácie nahradiť. V niektorých prípadoch môže byť nahradenie aplikácie výrazne jednoduchšie ako samotná integrácia, avšak to závisí od konkrétnych podmienok projektu. Podobné projekty sa dotýkajú typicky CRM, ERP, CMMS/EAM aplikácií či supportného/ticketingového portálu.

4. Infraštruktúra

Infraštruktúra potrebná pre tento typ projektov nie je zásadne odlišná od infraštruktúry pre iný IT projekt/systém. Samozrejme, vo väčšine prípadov je možné prevádzkovať výsledné riešenie v cloude, často je ale možné aj nasadenie *on-site*. V minimalistickom variante postačuje poskytnúť dodávateľovi virtuálny server, v závislosti od rozsahu spravovaných dát však nároky na výkon rastú – podobne ako pri akomkoľvek inom informačnom systéme.

5. Ľudia

Do projektu by mali byť zainteresovaní vedúci pracovníci, ktorí detailne poznajú celý proces, ako aj ďalší pracovníci, ktorých sa prípadné zmeny v procese môžu priamo dotknúť. Keďže zvyčajne sa zmeny dotknú aj ďalších informačných systémov, správcovia týchto systémov a vlastníci biznis procesov v týchto systémoch by mali byť účastníci minimálne širšieho tímu. V prípade, že pri štarte nie sú k dispozícii všetky potrebné dáta, je potrebné rátať so zapojením ďalších pracovníkov, ktorí pomôžu pri vytváraní potrebnej vzorky dát na tréning neurónovej siete.

Profily na strane zadávateľa:

- Vedúci oddelení spolupracujú s dátovými vedcami na určení problémov a cieľov;
- Pracovníci oddelení zodpovední za čiastkové agendy participujú na tréningu umelej inteligencie;
- Operátori na základe školení vykonávajú komplementárne úlohy a fungujú ako eskalačný stupeň;
- Informatici zodpovedajú za prevádzku výpočtovej techniky a sieťovej infraštruktúry.

Niektoré z požadovaných pozícií môžu poskytnuté zástupcami tretích strán, externými konzultantmi.

Profily na strane dodávateľa:

- Dátoví inžinieri spravujú dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;
- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- IT architekti spravujú základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Experti na vizualizáciu a interpretáciu dát;
- Vývojári aplikácií nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;

- Programátori a ďalší IKT špecialisti zodpovedajú za implementáciu riešenia po stránke softvéru aj hardvéru;

6. Organizácia

Súčasťou projektu by mala byť detailnejšia procesná analýza oblasti, ktorá sa bude riešiť. Pri automatizácii procesov treba určite myslieť na možnosť dramatických zmien a prípadného prekopania istých procesov, či úplné zrušenie niektorých súvisiacich procesov.

Prínosy a riziká

1. Prínosy

Primárne prínosy automatizácie procesov je možné hľadať v skrátaní trvania procesov, a to až v desiatkach percent. Existujú prípady, keď zavedením automatizácie procesov došlo k skrátaniu času od zaznamenania po vyriešenie prípadu z priemerných 30 dní na 2 pracovné dni. V prípade, že príslušný proces je súčasťou poskytovaných služieb, môže byť takéto dramatické zlepšenie zásadnou konkurenčnou výhodou. Avšak aj v prípade, že ide o interné procesy, má takéto zásadné zrýchlenie, zjednodušenie a sprehľadnenie procesov dopad na celkové fungovanie podniku.

Výpočet potenciálnych úspor:

Výpočet priamych úspor vychádza z času pracovníkov strávený na repetitívnych úlohách, ktoré budú po vyriešení procesu automatizované buď úplne, alebo čiastočne.

Ďalšie úspory je možné hľadať v znížení nekvality v rámci daného procesu (eliminácia chýb) v závislosti od konkrétneho projektu.

Príklad: V podniku dôjde ročne k 1000 poruchám, z čoho 100 má za následok odstavenie výroby a ďalších 100 má náklady na opravu presahujúce 10 000 Eur. Na následnej analýze a riešení týchto porúch sa zostaví tím piatich vysoko kvalifikovaných odborníkov. Priemerne na analýze týchto porúch strávia 10 hodín.

Po zavedení systému na podporu procesu riešenia poruchových udalostí sa predpokladá skrátanie času potrebného na riešenie udalosti na štvrtinu.

Primárne úspory je teda možné vypočítať:

$$\begin{aligned}
 &200 \text{ prípadov/ročne} \\
 &\times 5 \text{ pracovníkov} \\
 &\times (10\text{h} - 2,5\text{h}) \text{ rozdiel pôvodného a nového času na proces} \\
 &\times 25 \text{ Eur sadzba interných nákladov pre technika seniora} \\
 &= 181\,250 \text{ Eur/rok}
 \end{aligned}$$

V tomto prípade sú však priame úspory až druhoradé. Prioritným cieľom je zníženie poruchovosti zariadení a eliminácia výpadkov vo výrobe. Odhad týchto úspor vychádza z priamych nákladov na opravy a nepriamych nákladov spojených s výpadkom vo výrobe. Povedzme, že ročné nepriame náklady spôsobené výpadkami vo výrobe sú 1 000 000 Eur + náklady na ich odstránenie ďalších 500 000 Eur.

Ak zavedením takéhoto systému dokážeme identifikovať koreňovú príčinu a navrhnuť skutočne efektívne opatrenia pri aspoň 10 % týchto problémov, hovoríme o potenciálnom ušetrení ďalších 150 000 Eur ročne.

Návratnosť takejto investície je, samozrejme, rôzna, avšak v niektorých prípadoch môžeme hovoriť o návratnosti už od jedného roka.

2. Riziká

Proces v realite obchádza informačný systém:

V praxi sa často stretávame s tým, že proces funguje istým spôsobom na papieri, ale v realite funguje cez tzv. *backchannels* a dôležité informácie sú predávané ústne či e-mailmi. Žiaľ, ak má systém fungovať korektne, musí mať úplné informácie. Napr. tickety typu „*Ten problém zo včera*“, alebo záznam po poruche s textom „*Porucha*“ nie je možné spracovať korektne.

Je dôležité pracovať so zamestnancami a dbať na to, aby v systéme boli všetky potrebné informácie, tak ako keby mal daný problém byť schopný vyriešiť kolega, ktorý pracuje v inom meste, a ktorého sme nikdy nevideli a nevieme sa s ním spojiť telefonicky. Systém sa môže rozhodnúť kvalitne len prípade, že sú v ňom všetky relevantné rozhodnutia. Nie vždy sa to však dá dosiahnuť úplne, a preto je dobré, aby dokázal tieto prípady identifikovať a nasmerovať na pracovníka, ktorý situáciu zhodnotí.

Odpor ku zmenám a obavy zo straty zamestnania:

Akákoľvek zmena bude prirodzene sprevádzaná odporom. Pracovníci majú v týchto prípadoch často pocit ohrozenia. Je preto dôležité so zamestnancami pracovať.

Vo väčšine prípadov po zavedení takéhoto systému pracovníci nájdu vo firme iné uplatnenie s vyššou pridanou hodnotou. Často ich takáto automatizácia odbremení od nudných a repetitívnych činností a umožní im venovať sa prospešnejším aktivitám.

Je dobré, ak sa so zamestnancami v tomto smere pracuje hneď od začiatku a ak sa im vysvetlí, ako budú veci fungovať po zavedení nového systému. Zároveň je potrebná aj podpora na strane manažmentu. Ak sa totiž manažment bude pozerať na projekt len cez primárne úspory (napr. ak sme ušetrili 7000 človekohodín ročne, je potrebné znížiť stavy aspoň o troch zamestnancov), projekt má naštartované na neúspech.

Kreativitu a invenciu ľudských pracovníkov zatiaľ stroje nahradiť nemôžu a zamestnanci majú často dlhoročné znalosti a skúsenosti, ktoré len ťažko možno nahradiť. Reálne benefity treba hľadať primárne v tom, že takáto automatizácia umožní transformáciu spoločnosti a tvorbu príležitostí s vyššou pridanou hodnotou.

4.6.5 Energetický manažment

Popis

Faktory na zavedenie AI v energetickom manažmente podnikov/miest/energetických komunít:

- **Identifikácia neefektívne prevádzkovaných zariadení** – predovšetkým vo výrobných podnikoch tvoria náklady na energie výrobných zariadení nezanedbateľnú časť nákladov. Zaujímavé je, že častokrát je možné znížiť spotrebu len správnym prevádzkovaním zariadení. Vo viacerých prípadoch sa po nasadení systému energetického manažmentu

podarilo identifikovať rozdiely v spotrebe toho istého zariadenia rádovo v desiatkach percent. Doplnením dát o prevádzkovaní týchto zariadení sa ukázala významná korelácia rozdielov s tým, ktorý operátor bol v danom čase pri danom zariadení. Dodatočným poučením zamestnancov, prípadne s prvkami motivácie, je možné dosiahnuť úspory niekedy v desiatkach percent;

- **Identifikácia neefektívnych zariadení** – často sa tiež ukazuje, že rovnaké zariadenia môžu mať výrazne odlišnú spotrebu. Môže to byť príznakom zlého technického stavu zariadenia, nesprávnej inštalácie či iného problému. Identifikácia týchto zariadení je kľúčová pre riešenie problému zbytočne vysokej spotreby. Náklady na prevádzku zastaraného či neefektívneho zariadenia v určitom okamihu v porovnaní s novým a efektívnejším zariadením presiahnu cenu tohto zariadenia. Často môže byť tiež indikátorom zásadnejšieho problému a predzvestou poruchy na danom zariadení. Týmto spôsobom je tiež možné identifikovať najvhodnejší čas na výmenu zariadenia, resp. moment, kedy sa prevádzka takéhoto zariadenia stáva menej výhodná ako jeho obnova či výmena;
- **Zvyšovanie energetickej efektívnosti budov** – stavebno-fyzikálne vlastnosti budov, účinnosť technických zariadení (vykurovací a osvetľovací systém, výťahy, vzduchotechnika a pod.) a spôsob ich využívania majú zásadný vplyv na konečnú spotrebu v budovách. Riadenie vykurovania, osvetlenia a ostatných komponentov energetických zariadení budovy v závislosti od jej využívania prináša zásadné úspory;
- **Identifikácia možností integrácie obnoviteľných zdrojov energie (ďalej len „OZE“) a optimalizácia riadenia energetického hospodárstva podnikov, miest alebo energetických komunit** – súčasný trend pri využívaní obnoviteľných zdrojov energie je často spájaný s *mikro-gridmi*. Navrhnutie optimálnych parametrov pre integráciu obnoviteľných zdrojov a ich následné riadenie v podmienkach čo najoptimálnejšieho využívania v rámci energetického systému podniku, mesta alebo energetickej komunity, je závislé od množstva premenných na strane výroby a spotreby energií, vrátane vplyvu meteorologických podmienok. Pre spracovanie týchto dát je vhodné použiť moderné *data science* prístupy s využitím strojového učenia a predikcií. Podobne pri riadení týchto sústav je nutné operatívne reagovať na veľké množstvo premenných a využitie umelej inteligencie sa tu priam ponúka. Predvídanie správania sa sústavy na fyzickej, ale aj ekonomickej úrovni je predmetom využitia AI v systémoch DERMS (*Distributed Energy Resources Management System*) a virtuálnych elektrární;
- **Optimalizácia plánu výroby a prevádzkovanie energeticky náročných zariadení v čase mimo špičku** – prepojením informácií o spotrebe s plánom výroby je niekedy taktiež možné dosiahnuť isté úspory v nákladoch na energiu. Je možné odložiť niektoré činnosti na nočné hodiny, kedy sú ceny energií spravidla nižšie a dosiahnuť tak isté úspory;
- **Vyhnutie sa pokutám za prekročenie rezervovanej kapacity** – prekročenie rezervovanej kapacity je sledované a sankcionované zo strany distribútora elektriny, pričom zosúladenie výroby s informáciou o energetickej náročnosti jednotlivých zariadení môže byť pomerne náročná úloha. Vďaka predikcii potenciálnych problémov sa však môžeme vyhnúť pokutám či nútenému odstaveniu výroby pri blížiacom sa prekročení rezervovanej kapacity;
- **Optimalizácia nákladov na el. energiu prevzatím zodpovednosti za odchýlky** – zaujímavou možnosťou ako optimalizovať svoje náklady na energiu, je prevzatie

zodpovednosti za odchýlku. V prípade, že výrobné fabriky majú dobre nastavený energetický management, dokážu aj vďaka spojeniu s plánom výroby predikovať svoju spotrebu výrazne presnejšie ako dodávateľ elektriny. Vďaka predikcii a následnému prevzatíu zodpovednosti za svoju odchýlku je možné dosiahnuť výrazne lepšie ceny elektriny.

Zaujímavým prvkom pri riešení energetickej efektívnosti (predovšetkým pri výrobných podnikoch) je možnosť identifikovať spotrebu elektriny jednotlivých zariadení aj bez nutnosti inštalácie podružných meračov na každé zariadenie.

Práve vďaka umelej inteligencii je dnes možné identifikovať spotrebu samotných zariadení len na základe analýzy tzv. obálky – t. j. analýzou celkovej spotreby (ideálne aj s parametrami o kvalite, ktoré dnešné inteligentné meracie zariadenia dokážu bežne poskytnúť). Spojením týchto údajov s údajmi z MES systému (kedy ktorý stroj pracoval) je možné vyhodnotiť, aký vplyv na spotrebu majú jednotlivé zariadenia a odhaliť najmenej efektívne zariadenia či prípadné anomálie.

- **Identifikácia odberateľov s nepravidelnou spotrebou** – kvalitná predikcia spotreby bilančnej skupiny je kľúčová pre subjekty na energetickom trhu, ktoré prebrali za danú bilančnú skupinu zodpovednosť za odchýlku. Nepresné predikcie majú dopad na náklady pre elimináciu odchýlky v sústave aktiváciou regulačných zdrojov. Pri predikovaní spotreby v bilančnej skupine je dôležité jej predvídateľné správanie, ktoré je možné sledovať na základe historickej spotreby. Problémom sú odberatelia s vysokým nepravidelným odberom, napr. štadión, výstavisko či fabrika, ktorá má inštalovaný stroj s vysokou spotrebou, avšak používa ho nepravidelne. Takéto odberné miesta je výhodnejšie vyňať z predikovanej skupiny a predpovedať ich odber samostatne. S takýmito odberateľmi je pritom často možné sa dohodnúť, že svoje aktivity hlásia svojmu dodávateľovi (resp. subjektu zodpovednému za odchýlku) v dostatočnom predstihu. Ak odberateľ súhlasí s takýmto režimom, môže získať od svojho dodávateľa výhodnejšie podmienky;
- **Hľadanie anomálií pri spotrebe u odberateľov energií** – anomálie pri spotrebe môžu indikovať rôzne neželané javy, ako sú úniky, poškodené zariadenie či rôzne trestné aktivity. Ich včasným odhalením môžeme predísť veľkým škodám predovšetkým v spoločnostiach, ktoré majú rozsiahlu technológiu a energetickú infraštruktúru;
- **Využitie umelej inteligencie v tejto oblasti vychádza z detekcie zmien oproti „bežnému stavu“**. Počas učenia modelu je preto potrebné trénovať na dátach, v ktorých sú už anomálie jednoznačne identifikované. Následne je možné tento monitoring automatizovať a venovať sa už len anomáliám, ktoré umelá inteligencia identifikuje ako potenciálnych kandidátov. Nedá sa preto očakávať, že po nasadení novej umelej inteligencie systém sám automaticky identifikuje úniky;
- **V súčasnosti prebieha masívna inštalácia inteligentných meracích systémov**, ktoré bežné informácie o spotrebe dopĺňajú aj o ďalšie dáta, na základe ktorých je možné vyhodnocovať aj kvalitu. Týmto spôsobom je možné napr. odhaliť niektoré problémy so zariadeniami, ktoré nemusia pracovať optimálne;
- **Predikcie pri obchodovaní na trhu s energiami** – trh s energiami prináša podobné možnosti ako trh s akoukoľvek komoditou. Vedieť predikovať spotrebu, výrobu,

akumuláciu, smer odchýlky v sústave či ceny energií umožňuje nielen optimalizovať svoje náklady na elektrickú energiu, ale poskytuje aj priestor pre rôzne špekulácie. Zároveň má však obchodovanie s energiami svoje špecifiká, ktoré vyplývajú z vlastností týchto komodít. Napr. pri elektrickej energii sú problémom limitované možnosti jej uskladnenia a prenosová kapacita cezhraničných vedení, ktorá zas obmedzuje voľné obchodovanie so subjektmi z iných štátov.

Predpoklady

Zákazník by mal spĺňať isté predpoklady, aby mohol uvažovať o nasadení AI riešení. Predpoklady odporúčame členiť za každých okolností v zmysle nižšie uvedenej štruktúry a nemeniť ich poradie:

1. Proces

- **Energetická efektívnosť** – okrem zavedenia procesu zberu a analýzy meraní je dôležité reálne zaviesť proces pre analýzu týchto dát a hlavne návrh a realizáciu opatrení. Rovnako dôležité je zaviesť proces pre následné vyhodnocovanie efektívnosti týchto opatrení. Niektoré softvérové riešenia obsahujú aj softvérovú podporu pre tieto procesy, avšak zavedenie týchto procesov je na samotnom obstarávateľovi;
- **Identifikácia technických a netechnických strát** – ak má spoločnosť veľké množstvo meraní, je veľmi pravdepodobné, že sa len hromadia v databáze, pretože efektívna a kontinuálna analýza je pomerne prácna a nákladná. Veľká časť rutinného monitoringu sa pritom dá čiastočne alebo úplne automatizovať;
- **Obchodovanie na trhu s energiami** – ak spoločnosť obchoduje na trhu s energiami, určite už má zavedené procesy, ktoré zabezpečujú predikcie. Tie je možné riešiť jednoduchými štatistickými metódami na základe historických dát až po komplexné modely s prvkami umelej inteligencie. Či už spoločnosť aktívne obchoduje na trhu, alebo o tom len uvažuje, prediktívne modely na báze umelej inteligencie sa už dnes dostávajú z okraja záujmu do mainstreamu;
- **Identifikácia odberateľov s nepravidelnou spotrebou** – tento bod sa týka spoločností, ktoré majú (alebo o tom uvažujú) zodpovednosť za svoju odchýlku. V takom prípade zavedenie procesu takejto analýzy svojich odberných miest môže mať zaujímavý efekt na schopnosť predikcie a plánovania.

2. Dáta

Monitorovaním spotreby v reálnom čase a sledovaním historických dát môžu systémy strojového učenia identifikovať scenáre, čo umožní vytvoriť vzorec, ktorý určí pravidlá na zdokonalenie procesu riadenia budov. Ide o adaptačný proces učenia, čo znamená, že čím viac informácií a možných scenárov budú poznať, tým budú vedieť lepšie reagovať.

Pri zhromažďovaní dát sú potrebné minimálne tieto dátové zdroje:

- kontinuálne meranie spotreby energií;
- zber dát z prevádzkových podmienok v interiéri;
- zber dát z prevádzkových podmienok v exteriéri;
- počet ľudí nachádzajúcich sa v budove.

Zber dát však nemá význam, ak ich nemá kto vyhodnocovať. Množstvo dát, ktoré technológie zhromažďujú a uchovávajú, môže priniesť prelomový prínos organizáciám, ale len ak ich budú schopné správne interpretovať. Práve na to slúži dátová veda.

Pri energetickom manažmente potrebujeme mať predovšetkým merania z konkrétnych meračov spotreby elektrickej energie.

Pri optimalizácii nákladov na energie sú vhodné aj údaje z ďalších meračov. V prípade výroby ide o dáta zo systémov typu MES, SCADA, prípadne dáta zo *smart building* snímačov (teplota v jednotlivých miestnostiach, obsadenosť priestorov, atď.).

Pri obchodovaní na trhu s energiami vstupujú do hry predovšetkým dáta o historickej spotrebe a výrobe, veľmi dôležité sú však aj údaje o lokálnom počasí. Zaujímavým spôsobom sa dajú zužitkovať aj historické údaje o cene elektriny a systémovej odchýlke v elektrizačnej sústave.

3. Aplikácie

Môžeme použiť zberové centrály, MES, Scada, *Smart building* monitoring, DERMS, virtuálnu elektráreň a systémy na manažment energie.

4. Infraštruktúra

- **Meracie zariadenia** – jednotlivé meracie zariadenia merajúce spotrebu energií ako aj ďalšie súvisiace dáta;
- **Zberová infraštruktúra** – platforma pre zber údajov z jednotlivých meracích zariadení. Zber dát je možný buď priamo, alebo cez tzv. koncentrátory, ktoré sú umiestnené blízko meradiel a zasielajú údaje z viacerých meradiel a senzorov;
- **Analytická infraštruktúra** – časť infraštruktúry, na ktorej pobeží samotná analýza, spracovanie meraní a následné predikcie, reporty, vizualizácie. Líši sa v závislosti od konkrétneho riešenia.

Inteligentné meracie zariadenia:

- Merače spotreby elektrickej energie
- Merače spotreby plynu
- Merače spotreby studenej a teplej vody
- Merače spotreby tepla

Senzory prevádzkových podmienok

- Senzory teploty (interiér a exteriér)
- Senzory vlhkosti (interiér a exteriér)
- Senzory koncentrácie CO₂ (interiér)
- Senzor merania rýchlosti vetra (exteriér)

Doplnkové senzory a zariadenia

- Snímače otvorenia okien a dverí
- Inteligentné termostaty
- Senzor zadymenia
- Senzory pohybu
- Počítanie počtu osôb v budove

IIoT brány (Gateway) – komunikačná brána – hardvérový produkt určený na pripojenie akéhokoľvek typu zdroja toku dát, vrátane zdrojov s bezdrôtovým spojením, za účelom zhromažďovania a spracovania dát z celej podnikovej infraštruktúry, vrátane dát zo základného modelu, neobsahuje analytické funkcie. Zhromaždené a spracované dáta budú môcť byť vypublikované do IT infraštruktúry pre následnú analýzu zozbieraných dát.

Edge Computing – hardvérový produkt, modulárne zariadenie IIoT Gateway doplnené o analytické softvérové nástroje obsahujúce všetky nevyhnutné funkcie pre riadenie, zhromažďovanie a spracovanie dát, ich dočasné ukladanie a analýzu dát a udalostí v reálnom čase, ale aj na priame riadenie pripojených zariadení, t. j. vypínanie, zapínanie, zmena prevádzkových parametrov, atď.

IIoT platforma – kompletný balík softvérových nástrojov pre analýzu dát a udalostí v reálnom čase. Pomocou IIoT platformy je možné zbierať dáta zo senzorov, riadiacich jednotiek, aplikácií, databáz a ďalších zdrojov údajov o faktoroch, ktoré majú priamy alebo nepriamy vplyv na prevádzku.

Platformou sú spracované všetky relevantné dáta z výrobných systémov a dátových zdrojov v podniku a sprístupňuje (zhromažďuje) všetky potrebné údaje na jedno miesto. Toky dát (tzv. *streams*) zvyčajne buď nie sú ukladané vôbec, alebo sú distribuovane uložené v rôznych informačných alebo riadiacich systémoch, ale nie sú centrálné prístupné alebo nie sú prístupné vôbec.

5. Ľudia²³

Vo väčšine prípadov samotné priemyselné podniky nedisponujú odborníkmi, ktorí by dokázali na základe svojich skúseností optimálne navrhnuť a vytvoriť vhodný systém na energetický manažment.

Odporúčame pri návrhu a výbere vhodného systému EM osloviť odborný tím. Dnes je už takmer bežné, že spoločnosti, ktoré nielen dodávajú, ale aj navrhujú konkrétne riešenia, dokážu priemyselnému podniku poskytnúť takéto poradenstvo bezplatne. Samozrejme, pri výbere takéhoto dodávateľa je dobré pýtať sa na jeho zázemie, referencie a pod.

Ak potrebujete pomoc pri vývoji správnej stratégie a prístupu k správnym nástrojom, aby ste uspeli v transformácii s umelou inteligenciou, mali by ste hľadať inovačného partnera s hlbokými odbornými znalosťami a rozsiahlym portfóliom riešení umelej inteligencie.

Profily na strane zadávateľa:

- Vedúci oddelenia energetického manažmentu spolupracuje s dátovými vedcami na určení problémov a cieľov;
- Operátori na základe školení vykonávajú komplementárne úlohy a fungujú ako eskalačný stupeň;
- Informatici zodpovedajú za prevádzku výpočtovej techniky a sieťovej infraštruktúry;

Niektoré z požadovaných pozícií môžu byť poskytnuté zástupcami tretích strán, externými konzultantmi.

Profily na strane dodávateľa:

²³ Co je umělá inteligence? [Dostupné online](#).

- Dátoví inžinieri spravujú dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;
- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- IT architekti spravujú základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Vývojári aplikácií so znalosťou *machine learning* algoritmov (Python, R a iných.), ktorí nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Programátori a ďalší IKT špecialisti zodpovedajú za implementáciu riešenia tak po stránke softvéru aj hardvéru.
- Experti na vizualizáciu a interpretáciu dát.

6. Organizácia²⁴

Samotné zavedenie systému s umelou inteligenciou nepostačuje. Vo firme je potrebné reálne zaviesť procesy, ktoré umožnia využiť informácie, ktoré softvérové riešenie s umelou inteligenciou poskytne. Bežnou praxou napríklad je, že energetickému manažmentu sa vo firme venuje jedno oddelenie, ktoré v prípade identifikácie problému nemá priamy vplyv a možnosti, ako zmeniť neželaný stav.

Povinnosť mať energetický audit mali do konca roku 2014 iba priemyselné a pôdohospodárske prevádzky s vyššou spotrebou energie, pri ktorých sa predpokladal väčší potenciál energetických úspor (podľa zákona 476/2008). Od konca roku 2014 sa povinnosť rozšírila na všetky veľké podniky (podľa zákona 321/2014). Teda tie, ktoré majú nad 250 zamestnancov, alebo ročný obrat nad 50 miliónov Eur, alebo ich celková ročná súvaha presahuje 43 miliónov Eur.

Náhradou za energetický audit je systém energetického manažérstva podľa medzinárodnej normy ISO 50001. **Dôležité kroky, ktoré by mala organizácia vykonať pred zavedením systému energetického manažérstva podľa normy ISO 50001:**

- analýza súčasného stavu riadenia energií;
- stanovenie energetického tímu;
- tvorba, implementácia a údržba energetickej politiky;
- stanovenie energetických cieľov a štartovacej čiary pre porovnávanie spotreby, benchmarky a energetické indikátory;
- definovanie kontrolných mechanizmov a spracovanie dokumentácie.

Proces analýzy dát a prijímanie opatrení na základe dát je skôr iteratívny než lineárny, nižšie uvádzame zvyčajný postup pri modelovaní dát²⁵:

1. Plán: Definuje sa projekt a jeho potenciálne výstupy.
2. Príprava: Vytvorí sa pracovné prostredie, dátovým vedcom sa poskytnú správne nástroje a prístup k správnym dátam a ďalším zdrojom, napríklad výpočtovému výkonu.
3. Naplnenie: Pracovné prostredie sa naplní dátami.
4. Skúmanie: Dáta sa analyzujú, študujú a vizualizujú.
5. Modelovanie: Zostavujú sa, učia a overujú sa modely, aby fungovali podľa požiadaviek.
6. Nasadenie: Modely sa nasadia do produkčného prostredia.

²⁴ Desiatky firiem čaká energetický audit. [Dostupné online.](#)

²⁵ ISO 50001 - systémy energetického manažérstva. [Dostupné online.](#)

Ak chcete čo najlepšie využiť inteligentný energetický manažment a vyhnúť sa problémom, ktoré bránia jeho úspešnej implementácii, musíte zaviesť tímovú kultúru, ktorá plne podporuje ekosystém umelej inteligencie.

Prínosy a riziká

1. Kvalitatívne prínosy

Systematický prístup k energetickému manažmentu prináša so sebou veľa výhod. Na základe poznania skutočností v oblasti spotreby energie a nákladov možno prijímať konkrétne technické alebo organizačné racionalizačné opatrenia na optimalizáciu spotreby. V prípade využitia informačných systémov zároveň majú všetci zodpovední pracovníci okamžitý prístup k informáciám²⁶.

Výsledkom celého snaženia je významne udržateľné zníženie nákladov na energiu, zníženie nepriaznivých vplyvov spotreby energie na životné prostredie a zvýšenie konkurencieschopnosti vlastníka alebo správcu budovy.

Efektívne využívanie energie pomáha organizáciám ušetriť peniaze, rovnako ako pomáha šetriť zdroje a zabráňovať zmenám klimatických podmienok. ISO 50001 podporuje organizácie vo všetkých odvetviach v efektívnejšom využívaní energie, a to prostredníctvom rozvoja energetického manažérského systému.

Systém energetického manažérstva ďalej organizáciám umožňuje:

- Zredukovať emisie bez negatívneho vplyvu na prevádzky;
- Pokračovať v zlepšovaní využitia energie a produktov;
- Definovať súčasný stav využitia energie a zdokumentovať úspory pre interné alebo externé použitie;
- Aktívne riadiť využitie energie a náklady;
- Zvýšiť pracovnú morálku²⁷.

Ako sa zmenia procesy po zavedení AI riešenia:

Prístup k zavedeniu systému energetického manažmentu, ako aj vykonávanie energetických auditov závisí od vrcholového manažmentu. Norma ISO 50001 kladie veľký dôraz na prístup vrcholového manažmentu k hospodáreniu s energiou.

Úlohy pre vrcholový manažment:

- Musí preukázať svoj záväzok podporovať EM a sústavne zlepšovať jeho účinnosť;
- Musí vymenovať zástupcu manažmentu so zodpovedajúcimi zručnosťami, kompetentnosťou a právomocami;
- Musí definovať energetickú politiku, ktorá bude konkrétne vyjadrovať záväzok organizácie zlepšiť hospodárenie s energiou.

Organizácia musí okrem iného²⁸:

- Analyzovať používanie energie a jej spotrebu na základe merania a ďalších údajov;
- Identifikovať oblasti s významným používaním energie na základe analýzy;

²⁶ Prínosy energetického manažmentu v budovách. [Dostupné online.](#)

²⁷ ISO 50001 - systémy energetického manažérstva. [Dostupné online.](#)

²⁸ Skúsenosti so zavádzaním systému energetického manažérstva podľa ISO 50001. [Dostupné online.](#)

- Identifikovať, určiť priority a zaznamenávať príležitosti na zlepšenie hospodárenia s energiou;
- Začleniť energetickú efektívnosť do systému riadenia firmy;
- Robiť rozhodnutia v hospodárení s energiou založené na faktoch;
- Stanoviť ciele a akčné plány;
- Adekvátne zaisťovať zdroje na zvýšenie efektívnosti využitia energie.

7. Kvantitatívne prínosy²⁹

Zvyšovanie energetických nákladov je „nočnou morou“ manažérov. Len veľmi malý počet podnikov u nás i vo svete zatiaľ spustil programy zamerané na ich efektívne vynakladanie. Hlavným dôvodom je uhol pohľadu na túto rozpočtovú položku. Na energetickú spotrebu sa totiž stále pozeráme ako na nevyhnutné pasíva namiesto investície, ktorá môže priniesť úspory.

- **Úspory** – programy EM sú také účinné, že vykazujú typické zníženie ročných nákladov na energiu cca 5 – 10 %. Z praxe vieme, že v priemere je možná úspora energií až 25 – 30 %. Najčastejšie odporúčania zahŕňajú opravy elektroinštalácií, odstránenie tepelných strát, regulovanie spotreby teplej vody a vykurovania alebo optimalizáciu technológie výroby;
- **Vyššie výnosy** – efektívny energetický manažment môže priniesť výhody s minimálnou mierou rizika a vplyv na biznis je výrazný. Vďaka aktívnemu riadeniu procesov už dokážeme úspešne predpovedať návratnosť týchto investícií. Merateľný a spoľahlivý energetický manažment dovoľuje firmám rozhodovať sa na základe reálnej energetickej spotreby. Firmy tak môžu zmeniť svoje klesajúce energetické náklady na konkurenčné výhody;
- **Očakávaný ROI** – zmena pohľadu môže preukázateľne ušetriť energiu a priniesť vyššiu kontrolu spotreby. Stále viac sa potvrdzuje, že investície do inteligentných riešení na meranie a riadenie energetickej spotreby majú svoje opodstatnenie. Kompaktný systém energetického riadenia sleduje spotrebu energie na všetkých úrovniach – od izolácie až po osvetlenie, kúrenie, klimatizáciu a vodu. Vnútorná miera výnosnosti môže byť pri týchto projektoch naozaj vysoká – modifikovaná vnútorná miera výnosnosti môže dosiahnuť až 29 %.

Možné úspory pri energetickom manažmente sa líšia od konkrétneho prípadu, avšak bežné sú prípady úspory na energiách v rozsahu 5 – 15 %.

2. Riziká

Nezavedenie potrebných procesov na realizáciu opatrení:

Žiaľ, je pomerne bežné, že spoločnosti dnes zavedú informačný systém, ktorý dokáže zbierať a analyzovať dáta, avšak spustením systému do prevádzky projekt pre nich končí. Pri akejkoľvek implementácii informačného systému je na dosiahnutie cieľov nutné, aby sa daný systém aj používal a aby informácie, ktoré poskytne, boli následne využité pri ďalšom rozhodovaní a pri realizácii následných opatrení na zníženie spotreby.

²⁹ Energetické náklady. [Dostupné online](#).

Ak napríklad odhalíme problém na jednom mieste merania s nezvyčajne vysokou spotrebou, je zvyčajne nutné problém ďalej analyzovať. Ak sa ukáže, že príčinou je poruchové zariadenie, treba ho dať opraviť či vymeniť. Ak opatrenia nie sú realizované, rovnako nebudú naplnené ani očakávania.

Nedostatočné zlepšenie po zavedení umelej inteligencie:

Umelá inteligencia často dokáže zvýšiť presnosť oproti konvenčným algoritmom o desiatky percent. Nie je to však pravidlom. Samozrejme, v prvom rade je potrebné mať kvalitné vstupné dáta (čo môže byť niekedy veľký problém). Niekedy však aj v prípade splnenia všetkých predpokladov sa stane, že zlepšenie je len zanedbateľné. Nastáva to typicky v dvoch prípadoch:

- Charakter dát je príliš náhodný a zo vstupných parametrov nie je možné urobiť presnejšiu predikciu;
- Dáta majú veľmi jednoduchú charakteristiku a na dosiahnutie veľmi dobrej presnosti nie je potrebná umelá inteligencia.

Pre elimináciu týchto rizík je dôležité urobiť v rámci projektu tzv. *Proof of concept*, pri ktorom sa možnosti a presnosť modelov vyhodnotia v „laboratórnych“ podmienkach bez veľkých investícií. Nie vždy je to, samozrejme, možné, avšak v prípade, že už máme k dispozícii aspoň časť potrebných dát, je veľmi rozumné pred samotnou investíciou urobiť tento test, či nám dané riešenie môže priniesť očakávané výsledky. Väčšina dodávateľov je schopná a ochotná urobiť takéto overenie buď zadarmo, prípadne za symbolických finančných podmienok.

4.6.6 Marketing a podpora predaja

Popis

AI v maloobchode sa sústreďí na kľúčové piliere digitálnej transformácie:

- Obohacuje maloobchodných zákazníkov individualizovanou/personalizovanou skúsenosťou;
- Zabezpečuje, aby maloobchodní zamestnanci poskytovali diferencované skúsenosti zákazníkom;
- Optimalizuje maloobchodný dodávateľský reťazec;
- Mení maloobchodné produkty a služby tak, aby zákazníkom doručili novú hodnotu;
- Rozširuje existujúce biznisové procesy o nové, dosiaľ nemožné.

Maloobchodné riešenia založené na dostupných AI cloudových službách umožňujú realizovať digitálnu transformáciu maloobchodu nasledujúcimi spôsobmi:

Obohatenie maloobchodných zákazníkov individualizovanou skúsenosťou:

- Transformujete spôsob, akým zákazníci začnú proces nákupu a pomocou automatizovaných postupov im pomôžete podniknúť ďalší najlepší krok;
- Analyzujete správanie a emócie zákazníkov a automaticky dodávate vysoko relevantné ponuky produktov a služieb;
- Poskytujete zákazníkovi osobného digitálneho asistenta, aby nasmeroval rozhodovanie a skrátil konverzný cyklus.

Zabezpečenie, aby maloobchodní zamestnanci poskytli diferencované skúsenosti zákazníkom:

- Tvoríte heatmapy založené na správaní zákazníkov v obchode s cieľom porozumenia, ktoré rozloženie obchodu vedie k zvýšeniu konverzných pomerov a predaja;
- Optimalizujete priestor pre regály a police a zabezpečujete, aby bol tovar vždy označený presnou cenou a zľavami;
- Automaticky upozorňujete odborných zamestnancov ak majú zákazníci konkrétne problémy s produktom alebo službou.

Optimalizácia maloobchodného dodávateľského reťazca:

- Vytvárate presnejšie dopytové prognózy a cenové informácie založené na automaticky zbieraných verejných a zákazníckych údajoch;
- Optimalizujete doručenia objednávok a znižujete náklady pomocou lokalizácie zákazníka a jeho predpokladaného pohybu za účelom plánovania plnení distribuovaných objednávok;
- Automatizujete procesy dopĺňania zásob a optimalizujete riadenie zásob.

Zmena maloobchodných produktov a služieb tak, aby zákazník poskytl novú hodnotu:

- Identifikujete preferencie zákazníka z viacerých zdrojov a porovnávate ich s najrelevantnejším zdrojom zásob;
- Umožňujete zákazníkovi testovať, skúšať a prispôbovať produkty v predajni;
- Agregujete a analyzujete náklady a správanie zákazníka zachytené v priebehu nákupu za účelom ďalšieho doladenia zákazníckej nákupnej cesty.

Rozšírenie existujúcich biznis procesov o nové, dosiaľ nemožné, či neexistujúce:

- Koncept „digitálneho dvojčata“ – vďaka *edge* technológiám a spracovaniu informácií v reálnom čase sa vyskytuje možnosť vytvoriť digitálnu kópiu fyzického produktu a uchovanie informácií vo vzťahu k danému fyzickému produktu. Príklad: vďaka zabudovaniu RFID alebo bluetooth senzorov do tenisiek vieme pomocou mobilnej aplikácie sledovať počet zvládnutých kilometrov, celkový čas tréningu a pod;
- Vďaka prepojenosti informačných systémov na úrovni v reálnom čase má zákazník možnosť zasahovať do výrobných procesov a konfigurovať budúce výrobky podľa svojich predstáv;
- Možnosť rozšíriť biznis procesy o nové, dosiaľ nemožné – vďaka vyššie uvedeným možnostiam zavedenia mobilnej aplikácie pre akumuláciu a spracovanie digitálnych informácií o konkrétnom produkte sa otvára výrobcovi možnosť monetizácie danej mobilnej aplikácie, napríklad formou rôznych edícií týchto aplikácií pre zákazníkov (licenčný plán PRO/Premium, standard a pod), na základe zakúpenej licencie má zákazník prístup k presnejším a personalizovanejším informáciám;
- Koncept „partnera pre zákazníka“ pri dosiahnutí cieľov zákazníka – prechod od ponuky len tovaru (predaj tenisiek) k ponuke služby (dosiahnutie lepších výsledkov).

Predpoklady

1. Proces

Retail je veľmi široké odvetvie a s jeho šírkou narastajú aj možnosti použitia technológií za účelom zlepšovania hospodárskych výsledkov firmy a zvýšenia spokojnosti spotrebiteľov.

Firma ako celok a zvlášť retailová sieť, ktorá obsluhuje veľa pobočiek, má k dispozícii obrovské množstvo interných dát. Za interné dáta považujeme tie, ktoré majú pôvod vo firme, alebo sú jej vlastníctvom (informácie o zákazníkoch, predajné dáta, skladové dáta, údaje z vernostného systému a pod.)

Spracovanie takéhoto veľkého objemu dát vie byť nákladné z hľadiska finančného, ale aj časového. Preto je dôležité ešte pred samotnou implementáciou akejkoľvek technológie mať stanovený jasný cieľ – čo chceme získať implementáciou danej technológie. Takáto požiadavka by mala vychádzať z biznisu.

Príklady biznisových cieľov:

- Zvýšiť predaj zákazníkom v danom segmente (nie segmentácia zákazníkov);
- Zvýšiť podiel zákazníkov využívajúcich vernostný program;
- Zvýšiť odpredaj starých skladových položiek za najvyššiu možnú cenu (nie optimalizovať skladové zásoby na pobočkových skladoch);
- Zvýšiť hodnotu priemerného košíka o xy %;
- Zvýšiť hodnotu UPT (*Units Per Transaction*) na úroveň 2,5;
- Zlepšiť hodnotenie mobilných aplikácií na Google Play/AppStore o 2 hviezdičky;
- Zvýšiť doručiteľnosť newslettera/výtlač newslettera o xy %;
- Znížiť odchody zákazníkov dlho čakajúcich pri pokladni;
- Zvýšiť návštevnosť webových stránok výrobcu alebo dodávateľa;
- Navýšenie času, ktorý zákazníci strávia na webe;
- Zvýšenie online konverzií.

Ako je možné vidieť na uvedených príkladoch, vymedzujú sa na konkrétnu úlohu. Na to, aby retailer takúto misiu splnil, potrebuje nahliadnuť len do časti svojich dát. Ak ideme zvyšovať doručiteľnosť newslettera, (napr. vo vzťahu ku konverznnej miere), zo všetkých dostupných (interných) dát nás zaujíma predovšetkým tabuľka s odberateľmi. Pre newsletter však nie sú podstatné všetky polia tejto tabuľky. Preto sa v prvom kroku pri kontrole dátovej kvality zameriame na polia, ktoré sú pre túto úlohu kľúčové. Napr. meno, priezvisko, e-mail.

Až z konkrétneho prípadu, ktorý ideme riešiť, následne „vypadnú“ potrebné nástroje, ľudia, oddelenia a procesy, ktoré bude treba vo vzťahu k úlohe spraviť. Môže sa teda stať, že danú úlohu vyriešime aj bez použitia drahých a zložitých technológií.

Celý proces stojí a padá na najspodnejšej vrstve a tou sú dáta, konkrétne ich kvalita. Jednotlivé poschodia tzv. DIKW pyramídy si môžeme predstaviť ako formy analytiky – od deskriptívnej (*Data*), cez diagnostickú (*Information*), prediktívnu (*Knowledge*), až po preskriptívnu (*Wisdom*).

Pokiaľ nebudeme mať zvládnuté elementárne procesy na najspodnejšej vrstve, ktorými nastavujeme kvalitu, všetky ďalšie vrstvy budú mať nedôveryhodné výstupy a celá analytika bude nespôľahlivá.

Deskriptívna analytika – je základná analýza, ktorá štandardne dáva odpoveď na otázku: Čo sa stalo? Štandardne si ju vieme predstaviť ako kontingenčnú tabuľku v Exceli. Už tento jednoduchý pohľad nám

povie veľa o dátovej kvalite. Je preto nevyhnutné zvládnuť tieto základy ak chceme ďalej skúmať dáta a podrobovať ich ďalším metódam.

Diagnostická analytika – ide o prvú z foriem pokročilej analytiky. Táto odpovedá na otázku: prečo sa to stalo? V tomto prípade podrobujeme dáta ďalším technikám ako sú *drilldowny*, aplikácia štatistických metód, *data mining* a podobne.

Prediktívna analytika – tu už môžeme hovoriť aj o formách umelej inteligencie a neurónových sieťach. Štandardne dáva odpoveď na otázky: Čo sa stane? Ako sa budú vyvíjať kľúčové ukazovatele do budúcnosti? Koľko ľudí môžeme očakávať na kamenných prevádzkach?

Preskriptívna analytika – často označovaná ako konečná hranica analytických možností podniku. Len veľmi málo firiem ju má dobre zvládnutú. Častokrát ide o veľké firmy a technologických gigantov, ktorí majú k dispozícii veľa dát. S rastúcimi investíciami do nových technológií a rýchlym rozvojom startupov prichádza vlna rôznych riešení práve pre tento typ analytiky. Tieto algoritmy sa však stále budú opierať o interné dáta firmy, na ktoré budú kladené veľmi vysoké nároky z pohľadu dátovej kvality. Preskriptívna analytika odpovedá na otázku: Čo mám urobiť?

2. Dáta

Základným predpokladom na nasadenie akejkoľvek technológie – *machine learning* nevynímajúc – sú kvalitné dáta. Tie existujú zväčša len v ideálnom prostredí a v realite sú skôr raritou. Kvalita dát sa nedá spraviť plošne. Bolo by veľmi komplikované a nákladné opraviť a zjednotiť všetky dáta, ktoré podnik má. Treba myslieť aj na to, že zlepšovanie kvality dát nie je len o samotnom dopĺňaní databáz a oprave jednotlivých PDE (*Physical Data Element*) a oprave štruktúr. Zavedenie kvality dát je najmä o procesoch a tie bývajú najdrahšie. To, že opravíme dáta a vytvoríme „stav 0“ ešte neznamená, že o rok sa opäť nedostaneme do nevyhovujúceho stavu.

Preto ak máme zmysluplne využiť technológie, a teda aj strojové učenie, mali by byť všetky nasadenia podriadené biznisovému cieľu. Až keď máme konkrétny cieľ, môžeme vybrať ktoré dáta na tento účel použijeme a nad týmito dátami začneme nastavovať kvalitu dát.

Z hľadiska použitia vieme dáta segmentovať do jednoduchej matice:

- Interné – externé;
- Štruktúrované – neštruktúrované.

Podľa použitia vieme následne vybrať vhodné aplikácie alebo databázy, ktoré nám dáta budú podsúvať.

Výhodou spoločností, ktoré sa zameriavajú na predaj koncovému zákazníkovi je, že majú k dispozícii veľké množstvo štruktúrovaných dát použiteľných aj pre strojové učenie.

Devízou štruktúrovaných dát je ich konkrétnosť. Ak máme kvalitu dát na dobrej úrovni, vieme z týchto údajov získať veľa aj bez použitia umelej inteligencie.

Skutočný poklad sa však ukrýva v dátach neštruktúrovaných. Pod týmto pojmom si môžeme predstaviť napríklad e-mailovú komunikáciu, nahrávky telefonických rozhovorov, videá z *in-store* kamier, ale aj facebookové príspevky a komentáre, diskusie a rôzne iné formy online komunikácie. Na analýzu tejto formy dát je strojové učenie výborným pomocníkom.

Prepojením týchto dát so štruktúrovanými dostaneme nový pohľad na zákazníka a vieme sa zamerať na kľúčové ukazovatele, ktoré majú vyššiu pridanú hodnotu, prípadne nám vedia rozšíriť pohľad na naše štandardné KPI.

Je iné pozeráť sa na ukazovateľ UPT (počet položiek na účtenke) vo vzťahu k transakčným dátam a je iné na toto isté číslo nazrieť cez zóny, v ktorých zákazníci trávajú najviac času. Informácie o tom nám vedia poskytnúť kamery a softvér, ktorý tieto zábery vyhodnotí. Následne môžeme aj podľa transakčných dát nastaviť jednotlivé zóny tak, aby zákazníkovi dávali zmysel.

3. Aplikácie

Veľa firiem funguje na takzvaný „technologický dlh“. Znamená to, že zvyšovanie požiadaviek na zavedenie nových technológií bolo zo strany firmy dlhodobo zanedbávané a potláčané, pretože manažment v týchto investíciách nevidel priamy finančný návrat.

Výsledkom bolo, že tieto potreby boli kompromisne splnené ohýbaním existujúcich systémov do čiastočne vyhovujúceho stavu, prípadne aplikáciou rôznych iných krátkodobých riešení. Nie je výnimkou, že spoločnosť, ktorá dokáže generovať miliónové obraty, beží na jednom ERP, ktorého súčasťou je všetko – od fakturácií, skladového hospodárstva, CRM, cez obsluhu webových portálov až po zber dát z počítačiel zákazníkov.

Vždy po pridaní nového modulu sa síce tento problém vyriešil, ale iba naoko. Akýkoľvek ďalší zásah alebo zmena tohoto systému si bude do budúcnosti vyžadovať dôkladnú dopadovú analýzu, testovanie a množstvo premrhaných interných človekohodín. Skôr či neskôr každý narazí na limit systému a bude nutná jeho kompletná výmena. S narastajúcim počtom zdrojov dát sa tento moment blíži exponenciálne. Migrácia hlavného systému vie trvať roky a pre väčšie podniky vie mať nepodarená výmena nosnej aplikácie fatálne následky.

Záleží od konkrétneho prípadu, zvyčajne však platí, že každú časť procesu by mala obsluhovať aplikácia, ktorá je primárne na to určená.

V retaile je veľmi dôležitá analytika a rýchle vyhodnocovanie zákazníckych dát. Tá primárne vychádza z transakčných dát (vydané bloky, faktúry). Na tieto dáta vieme následne naviazať dáta z ďalších zdrojov. Záleží od povahy údajov, či ich budeme na transakčné dáta prepájať cez unikátne identifikátory, alebo cez časovú značku (timestamp). Keď máme pripravený dataset a máme k nemu biznis case, môžeme prejsť k samotnej analytike.

4. Infraštruktúra

Ideálnym stavom je existencia tzv. *data lake*. Zjednodušene sa dá povedať, že ide o úložisko, do ktorého je možné ukladať veľké množstvo štruktúrovaných, pološtruktúrovaných a neštruktúrovaných dát. Je to miesto na ukladanie všetkých typov dát v ich natívnom formáte bez pevných limitov na veľkosť. Na rozdiel od bežných DWH (*Data Warehouses* – dátových skladov), kde sú údaje ukladané hierarchicky, *data lake* má plochú architektúru. Každý dátový prvok má jedinečný identifikátor a je označený súborom metadát.

Pre malé a stredné firmy predstavuje investícia do takejto infraštruktúry vysoké náklady s častokrát neistým výsledkom. Na trhu existujú aj cloudové riešenia pre tento segment, kľúčovú rolu zohráva kvalitný ETL systém. Ide o skratku *Extract-Transfer-Load* a je to softvér, ktorý dokáže získať dáta z rôznych zdrojov, transformovať ich do celku, ktorý dáva zmysel a poskytnúť ich v ucelenej forme používateľovi. Používateľom sa v tomto prípade okrem človeka rozumie aj iný dátový produkt alebo aplikačné programové rozhranie (API).

Príklad:

Chceme zmerať konverznú mieru v jednotlivých predajniach. Na to, aby sme vedeli vypočítať tento ukazovateľ potrebujeme: transakčné dáta z pokladní (ERP), zoznam prevádzok(ERP), dáta z počítačiel zákazníkov. Z dátovej matice vyplýva, že ide o interné štruktúrované dáta. Úlohou ETL bude:

- V rámci procesu extrakcie stiahnuť dáta z počítačiel a transakčné dáta. Väčšina ERP automaticky priraduje účtenky jednotlivým strediskám (predajniam), takže v jednej tabuľke už máme spárovanú účtenku ku konkrétnej predajni;
- V transformačnom procese musíme zosumarizovať počty účteniek pre každé stredisko – ideálne po hodinách a ku každej prevádzke doplniť počet návštev. Tieto musia byť sumarizované tiež v rovnakej časovej granularite.

V poslednom kroku sa takto pospájané dáta publikujú pre ďalšie aplikácie. Výsledná tabuľka môže následne slúžiť ako dátový zdroj pre *Business Intelligence* (analytické nástroje), prípadne môže byť spracovaná ďalej v Exceli.

Je zrejmé, že v rámci transformácie nedopočítavame samotnú konverznú mieru. Ide o vypočítaný ukazovateľ a výpočet nechávame na analytika. Dôvodom je, že v analytickej vrstve vieme okrem vzorca na výpočet konverznej miery (počet účteniek/počet návštev * 100) zohľadniť aj konštantu, ktorá ráta s chybou počítačiel, prípadne ošetriť stavy, kedy by nám mohla konverzná miera vzrásť nad 100 % (ak jeden zákazník vyrobí viac ako jeden pokladničný doklad), prípadne odstrániť z výpočtov storná a reklamácie.

Toto bol veľmi jednoduchý príklad. V praxi sa bežne v rámci transformačného procesu dáta spracovávajú pomocou zložitých skriptov a neurónových sietí. Výsledkom môžu byť podklady pre prediktívnu a preskriptívnu analytiku.

5. Ľudia

Veľmi dôležitú úlohu zohráva práve doménový expert, ktorý má okrem biznisových znalostí aj prehľad o technológiách a rozumie im aj po technickej stránke. Nie je nutné aby ovládal SQL a programovacie jazyky, je dôležité, aby rozumel ich princípu a logike. Jeho najsilnejší *skill-set* však musí byť z odboru, v ktorom firma podniká, prípadne z odboru riešenia konkrétnej problematiky.

Do toho však vstupuje ďalší rad skúseností, ktoré takémuto človeku umožňujú efektívnu komunikáciu s technickými ľuďmi, a čo je dôležitejšie, dokáže ich prácu aj skontrolovať.

Profily na strane zadávateľa:

- Pracovníci zodpovední za riadenie predajní;
- Pracovníci zodpovední za plánovanie;
- Experti so znalosťou retailovej analytiky a KPI s metodikami ich výpočtu;
- Experti na plánogramy a zonáciu predajní;
- Ďalšie profily s doménovou expertízou;
- Pracovník zodpovedný za priebeh projektu ako celku.

Profily s IKT zameraním, či už v internom tíme, alebo na strane dodávateľa, poprípade zamestnanci:

- Dátoví inžinieri spravujú dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;

- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- Experti na vizualizáciu a interpretáciu dát;
- IT architekti spravujú základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Vývojári aplikácií so znalosťou *machine learning* algoritmov (Python, R a iných), ktorí nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Programátori a ďalší IKT špecialisti zodpovedajú za implementáciu riešenia tak po stránke softvéru aj hardvéru;
- Konzultant so znalosťami základov dátovej etiky;
- Konzultanti so znalosťami GDPR;
- Integrační špecialisti so znalosťou REST alebo SOAP technológií komunikácie;
- Správca databáz.

6. Organizácia

Kľúčovým faktorom úspechu akejkoľvek iniciatívy v oblasti *data science* je správny tím. Rola *data scientist* je pomerne nová a vyžaduje kombinácie schopností, ktoré doteraz neboli bežné. Je takmer nemožné nájsť človeka, ktorý vie pokryť tieto schopnosti samostatne *end-to-end*. Preto je dôležité mať správnu tímovú dynamiku a správne zloženie tímu.

Záleží od možností firmy a jej veľkosti, ako jednotlivé roly obsadí. Dôležité je aj to, či vytvorí trvalý tím, alebo len pracovnú skupinu, ktorá bude mať za úlohu vyriešiť konkrétnu úlohu.

Ak firma nemá dostatok prostriedkov na nábor alebo nie je možné navyšovať počty zamestnancov z iných dôvodov, dá sa pristúpiť aj k outsourcingu. Trendom najmä väčších firiem je neoutsourcovať ľudí, ktorí sa venujú vývoju a podieľajú sa na tvorbe *know-how*. Takíto externisti sa ľahko dostávajú k algoritmom, ktoré často predstavujú konkurenčnú výhodu. Zmluvy o mlčanlivosti sa väčšinou vzťahujú na konkrétne dáta. Algoritmus, ktorého vývoj si firma zaplatí u kontraktora, sa môže veľmi ľahko stať jeho obchodovateľným produktom a spoločnosť tak riskuje stratu konkurenčnej výhody.

Prínosy

1. Kvalitatívne prínosy/kvantitatívne prínosy

AI môže v maloobchode posilniť prakticky všetky obchodné funkcie. Zatiaľ čo sa niektoré ľahko realizujú (dostupnosť dát, overené ML modely a ďalšie), iné poskytujú maloobchodníkovi väčšiu pridanú hodnotu, napríklad znížením úbytku zákazníkov. Podľa našich skúseností k najväčším prioritám pre väčšinu maloobchodníkov patria nasledujúce štyri príklady scenárov použitia AI.

Optimalizácia zásob na báze strojového učenia (ML)

Prognóza dopytu, plánovanie tovaru, dopĺňovanie skladov: Nedostatok tovaru na sklade predstavuje najväčšiu príčinu straty predaja a nespokojnosť zákazníkov. Súčasný globálny celosvetový priemer nedostatočných zásob je 8 %; vzhľadom na to, že aspoň tretina zákazníkov nakúpi tovar u konkurenta, čoho následkom je nielen strata predaja, ale aj potenciálna strata pri ďalšom predaji a budúcich príležitostiach predaja.

Výhody pre maloobchodného zákazníka: súhrn týchto nedokončených nákupov sa premietne do straty predaja cca 4 % pre typického maloobchodníka. Pre porovnanie: americké maloobchodné predaje vzrástli o 3,5 % v roku 2017.

Druhým veľkým problémom sú nadmerné zásoby, vopred nakúpené položky, ktoré zvyšujú nároky na investície, čo v konečnom dôsledku vedie k donúteným zľavám, ktoré sa nakoniec dotýkajú prevádzkových marží maloobchodníkov. Dômyselný ML algoritmus pre prognózovanie dopytu bude brať do úvahy interné a externé dáta pre vytvorenie presnejších prognóz, ktoré sa časom neustále zlepšujú.

Optimalizácia cien na báze ML

Ďalším prípadom s dôležitým prínosom je využitie AI pre maloobchodné ceny. Maloobchodní predajcovia často nastavujú obchodné prirážky pri stanovovaní cien produktov ručne pomocou metódy *cost+* alebo *Keystone*. Metodiky naceňovania na základe ponuky nie sú účinné tak ako varianty založené na dopyte, čo znamená, že tovar by mal byť nacený podľa toho, čo je zákazník ochotný zaplatiť vs. odporúčaná koncová cena alebo jednotková nákupná cena pre maloobchodníka. Algoritmy ML pre optimalizáciu cien budú analyzovať pružnosť ceny tovaru bez vplyvu na objem predaja.

Prínos pro maloobchodného zákazníka: priemerný obchod s potravinami v USA ponúka výber 50 – 60 000 typov tovaru. Zvýšením ceny spodného kvartilu sortimentu obchodov s potravinami v priemere 0,10 USD za tovar by sa zvýšilo celkovou prevádzkovou maržou o 1,3 %. Pre porovnanie, americké predajne potravín mali priemernú prevádzkovú maržu 1,9 %.

Zákaznícka osobná skúsenosť s ML

Ďalším efektívnym využitím AI v maloobchode je vytváranie individuálnych marketingových kampaní. Historicky väčšina maloobchodných predajcov využíva každý rok rovnaké sezónne zľavy, čo má za následok identický marketing a ceny pre každého zákazníka. Tento typ jednotného prístupu už nebude naďalej žiadaný. ML môže pomôcť určiť optimálnu komunikáciu a ceny pre špecifické skupiny zákazníkov s možnosťou cielenia až na jednotlivca. Tým sa zvýši miera reakcií, ale môže taktiež optimalizovať marže, pretože niektorí zákazníci potrebujú menšie zľavy ako ostatní, aby sme u nich vzbudili motiváciu k nákupu. Individuálna propagácia prostredníctvom CRM s využitím AI zvýši obchodu návratnosť marketingových investícií jednotlivých kampaní.

Prínos pre maloobchodného zákazníka: priemerný výnos z investícií z každého 1 USD je generovaná marža vo výške 1,09 USD. Takže pre každý 1 cent v ROI to znamená 1 % nárastu tržieb.

AI podporená nákupná cesta zákazníka

Komunikačné platformy priamo spájajú fyzické obchody s digitálnym svetom zákazníka a vytvárajú tak prepojenú skúsenosť naprieč rôznymi systémami (*Omni-Channel-Experience*). To pomáha zvyšovať predaj pomocou kombinácie osobnej skúsenosti v kamennej predajni s AI asistenciou a online nákupom s cieľom zvýšiť predaj a minimalizovať odklon od online nákupného košíka.

Prínos pre maloobchodného zákazníka: odlišuje sa v závislosti od typu obchodu a regiónu, ale konverzný pomer nákupu vo fyzickej predajni sa pohyboval okolo 20 % v roku 2013. Denný počet zákazníkov IKEA je 6 200, každý z nich strojí priemerne 200 USD. Každé zvýšenie konverzného pomeru o 0.1 % sa rovná 4,5 miliónom USD.

2. Riziká

Mnoho spoločností si pri týchto technológiách neuvedomuje tú najpodstatnejšiu vec. Použitie akýchkoľvek nástrojov pokročilej analytiky alebo umelej inteligencie je vo veľkej miere závislé od

kvality dát, ktoré sú použité a platí jednoduché *Trash In = Trash Out* (neporiadok dnu = neporiadok von, pozn. preklad.). Uponáhľané a nepremyslené implementácie mnohokrát končia sklamaním a nulovým alebo negatívnym prínosom pre spoločnosť.

4.6.7 Online predaj

Oblasť portfólia

Automatizácia je termín, s ktorým sa v posledných rokoch stretávame dennodenne v médiách. Väčšinou sa to týka automatizácie priemyslu alebo tiež priemyslu 4.0. O čom však vieme oveľa menej je automatizácia činností, ktoré nezahŕňajú manuálnu ľudskú prácu.

Jednou z takýchto oblastí je automatizácia v oblasti marketingu. Neznačená to, že by v najbližšej dobe počítače nahradili prácu kreatívcov v agentúrach, vymýšľali by za nás obsah na sociálnych sieťach, či dokonca navrhli kompletnú marketingovú stratégiu, ktorá by dokázala lepšie osloviť zákazníkov. Takáto budúcnosť nás v najbližšej dobe nečaká. Automatizácia v oblasti marketingu však predstavuje príležitosť, ako lepšie osloviť zákazníkov a zároveň nepridávať marketérom viac práce.

Marketingová automatizácia nie je totižto len marketingovou disciplínou. Je to skôr mix oblastí marketingu a IT. Na vstupe je komunikácia smerom k zákazníkovi, a to komunikácia personalizovaná, prispôbena na mieru každému užívateľovi, a na druhej strane je to komunikácia podporená na pozadí softvérom, ktorý zabezpečuje, aby sa správna komunikácia dostala správnym spôsobom k tomu správne zákazníkovi.

Popis

Analyzujeme procesy, ktoré sú bežné v oblasti marketingu. Na jednej strane ide o bežné prístupy strojového učenia založené na štatistike a metódach ako sú Lineárny regresný model, Logistické regresné modely, Zhľukovanie (*Clustering*), Zmiešané Gaussove modely, Markovove reťazce a podobne.

Predpoklady

1. Proces

Vyššie uvedené softvéry slúžia ako možné riešenie, pokiaľ chce firma účinne prevádzkovať marketingové oddelenie, a to najmä:

- Využiť 360-stupňové profilovanie zákazníkov;
- Využiť nové možnosti segmentácie zákazníckeho portfólia: založených na prediktívnych informáciách o zákazníkoch a na ich správaní v reálnom čase;
- Pripravovať dizajn a návrh segmentu;
- Využívať multidimenzionálne kritériá;
- Tvoriť segment založený na tom, čo si zákazníci myslia o potrebách organizácie;
- Organizovať zákazníkov na základe hodnôt získaných od samotných zákazníkov a využiť potenciál, ktorý táto organizácia poskytuje (prepája potreby zákazníka a produkt);
- Vývoj jasných hodnotových propozícií;
- Pripravovať zacielenie založené na dlhodobých hodnotách zákazníka;
- Nastavovať zobrazenie propagovaného produktu s cieľom odlíšiť sa od konkurencie a na základe reálnych potrieb zákazníka;

- Mať možnosti pohľadu na správanie zákazníka;
- Založené na kontexte v reálnom čase (riziká, trh, príležitosti, odporúčania *next best offer* na základe informácií v reálnom čase);
- Pripravovať logiku pre všetky komunikačné kanály;
- Využívať komunikačné kanály založené na informáciách v reálnom čase a v kombinácii všetkých kanálov;
- Mať konzistenciu informácií naprieč všetkými kanálmi a komplexnú logiku jednotne pripravenú pre všetky kanály;
- Mať možnosť priebežného merania úspešnosti marketingových kampaní: merať a sledovať výkon marketingových kampaní naprieč všetkými relevantnými kanálmi.

2. Dáta

Firma musí disponovať údajmi o svojich produktoch alebo službách, mať určitý počet zástupcov marketingového oddelenia, mať obchodný cieľ a disponovať nejakým množstvom údajov o svojich zákazníkoch.

V prípade vyššie opísaného riešenia by do systému mali vstupovať všetky dáta, s ktorými pracuje zamestnanec marketingového oddelenia. Vďaka zabudovaným šablónam systém prevedie užívateľa veľmi rýchlo štruktúrou vstupných údajov, ktoré potrebuje pre optimálne fungujúci algoritmus umelej inteligencie.

Taktiež v tzv. karte zákazníka vieme nájsť datasety, ktoré sú podmienkou pre nasadenie umelej inteligencie podľa ich kategórií:

- Transakčná história zákazníkov;
- Dáta o správaní na sociálnych sieťach;
- Dáta o už aplikovaných marketingových kampaniach;
- Dáta o zákazníckych emóciách a pocitoch;
- Dáta týkajúce sa marketingových plánov a rozdelenia zdrojov;
- Geografická mapa;
- Korešpondenčná história.

3. Aplikácie

Je potrebná integrácia so zdrojmi dát, presne tak ako s marketingovými kanálmi a cieľovými systémami.

Konkrétne je pravdepodobná potreba integrovať sa na existujúcu databázu, ktorú už zákazník používa. Ďalej môže byť potrebné napojiť sa na systém pre riadenie vzťahov so zákazníkmi, ako napríklad CRM. Aplikácie, ktorú sú dôležité pre *end-to-end* proces potom môžeme rozdeliť do nasledujúcich kategórií:

- Zdrojové aplikácie pre informácie o zákazníckom správaní (ERP, CRM a ďalšie);
- Aplikácie pre meranie zákazníckeho myslenia (Facebook, Instagram, Twitter a ďalšie);
- Aplikácie pre správu zákazníckych povolení a súhlasov (*consent management* systém a ďalšie);
- Integrovaný broker (napr. typu *SAP Cloud Platform*);
- Cieľové aplikácie pre transfer obchodných typov (typu CRM);
- E-mail a SMS brány (*Amazon, Alibaba, SAP Digital Interconnect* a ďalšie).

Je potrebné taktiež zdôrazniť, že riešenia obsahujú *Application Programming Interfaces*, čo z tohto riešenia vytvára otvorenú platformu pre integráciu ďalších riešení, ktoré môžu obohatiť celkovú biznisovú výhodu.

Automatizácia marketingových procesov sa väčšinou nebuduje na „zelenej lúke“, často dochádza k integrácii s existujúcimi aplikáciami. Voľba potom závisí od konkrétneho projektu, či je vhodnejší spôsob integrácie na existujúcej aplikácii, alebo poprípade náhrada niektorej aplikácie. V niektorých prípadoch môže byť nahradenie existujúcej aplikácie oveľa jednoduchšie ako samotná integrácia.

4. Infraštruktúra

Pre úspešné zavedenie spomínaného riešenia je nutné mať prístup na internet, mať možnosť alebo mať počítač s napojením na SMS a e-mail bránu, mať vytvorené účty na sociálnych sieťach typu Facebook, mať vytvorené účty na reklamných portáloch typu *Google Adwords* a podobne.

Kvalitné nasadenie riešení s umelou inteligenciou si preto vyžaduje sprístupnenie dát v databázach firiem (získaných z rôznych zdrojov). Pre dodatočný zber dát môže byť potrebná inštalácia *add-ons*, napríklad pre napojenie na *on-premise* zdroje dát. Pre potreby prezentácie výsledkov, napríklad výkonnosti kampaní, je potrebné sa napojiť cez integračný broker na firemné BI riešenie.

5. Ľudia

Pre potreby kvalitného nasadenia systémov je dôležitý projektový manažér, programátor so skúsenosťami v JavaScript, funkčný konzultant systému *SAP Sales Cloud* a odborník na integráciu typu API.

Pre celkový úspech projektu je dobrou praxou zriadiť pracovné tímy – tak na strane zákazníka, ako aj na strane dodávateľa riešenia – ktorí medzi sebou spolupracujú. Tím zákazníka sa môže skladať aspoň z jedného projektového manažéra a niekoľkých kľúčových používateľov, ktorí by preberali dielčie výsledky, konzultovali implementáciu projektu a dostávali potrebné školenia od tímu implementátora.

Dôležitú rolu taktiež zohrávajú pravidelné stretnutia (aj osobné), dobre nastavené míľniky a prezentácie cieľov projektu, jasná komunikačná matica, ale najmä dostatočná alokácia odborného tímu, proaktívne tvarovanie požiadaviek a rýchle reagovanie na podnety od implementačného tímu. Toto všetko sú dôležité faktory, ktoré ovplyvňujú technický úspech, ale aj budúcu využiteľnosť riešenia.

6. Organizácia

V prípade štandardného spôsobu nasadenia systému pomocou expertného tímu bude zo strany objednávateľa potrebné zorganizovať dočasný tím, ktorý sa skladá z kľúčových používateľov a projektového manažéra.

Pre úspech projektu je prínosná častá interakcia odborného tímu a implementačného tímu. Súčasťou projektu by mala byť detailná procesná analýza oblastí, ktoré sa budú riešiť.

Pri automatizácii procesov je potrebné myslieť na možnosť dramatických zmien a prípadného radikálneho prerobenia určitých procesov, či úplné zrušenie niektorých súvisiacich procesov.

Prínosy

1. Kvalitatívne prínosy

Popísané riešenie pomáha marketérovi optimalizovať všetky články procesu, ktorý zachytí záujmy od možného prospektu až po odovzdanie kvalitne spracovaných typov v ďalšom obchodnom cykle,

napríklad pre riadenie vzťahov so zákazníkom. *Marketing Cloud* dokáže spájať a kombinovať akékoľvek zákaznícke dáta a zároveň umožňuje personalizovaným spôsobom osloviť každého zákazníka individuálne.

V *SAP Marketing Cloud* môžete vytvoriť komplexnú segmentáciu z miliónov datasetov za niekoľko sekúnd, môžete osloviť každého zákazníka cielene a prostredníctvom preferovaného kanála, ako napríklad e-mail, SMS, push notifikácia, chatbot, landing page, mobilné aplikácie, sociálne médiá, atď.

Marketing Cloud naplno využíva AI s reálnym využitím ako *best sending time*, *product recommendation*, *customer retention*, *product buying propensity*, *next best offer* a mnohé ďalšie. Riešenie taktiež ponúka silné analytické nástroje a komplexný marketingový kalendár a plánovač pre efektívne riadenie online a offline kampaní.

2. Kvantitatívne prínosy

SAP Marketing Cloud prináša reálne zvyšovanie konverzií na strane zákazníka a podstatné zníženie nákladov na prevádzku marketingového oddelenia vďaka čomu maximalizuje efektivitu vynaložených prostriedkov³⁰.

Do oblastí kvantitatívnych prínosov patria najmä:

Získavanie nových zákazníkov:

- zvýšená návštevnosť stránok o 25 %;
- zvýšená akvizícia nových zákazníkov o 23 %.

Zvyšovanie predaja, cross/up/sell:

- zníženie času potrebného na vstup na trh – *Time to market* o 40 %;
- 10-násobné zvýšenie konverzného obchodu;
- zvýšenie priemernej hodnoty objednávky o 5 %.

Spokojnosť a lojalita:

- zvýšenie spokojnosti zákazníkov o 4 %;
- zvýšenie opakovaného nákupu o 4 %.

Efektivita vynaložených prostriedkov:

- zníženie nákladov za aktiváciu zákazníka o 24 %;
- zvýšenie čistého obchodu o 30 %.

Riziká

Základným predpokladom presných a použiteľných výstupov umelej inteligencie je množstvo použitých dát. Čím väčšia vzorka dát, tým presnejšie a užitočnejšie sú výstupy. Pri využití nekvalitných dát alebo ich nedostatočnom množstve projekt nasadenia umelej inteligencie nebude úspešný.

Ak budú dáta naplnené nedostatočne, existuje riziko neskoršej návratnosti. Princípom fungovania strojového učenia je proces učenia systému na nejakej vzorke dát. Čím menšia a nekvalitnejšia je vzorka dát, tým pomalšie sa systém učí.

Riziká z možných externalít

³⁰ The Total Economic Impact™ of SAP Marketing, a June 2017 commissioned study conducted by Forrester Consulting on behalf of SAP. [Dostupné online.](#)

Politické a environmentálne krízy môžu byť závažným rizikom pre úspešné nasadenie a využitie umelej inteligencie. Avšak moderní dodávatelia riešení s využitím umelej inteligencie, akým je napr. SAP, riešia podobné riziká zálohovaním dát na niekoľkých dátových centrách, algoritmy *disaster-recovery* a mechanizmy kybernetickej bezpečnosti a podobne.³¹

4.6.8 Podpora zákazníkov a používateľov

Popis

Virtuálny Digitálny Asistent, tzv. **Chatbot** je expertný systém, ktorý pomocou metód umelej inteligencie napodobňuje komunikáciu človeka. Pojmom expertný systém je myslené to, že znalosti chatbota (z angl. *skills*) sú vytvorené manuálne. Chatbot môže byť doplnený o znalostné vyhľadávanie v poskytnutých dokumentoch alebo poskytovanie informácií z databáz, informačných systémov, vyvolávať akcie či skripty, alebo prepojiť používateľa na agenta call centra.

Primárne je vstupom chatbota text v chatovacom (dialógovom) okne. Odpoveďami chatbota môžu byť text, tlačidlo alebo audiovizuálny obsah. Chatbota je možné doplniť o systém automatického rozpoznania reči a systém prevodu textu na reč.

Vo všeobecnosti sa chatbot skladá z viacerých blokov. **Možnosti a limitácie chatbotov môžu byť v skratke popísané nasledovne:**

1. Komunikačný kanál:

Komunikačným kanálom môže byť webové rozhranie alebo časť webovej stránky (*iframe*). *Chatbotové frameworky* často poskytujú možnosti jednoduchého prepojenia s populárnymi aplikáciami alebo sociálnymi sieťami ako napr. Facebook, Slack, atď. Do tohto bloku je možné pridať aj autentifikáciu.

2. Systém automatického rozpoznania reči (z angl. *Automatic Speech Recognition*, skr. **ASR**) (voliteľný doplnok):

Cieľom tohto systému je prevod vyslovenej reči používateľom na text. Systémy ASR fungujú v súčasnosti so slovnou chybovosťou <5 %. Chybovosť je závislá od kvality zvukovej nahrávky, typu mikrofónu, vzdialenosti rečníka od mikrofónu, hluku v pozadí ale aj od artikulácie, tempa reči alebo nárečia a celkovo od kvality rečového prejavu. Štandardne systémy ASR vedia rozpoznať iba slová v slovníku, ktorý býva z viacerých dôvodov rozumne limitovaný. V prípade vyslovenia mimoslovníkového slova je vybraté najpravdepodobnejšie slovníkové slovo alebo slová. Navrhnuť si vlastný systém ASR je veľmi zložitá a okrem expertov na danú oblasť vyžaduje aj množstvo tréningových dát, ktoré sú veľmi drahé. V praxi sa na automatické rozpoznávanie reči používajú cloudové služby alebo *on-premise* softvéry (na vlastných serveroch).

V prípade, že slovná chybovosť nie je dostačujúca, je možné požiadať dodávateľa o použitie špecifického (doménového) jazykového modelu. Ten napomáha pri rozpoznávaní reči tak, že slová a slovné spojenia často vyskytujúce sa v doméne majú vyššiu

³¹ Viac informácií na <https://www.scrtechnologies.sk/ai-marketing>

pravdepodobnosť pri rozpoznávaní reči, a preto môžu znížiť slovnú chybovosť. To platí hlavne pre špecifické domény ako napr. zdravotníctvo, právo, hovorová reč, atď.

3. Porozumenie prirodzeného jazyka (z angl. *Natural Language Understanding*, skr. NLU):

Cieľom tohto bloku je pochopenie textu zadaného používateľom, čo je nazývané ako zámer (z angl. *intent*). Výsledkom tohto bloku je rozpoznanie jedného z konečnej množiny zámerov v datasete. V prípade, že klasifikačný algoritmus neprekročí stanovený prah dôveryhodnosti, je možné vypísať záložnú odpoveď. Napr. „Nerozumiem vám, prosím, skúste vetu preformulovať“.

Každý text zadaný používateľom je spracovávaný týmto blokom. Jadrom tohto bloku je model strojového učenia pre textovú klasifikáciu. Trénovanie tohto modelu zabezpečuje *chatbot framework* automaticky a pre jednoduchšie aplikácie nie sú potrebné špeciálne vedomosti.

4. Rozpoznávanie pomenovaných entít (z angl. *Named Entity Recognition*, skr. NER) (voliteľný doplnok, v praxi používaný takmer vždy):

Tento blok zabezpečuje rozpoznanie entít v texte zadanom používateľom. Entity môžu byť akékoľvek textové dáta – meno, priezvisko alebo číslo objednávky. Na rozpoznanie jednoduchých entít ako meno, priezvisko, adresa jestvuje viacero nástrojov. Na rozpoznávanie vlastných entít je potrebné vytvoriť vlastný dataset (označením entity v texte) a natrénovať z neho model. Natrénovanie takého modelu sa štandardne robí automaticky v *chatbot frameworkoch* a pre jednoduchšie aplikácie nie sú potrebné špeciálne vedomosti.

• Dialógový manažér (z angl. *Dialog Manager*, skr. DM):

Tento blok zabezpečuje riadenie dialógu. DM sleduje aké záмеры boli rozpoznané v NLU, aké entity boli rozpoznané a následne predpovedá nasledujúcu akciu. Štandardné akcie môžu byť:

- Odpoveď (text, audiovizuálny obsah, informácia z externého systému, výsledok skriptu alebo vyhľadaná informácia v znalostiach – dokumentoch);
- Vyžiadanie si viac informácií – entít;
- Čakanie na ďalšiu správu od používateľa;
- Ukončenie konverzácie.

Jadrom tohto bloku je model strojového učenia. Z praxe však vyplynulo, že čím kvalitnejšie sú tréningové dáta pre DM, tým lepšie funguje. Inak povedané – čím viac možností konverzácie je zapísaných v tréningových dátach, tým lepšie funguje riadenie dialógu.

5. Systém prevodu textu na reč (z angl. *Text to Speech*, skr. TTS) (voliteľný doplnok):

Systém prevodu textu na reč (známy aj ako syntéza reči) prevádza textové odpovede na reč. V súčasnosti dosahuje veľmi dobré výsledky a reč znie skoro prirodzene. Vytvorenie vlastného systému TTS nie je jednoduché a vyžaduje spracovanie expertami na danú oblasť a kvalitné rečové dáta s presnými časovo zarovnanými prepismi. Pre tento blok je vhodné radšej využiť cloudové služby alebo *on-premise* riešenia.

Predpoklady

1. Proces

Chatboty sa štandardne používajú v oblastiach:

- **Call centrá** – časť zákazníkov kontaktujúcich call centrum (volaním alebo písaním) môže byť obslužená chatbotom. Jednoduchšie úlohy zvládajú chatboty veľmi dobre, ako napríklad zobrazenie výšky faktúry. V prípade, že chatbot nevie naplniť požiadavky používateľa, je možného používateľa automaticky prepojiť na operátora.
- **Poskytovanie informácií používateľom** – systém môže používateľom poskytovať informácie, odpovedať na frekventované otázky alebo vyhľadať poruchu u používateľa a postupne smerovať k vyriešeniu, prípadne pomôcť s hlbšou diagnostikou problému alebo vyhľadávať v dokumentoch.
- **Samoobslužné systémy** – pomocou samoobslužných chatbotov si môže používateľ objednať alebo upraviť nejakú službu, prípadne zmeniť nastavenie systému. V tomto prípade je nutná aj autentifikácia.
- **Reklamné kampane** – chatbot na reklamné kampane môže napríklad informovať používateľa o akciách, pričom táto konverzácia je vyvolaná chatbotom, nie používateľom. Z etického hľadiska je v tomto prípade vhodné dať používateľovi možnosť sa jednoducho odhlásiť z tejto komunikácie. Komunikácia môže byť uskutočnená textom alebo telefonickým rozhovorom (v slovenčine sa zatiaľ veľmi nepoužíva).

Z praxe vyplynulo, že používatelia dobre prijímajú komunikáciu s chatbotom. V niektorých prípadoch používatelia priam preferujú komunikáciu s chatbotom pred živým operátorom. Chatbot tak môže značne zredukovať počet rozhovorov s operátorom a znížiť tak náklady na pracovnú silu.

2. Dáta

Tréningové dáta pre porozumenie prirodzeného jazyka (NLU) je potrebné vytvoriť manuálne. V prípade jednotlivých zámerov je potrebné napísať niekoľko možností, akými by ich mohol napísať používateľ. Čím viac možností sa uvedie, tým bude komunikácia s chatbotom prirodzenejšia. Nie je však nutné uvádzať všetky možnosti. Napríklad pre zámer „výška faktúry“ môže stačiť 10 rôznych príkladov. NLU je vlastne textový klasifikátor na báze strojového učenia. S vhodným modelom vektorovej sémantickej reprezentácie slov môže fungovať rozpoznanie zámeru aj pre také texty, ktoré nie sú uvedené medzi príkladmi.

K bloku rozpoznávania entít (NER) je možné pristúpiť dvomi spôsobmi. Prvým je použitie voľne dostupných NER modelov, ktoré však rozpoznávajú len obmedzené množstvo rôznych entít. Druhá možnosť je označiť jednotlivé entity v tréningových dátach, konkrétne v dátach pre tréning NLU. Príklad: „*Chcel by som zistiť vlakové spojenie z Košíc do Bratislavy*“ môžeme označiť „*vlakové*“ ako typ dopravy, „*Košíc*“ ako štartovacie mesto a „*Bratislavy*“ ako destináciu. Pre jednotlivé entity môže byť vytvorená vyhľadávacia tabuľka, v ktorej môže byť zoznam všetkých slovenských obcí a miest.

Najkomplikovanejšie a najzdĺhavejšie je vytváranie dát pre DM. V týchto dátach je potrebné symbolicky zapísať všetky (alebo väčšinu) možností vývoja dialógu. Symbolicky znamená, že sa zapisujú iba názvy zámerov a názvy odpovedí. Chatbotovi je možné definovať viacero možností odpovede, aby komunikácia bola prirodzenejšia a menej strojová. Chatbot náhodne vyberá odpoveď z množiny odpovedí. Napr. odpoveď pre rozlúčenie môže byť: „*Dovidenia*“, „*Pekný deň*“, atď. Tieto odpovede je potrebné taktiež manuálne zdefinovať.

V tréningových dátach je možné zadať rôzne dialógové sledy v prípade, že bola detegovaná špecifická entita. Takisto je možné v dialógu zadať, ktoré entity sú povinné a chatbot sa na ne môže postupne opýtať – napr. „Zadajte číslo OP“, „Zadajte RČ“.

Jadrom DM je model strojového učenia, ktorý je trénovaný z hore uvedených dát. Model sa snaží v maximálnej miere kopírovať symbolicky popísané dialógové sledy. V prípade, že neexistuje konkrétny sled v tréningových dátach, model sa snaží nájsť najvhodnejšiu alternatívu, poprípade vypísať chybovú hlášku alebo prepojiť používateľa na operátora.

3. Aplikácie

Chatbot riešenia je možné vytvoriť pomocou cloudovej služby alebo na vlastných zariadeniach. Cloudové služby sú štandardne platené podľa počtu relácií, v prípade ASR/TTS počtu sekúnd nahrávky. Existuje aj množstvo frameworkov (aj *open source*) na vytvorenie chatbot riešení na vlastnom hardvéri. V dnešnej dobe sú cloudové služby, ale aj frameworky vytvorené tak, aby boli čo najjednoduchšie a prípadne, aby nebolo potrebné spracovanie expertom (*data scientist*).

4. Infraštruktúra

Systémy na vlastnom hardvéri sa delia na *frontend* a *backend*. Frontend je komunikačným rozhraním a backend štandardne vykonáva NLU, NER a DM. Rečové rozhrania ASR a TTS sa väčšinou implementujú do frontendu. Výpočtové zaťaženie backendu závisí od metód strojového učenia použitých v NLU a NER.

Čím komplexnejší model, tým je potrebný aj väčší počet výpočtov. Väčšinou sa používajú jednoduchšie modely, ktoré pracujú rýchlejšie, a teda jednotlivý server zvládne viac relácií. V prípade používania *on-premise* ASR/TTS riešenia je výpočtové zaťaženie veľmi veľké. Na spracovanie sú potrebné stroje s hardvérovými akcelerátormi, ako sú GPU, FPGA, NNP.

5. Ľudia

Na nasadenie riešenia je potrebný frontend developer. Pre backend na vlastných serveroch je potrebný skúsený IT developer, ktorý si naštuduje konkrétny framework. Pre produkčné riešenie je potrebné myslieť na automatické testovanie a monitoring.

Na úspešné nasadenie a udržiavanie chatbota je potrebný manažér obsahu, ktorý bude vytvárať tréningové dáta pre NLU, NER a DM. Počet manažérov obsahu závisí od komplexnosti riešenia a dostupných schopností chatbota.

Pre uchovanie konverzačných dát je potrebné myslieť aj na anonymizáciu dát tak, aby spĺňali nariadenia GDPR. Preto je potrebná manuálna alebo automatická anonymizácia textov.

Profily na strane zadávateľa:

- Vedúci podpory zákazníkov spolupracujú s dátovými vedcami na určení problémov a cieľov;
- Informatici zodpovedajú za prevádzku výpočtovej techniky a sieťovej infraštruktúry;
- Pracovníci zodpovedajú za obsluhu zákazníka, za predaj, za kvalitu a včasnosť servisu v existujúcom *help-desk* pracovisku, *call centre*, atď.

Profily s IKT zameraním či už v internom tíme alebo na strane dodávateľa, poprípade pracovníci:

- Dátoví inžinieri spravujú dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;
- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- Experti na technológiu konkrétneho chatbota;
- IT architekti spravujú základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Vývojári aplikácií so znalosťou *machine learning* algoritmov (Python, R a iných.), ktorí nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Programátori a ďalší IKT špecialisti zodpovedajú za implementáciu riešenia tak po stránke softvéru aj hardvéru;
- Konzultant so znalosťami GDPR.

6. Organizácia

Chatbot riešenie je možné po softvérovej stránke prideliť iným dodávateľom (cloudové riešenia, externí dodávatelia). Obsah chatbota je potrebné vytvoriť. Firma ako vlastník znalostí a procesov je najkompetentnejšia na tvorbu obsahu chatbota. Tvorba dát nie je zložitá, ale môže byť zdĺhavá. Externalizácia tvorby trénovacích dát chatbota je možná, je však na zvážení či náklady na tvorbu a prípadné zmeny nepresiahnu náklady na vlastných zamestnancov.

Prínosy a riziká

1. Kvalitatívne prínosy

- Zvýšenie kapacity obslužených zákazníkov;
- Možné zvýšenie kvality, vďaka odstráneniu ľudského faktora;
- Rýchlejšie obsluženie zákazníka;
- Dostupnosť 24/7.

2. Kvantitatívne prínosy

- Úspory;
- Náklady na zamestnancov sú oveľa vyššie ako na chatbot riešenie. Úspory sú hlavne na menšom počte zamestnancov call centier;
- Vyššie výnosy;
- Relatívne skorý ROI. V prípade vlastného riešenia pomocou napr. *open-source* frameworkov je ROI trochu dlhší. V prípade cloudových riešení sa platí za každú reláciu, čiže náklady sú platené postupne (samozrejme je potrebné vytvoriť znalosti chatbota v oboch prípadoch);
- V prípade používania *on-premise* ASR/TTS riešenia je ROI neskorší. Najväčšie náklady sú na zakúpenie alebo vývoj vlastného ASR/TTS riešenia, zakúpenie vlastných serverov s hardvérovými akcelarátorami a aj operačné náklady na správu týchto serverov.

3. Riziká

- Najväčším rizikom je zlé vytvorenie datasetu hlavne pre DM. V takom prípade môže byť komunikácia s chatbotom chaotická a akceptácia používateľmi nízka, až žiadna;
- V prípade nízkej akceptácie používateľmi je pravdepodobné neskoršie ROI, ak vôbec nastane;

- V prípade použitia cloudových riešení je potrebné rátať s malou mierou nedostupnosti služby. Tá je však pri cloudových riešeniach extrémne nízka. V prípade použitia cloudových riešení je nutné anonymizovať dáta pred vstupom do cloudu a následne po výstupe z cloudu ich naspäť rekonštruovať tak, aby boli naplnené požiadavky GDPR, poprípade interných smerníc na dodržiavanie ochrany osobných údajov.

5 Zodpovedný prístup k umelej inteligencii

5.1 Etická stránka umelej inteligencie

Špecifickým znakom v oblasti umelej inteligencie je jej etická stránka. Pod etickým rámcom sa skrývajú morálne zásady, právne normy a všeobecné nariadenie o ochrane osobných údajov. Pri samotnom definovaní prevádzkových požiadaviek je dôležité zohľadniť interakcie medzi človekom a systémom s umelou inteligenciou.

Európska komisia má v pláne preskúmať, ako vyššie spomenuté aspekty uplatniť v samotnej tvorbe legislatívnych návrhov. Zameranie na etickú umelú inteligenciu preberajú do svojich národných stratégií postupne aj jednotlivé členské krajiny EÚ.

5.2 Etické a právne riziká

Schopnosť AI dopĺňať, ovplyvňovať či nahrádzať ľudské chápanie a rozhodovanie prináša množstvo nových spoločenských otázok. Medzi nové výzvy, ktoré umelá inteligencia priniesla, patria aj riziká neúmyselnej diskriminácie v dôsledku neférových rozhodnutí a napríklad aj informovanosť zákazníkov o tom, že sa AI podieľa na dôležitých či citlivých rozhodnutiach o nich samotných.

Keď používame AI na rozhodnutia, ktoré majú dopady na ľudí, ako zabezpečíme, aby bol tento proces férový, vysvetliteľný a transparentný? Ako rozpoznať, kedy má AI pri rozhodovaní nežiaduce predsudky? Kedy jej môžeme zveriť proces bez toho, aby sme ju kontrolovali a kedy je dôležité ponechať aj dozor človeka? Ako vieme využiť výhody AI a zároveň si nenarušiť súkromie?

Ak chceme predísť chybám, je nevyhnutné, aby sme tieto otázky vedeli zodpovedať. Inak ľudia nebudú AI systémom plne dôverovať. A ak si dôveru v umelú inteligenciu naštobia, nebudú ochotní ju toľko používať či rozvíjať.

Jedným zo zásadných etických problémov s AI je slabá transparentnosť a vysvetliteľnosť jej rozhodnutí. Ak umelá inteligencia pochybí, často o tom buď vôbec nevieme alebo nedokážeme pochopiť dôvod zlyhania. Jedným zo spôsobov riešení je vybrať taký algoritmus, ktorý sa vyznačuje práve transparentnosťou. O nasadení AI by mali organizácie tiež otvorene komunikovať.

AI algoritmy by mali každého posudzovať férovo a takým vyváženým spôsobom, aby podobné skupiny ľudí neovplyvňovali odlišne. Preto je pri tvorbe AI algoritmov dôležité vybrať také dáta, ktoré dostatočne reprezentujú svet, v ktorom žijeme, alebo aspoň tú jeho časť, v ktorej bude AI algoritmus pôsobiť a tiež zabezpečiť, aby tieto dáta neobsahovali predsudky.

Ďalšia skupina etických problémov sa viaže k rizikám autonómnosti AI. Musíme si stanoviť, v ktorých oblastiach a prípadoch AI dovoľíme rozhodovať samostatne a kedy bude musieť byť pod dohľadom ľudí. Príkladom riešenia je pridať overenie človekom všade tam, kde existuje istá pravdepodobnosť pochybenia AI a zároveň je tam vysoké riziko skutočného ublíženia.

Existuje niekoľko praktických príručiek na systematické posúdenie rizík spojených s nasadzovaním algoritmov AI. Jedna z nich bola vytvorená výskumníkmi z USA, nachádza sa na stránke ethicstoolkit.ai a do nášho jazyka ju preložila a verejnosti sprístupnila slovenská firma exe, dostupná je na stránke [e-](#)

tika.sk. Na tejto stránke sa nachádza aj ďalší [zdrojový dokument Zodpovedný prístup k AI³²](#) spolku E–tika, ktorý detailnejšie prináša tému etických rizík a zodpovedného AI. Tento dokument poslúži ako základ pre plánovanú praktickú príručku etického vývoja a nasadzovania AI vo firmách a štátnych inštitúciách.

5.3 Implementačné a prevádzkové riziká

Problémy súvisiace s učením sa umelej inteligencie

Výsledky sú nespoľahlivé v prvých týždňoch po nasadení systému, kým nie je umelá inteligencia dostatočne natrénovaná, rovnako zníženú spoľahlivosť riešenia vyvolá neočakávaná zmena výrobných podmienok (optických podmienok, typu defektov, vzhľadu výrobkov, atď.).

V prípade neodborných manuálnych zásahov do systému (spravidla neúmyselných) či manipuláciou s tréningovými vzorkami a anotáciami a neodborným rozhodovaním hrozí degradovanie softvérového systému.

Proces môže v realite obchádzať informačný systém. V praxi sa často stretávame s tým, že proces funguje istým spôsobom na papieri, ale v realite funguje cez tzv. *backchannels* a dôležité informácie sú predávané ústne či e-mailmi. Žiaľ, ak má systém fungovať korektne, musí mať úplné informácie. Napr. tickety typu „*Ten problém zo včera*“, alebo záznam po poruche s textom „*porucha*“ nie je možné korektne spracovať.

Odpor ku zmenám a obavy zo straty zamestnania

Akákoľvek zmena bude prirodzene sprevádzaná odporom. Pracovníci majú v týchto prípadoch často pocit ohrozenia. Je dôležité so zamestnancami pracovať. Vo väčšine prípadov po zavedení takéhoto systému pracovníci nájdu vo firme iné uplatnenie s vyššou pridanou hodnotou. Často ich takáto automatizácia odbremení od nudných a repetitívnych činností a umožní im venovať sa prospešnejším aktivitám.

Pohľad na projekt striktne cez primárne úspory môže vyvolať odpor pracovníkov. Kreativitu a invenciu ľudských pracovníkov zatiaľ stroje nahradiť nemôžu a zamestnanci majú často dlhoročné znalosti a skúsenosti, ktoré len ťažko možno nahradiť. Reálne benefity je potrebné hľadať primárne v tom, že takáto automatizácia umožní transformáciu spoločnosti a tvorbu príležitostí s vyššou pridanou hodnotou.

Nezavedenie potrebných procesov na realizáciu opatrení

Spustením systému do prevádzky projekt nekončí. Neefektívne pracovné postupy môžu brániť spoločnostiam vo využití všetkých výhod ich implementáciou umelej inteligencie. Pri akejkoľvek implementácii informačného systému je na dosiahnutie cieľov nutné, aby sa daný systém aj používal a aby informácie, ktoré poskytne, boli následne využité pri ďalšom rozhodovaní a pri realizácii následných opatrení na zníženie spotreby.

Nedostatočné zlepšenie po zavedení umelej inteligencie, zväčša ak charakter dát je príliš náhodný a zo vstupných parametrov nie je možné urobiť presnejšiu predikciu alebo ak dáta majú veľmi jednoduchú charakteristiku a na dosiahnutie veľmi dobrej presnosti nie je potrebná umelá inteligencia.

³² Zodpovedný prístup k umelej inteligencii. [Dostupné online](#).

Úspešná implementácia AI závisí od zaangažovanosti všetkých úrovní a funkcií organizácie, špeciálne vrcholového manažmentu. Vedúci pracovníci si nemusia uvedomovať celý potenciál investícií do umelej inteligencie v spoločnosti. V dôsledku toho neposkytnú dostatok prostriedkov a zdrojov k vytváraniu spoločného a integrovaného ekosystému potrebného k úspešnému použitiu umelej inteligencie. Stáva sa, že dátoví vedci často dlho čakajú na dáta a zdroje, ktoré potrebujú analyzovať. Problém taktiež je, že dátoví vedci sú nútení analyzovať dáta pomocou rôznych a možno nekompatibilných nástrojov. Vývojári aplikácií niekedy nemajú prístup k použiteľnému strojovému učeniu a v niektorých prípadoch musia byť modely strojového učenia, ktoré vývojári obdržia, preprogramované alebo nie sú pripravené na nasadenie v aplikáciách. Z tohto dôvodu môže trvať týždne, ba dokonca aj mesiace, kým možno modely nasadiť do užitočných aplikácií.

6 Odporúčania na podporu nasadzovania umelej inteligencie v slovenských podmienkach

Hlavným cieľom podpory nasadzovania umelej inteligencie v slovenských podmienkach je zvýšiť konkurencieschopnosť Slovenska vďaka využitiu umelej inteligencie v tých oblastiach, v ktorých má Slovensko potenciál stať sa jedným z európskych lídrov.

Tieto ciele môžu byť dosiahnuté vďaka:

1. **Koncentracii excelentného** výskumu a vývoja AI riešení v rozumne vybraných oblastiach.
2. **Podpore digitálnej transformácie** firiem a zavedenia AI riešení do slovenského priemyslu na všetkých úrovniach (procesy, údržba, predaj, logistika a ďalšie).
3. **Dôrazu na kvalitu a technologickú inteligenciu** pracovnej sily, tradície priemyslu v SR, podpore SMEs a rozvoju *startup* kultúry či financovaní *hi-tech* inovácií.
4. **Dôrazu na reformu vzdelávacieho systému** a širokej rekvalifikácie v odboroch s najvyšším potenciálom automatizácie.
5. **Vytvoreniu legislatívneho a etického rámca AI** a silnej spolupráce na osi akadémia – vláda – priemysel.

6.1 Odporúčania pre hospodársku politiku a riadenie inovácií

6.1.1 Excelentnosť a inteligentná špecializácia

Ak chceme obe témy dobre uchopiť a podporiť, v zmysle záverov [Rady vlády SR pre vedu, techniku a inovácie zo dňa 24. 6. 2019](#) k Jednotnému postoju zamestnávateľov v oblasti rozvoja Výskumu–vývoja–inovácií, bude najdôležitejšie nastaviť funkčný ekosystém výskumu, vývoja a inovácií, ktorý je postavený na:

- **Zjednotení orientácie vedeckých a výskumných aktivít s podnikateľskými snahami:**
Pri hľadaní maximálneho hospodárskeho vplyvu sa inovácie od začiatku vnímajú z hľadiska ich budúcich komerčných aplikácií. Je bezpodmienečne nutné prijať účinné stimulačné opatrenia na zintenzívnenie a zásadné zvýšenie úrovne spolupráce akademických, vedeckých a výskumných inštitúcií s podnikateľmi, aby sa zvýšila komercializácia výsledkov a výstupov riešení projektov výskumu a vývoja;
- **Dostupnosti kapitálu pre všetky štádiá a úrovne výskumu a vývoja:**
Podporovať všetky úrovne financovania, od malých grantov na výskum v počiatočnom štádiu, až po rozsiahle investície do výskumu a vývoja zamerané na komerčné využitie. Zabezpečiť vyvážené prostredie štátnej podpory, eurofondov, podnikových investícií, rizikového kapitálu, atď.;
- **Vyváženej štátnej podpore:**
V praxi realizovať systematicky zavedené politiky, predpisy, stimuly a dane na podporu vytvárania a rastu výskumných a vývojových aktivít. Vytvoriť reálne podmienky, aby priemysel mal príležitosť (možnosť) ovplyvňovať rozvoj tohto ekosystému v zmysle meniacich sa potrieb.

Zdroje slovenskej ekonomiky sú limitované. Je preto potrebné definovať len určitý počet strategických priorít v oblasti výskumu.

Excelentnosťou rozumieme vytváranie medzinárodne uznaných nových poznatkov a aplikovanie výsledkov výskumu a vývoja do úspešných inovácií, pričom meradlom úspešnosti je primárne ekonomická návratnosť vložených prostriedkov. Výsledkom excelentnosti je nielen konkurencieschopnosť (robiť veci rovnako dobre a efektívne ako ostatní), ale skôr konkurenčná výhoda (robiť veci lepšie ako ostatní).

Treba otvorene povedať, že tu modelujeme proces, ktorý na iných kontinentoch zabezpečuje rizikový kapitál.

Vieme, že sme úspešní, ak firmy, ktoré inovácie aplikujú, dokážu získavať nových zákazníkov a ekonomicky expandovať. Môže byť v tomto Slovensko úspešné? Pravdepodobne nie vo všetkých oblastiach, ktoré sú kumulované v stratégii RIS3³³.

Aby sme dokázali správne alokovať zdroje, musíme brať do úvahy aspoň nasledovné:

- **Ľudské zdroje:**
Prítomnosť odborníkov schopných vyvíjať a inovovať, pričom pod inováciou rozumieme úspešné nasadzovanie riešenia v praxi. Výskumná zložka nestačí. Nositeľmi témy a prijímateľmi podpory musia byť subjekty a konzorciá, ktoré dokážu postaviť heterogénny tím, v ktorom na jednej strane budú nositelia vedeckých poznatkov, na druhej strane obchodníci a niekde medzi nimi ľudia s rozličnými profilmi, ktorí budú schopní pokryť celý inovačný cyklus;
- **Rastový potenciál:**
Ak už v úvode nenájdeme firmy, ktoré by si z inovácie chceli urobiť predmet podnikania, pravdepodobne nemáme pred sebou dobrý a použiteľný nápad, trhový potenciál, či niku trhu, ktorú dokážeme obsadiť. Čím viac firiem sa bude chcieť profilovať v danej doméne, tým väčšia je šanca, že z nej urobíme kompetitívnu výhodu Slovenska;
- **Kontinuálna spätná väzba:**
Túto spätnú väzbu musí poskytnúť trh. Tak ako nie je zmysluplný aplikovaný výskum, ktorého výsledky nikto neaplikuje, nejestvuje ani úspešná inovácia, ktorá nemá svojich odberateľov a zákazníkov. To, že vzťah medzi inováciou a jej nasadením je do veľkej miery procesom pokus – omyl, treba od začiatku brať ako fakt, bez ohľadu na to, že slovenské výskumno-vývojové prostredie na to nie je zvyknuté;
- **Škálovateľnosť:**
Ak bude mať riešenie potenciál, skôr či neskôr sa oň budú zaujímať technologickí investori. Ich vstup je žiaduci a je v záujme expanzie. Pravidlá financovania tomuto nesmú brániť, naopak, musia to podporovať. Rovnako je potrebné myslieť na to, že financovanie excelentnosti z verejných zdrojov nemôže končiť prototypom, ale musí pokrývať aj podporu hromadnej výroby a odbytu;
- **Ochrana pred *brain drainom*:**
Úspešným riešiteľom môže byť aj startup, spin-off z univerzity alebo inej firmy. Budú oslovovaní investormi, ktorí môžu mať záujem stiahnuť *know-how*, kľúčových ľudí alebo

³³ RIS3. [Dostupné online](#)

celé tímy do prostredia, ktoré majú pod kontrolou. Pravidlá narábania s verejnými zdrojmi by mali zabezpečiť, aby sa pridaná hodnota čo najdlhšie vytvárala na Slovensku.

Predbežný zoznam sektorov, v ktorých by sa Slovensko mohlo pokúsiť o získanie excelentnosti v AI založenej na prepojení výskumu/vývoja a podnikateľského sektora je v [Kapitole 6.2 Potenciál umelej inteligencie v ďalších sektoroch](#).

Potrebou zásadne zmeniť vzdelávací systém v prospech výuky v odboroch požadovaných trhom práce a celoživotným vzdelávaním sa zaoberá [Kapitola 6.3 Odporúčania pre rozvoj ľudských zdrojov](#).

Uvedené aktivity sú premietnuté do [Kapitoly 6.4 Odporúčania pre operačné programy](#).

6.1.2 Diverzifikácia priemyselnej výroby

Potreba diverzifikácie priemyslu je na Slovensku bežne skloňovaným pojmom bez toho, aby došlo k jej strategickému uchopeniu zo strany štátnych orgánov. Diverzifikácia z pohľadu firiem znamená:

- Dodávanie existujúceho portfólia novým zákazníkom;
- Dodávanie nového portfólia existujúcim zákazníkom;
- Rozšírenie obchodu na nové teritória.

Z hľadiska štátnej podpory diverzifikácie bude potrebné rozšíriť tradičné kategórie oprávnených výdavkov o niektoré nové a zohľadniť rozšírený zoznam potrieb vo svojich strategických rozhodnutiach aj v operatívnych krokoch. Od štátu očakávame, že zabezpečí:


- Jednoduchú podporu redizajnu produktov, respektíve obmenu ich vybavenia tak, aby firma mohla atakovať nové typy zákazníkov a nové trhy;
- Pomoc pri získavaní certifikátov relevantných pre dané trhy; pritom ide o certifikáty firiem a produktov, ale aj o certifikáty expertov, napríklad v oblasti kybernetickej bezpečnosti;
- Podporu pri náboe obchodných kapacít, ich zaškoľovaní a podľa možností aj pomoc s ich financovaním, kým nábeh obchodu nezabezpečí ich financovanie z predaja;
- Podporu obchodných a marketingových tímov pri nadväzovaní kontaktov na veľtrhoch a konferenciách, podpora členstiev v asociáciách a odborných združeniach;
- Podporu marketingových kampaní na cieľových trhoch, kofinancovanie sponzorstva konferencií, výroby doplnkových marketingových materiálov, brožúr a aktivít na sociálnych sieťach;
- Podporu výskumu a vývoja v oblasti umelej inteligencie v prioritných oblastiach, ktoré treba identifikovať (viac pozri aj kapitolu 6.2);
- Podporu širokého transferu inovácií do praxe, a to bez ohľadu na to, či ide o domáce alebo zahraničné inovácie;
- Podporu vytvárania *spin-off* spoločností zameraných na diverzifikáciu materského portfólia, pomoc pri hľadaní rizikového kapitálu alebo strategického investora;
- Odbúravanie administratívnych bariér pri čerpaní prostriedkov európskych štrukturálnych fondov (EŠIF) a pri ďalších dotačných schémach;
- Trvalú finančnú podporu Národného inštitútu pre umelú inteligenciu a digitálnych inovačných hubov tak, aby mohli byť rovnocenným partnerom digitálnych inovačných hubov v iných krajinách EÚ.

Cieľom návrhu je vytvoriť platformu na maximalizáciu prínosov umelej inteligencie pre občanov Slovenska, podniky a orgány verejnej správy, a to posilnením kapacít technológií s prvkami umelej inteligencie.

Kľúčovým princípom, na ktorom bude stáť činnosť Národného inštitútu pre umelú inteligenciu a digitálnych inovačných hubov budú investície do inovácií, ktoré primárne reagujú na potreby firiem a občanov a na zdokumentovaný a vecne správne naformulovaný dopyt po digitálnych inováciách zo strany podnikov a verejnej správy. Národný inštitút pre umelú inteligenciu zároveň bude ako prioritu podporovať základný a aplikovaný výskum a jeho transfer do praxe. Tým sa vytvorí priestor pre excelenciu a prepojenie akademického a súkromného sektora.

Nasadenie umelej inteligencie bude tvoriť významnú zložku v portfóliu Národného inštitútu pre umelú inteligenciu a bude absorbovať významnú časť alokovaných prostriedkov.

Podľa Nariadenia Európskej komisie centrálnym bodom inovačného ekosystému pre oblasť digitálnych technológií bude centrum digitálnych inovácií (digitálny inovačný hub, ďalej aj „DIH“). Opierame sa pritom o Návrh nariadenia Európskeho parlamentu a Rady, ktorým sa stanovuje program Digitálna Európa na obdobie 2021 – 2027 (DEP)³⁴.



Obrázok 6.1 Základná architektúra spolupráce Štát – Akadémia – Biznis

Cieľom návrhu Európskej komisie je vytvoriť výdavkový nástroj na maximalizáciu prínosov digitálnej transformácie pre občanov EÚ, podniky a orgány verejnej správy, a to posilnením digitálnych kapacít EÚ v piatich kľúčových oblastiach (tzv. špecifické ciele):

- Vysokovýkonná výpočtová technika,
- Umelá inteligencia,
- Kybernetická bezpečnosť a dôvera,
- Pokročilé digitálne zručnosti a
- Zavedenie a najlepšie využívanie digitálnej kapacity a interoperabilita.

³⁴ Návrh Nariadenia Európskeho parlamentu a Rady, ktorým sa stanovuje program Digitálna Európa na obdobie 2021 – 2027. [Dostupné online](#).

Kľúčovým princípom, na ktorom bude stáť činnosť slovenského DIHu, budú investície do inovácií, ktoré primárne reagujú na potreby firiem a na zdokumentovaný a vecne správne naformulovaný dopyt po digitálnych inováciách zo strany podnikov.

Nasadzovanie umelej inteligencie bude tvoriť veľmi podstatnú zložku v portfóliu DIHu a bude absorbovať významnú časť alokovaných prostriedkov.

Konkrétne projekty sa budú robiť v niektorej z prioritných oblastí digitálnej transformácie:

- Podpora integrácie digitálnych technológií (vrátane AI) do produktov, ktoré spoločnosť vyrába, pričom môže ísť o komodity určené pre masový trh, ako aj produkty, ktoré sa budú využívať ako zariadenia, nástroje alebo IT riešenia v niektorom odvetví hospodárstva či verejných služieb;
- Podpora integrácie digitálnych technológií (vrátane AI) do podnikových procesov, napríklad optimalizácia výroby, riadenie kvality, výstupná či laboratórna kontrola, prediktívna údržba, optimalizácia logistiky, inteligentná automatizácia nevýrobných procesov, energetický manažment, marketing a podpora predaja, online predaj, podpora zákazníkov a používateľov a ďalšie.

6.2 Potenciál umelej inteligencie v strategických hospodárskych oblastiach

V nasledujúcich podkapitolách uvádzame oblasti, v ktorých by sme mali zvážiť potenciál ich rozvoja. Po dôkladnom odbornom posúdení bude možné vybrať z týchto oblastí tie, ktoré budú tvoriť jadro dlhodobej slovenskej stratégie pre výskum a aplikáciu AI. Na konci tejto časti diskutujeme o potenciáli umelej inteligencie vo vnorených systémoch, čo je oblasť, ktorá má uplatnenie takmer vo všetkých sektoroch, aj keď zrejme najviac vo výrobe. Práve preto, že vnorené systémy majú veľký potenciál, uvádzame ich v samostatnej časti.

6.2.1 Kybernetická bezpečnosť

Kybernetická bezpečnosť je kľúčovou, aj keď v praxi podceňovanou, oblasťou pri nasadzovaní akýkoľvek riešení v oblasti IKT.

Pri zvyšovaní kybernetickej bezpečnosti hovoríme o nasledujúcich typoch profesionálnych aktivít a služieb:

- Audity a posudzovania bezpečnosti a súladu;
- Vzdelávanie a zvyšovanie povedomia, školenia a tréningy;
- Poradenské a konzultačné služby k informačnej bezpečnosti a kybernetickej bezpečnosti;
- Implementácia riešení informačnej bezpečnosti a kybernetickej bezpečnosti;
- Bezpečnostný monitoring a riešenie bezpečnostných incidentov ako služba (SIEM a *SOC as a Service/CSIRT*);
- Dátová a forenzná analýza;
- Skúmanie a vyhodnocovanie kybernetických hrozieb;
- Certifikačné a akreditačné služby;
- Ochrana osobných údajov.

Možné aplikovanie AI do oblasti kybernetickej bezpečnosti

- **Detekcia** – AI sa široko používa na identifikáciu kybernetických hrozieb. Organizácie môžu kontinuálne zlepšovať parametre, na základe ktorých identifikujú anomálie a vyšlú príslušné avízo;
- **Predikcia** – AI analyzuje obrovské množstvo dát a robí rozličné predikcie na základe toho, ako bola natrénovaná. Následne je možné prijímať predbežné opatrenia;
- **Reakcia** – doména, ktorá je z hľadiska využívania AI zatiaľ v počiatkoch. Najčastejšie sa používa na skrátenie času medzi detekciou útoku a vytvorením najvhodnejšieho balíka opatrení a „záplat“, v budúcnosti možno aj na návrh nových ochranných mechanizmov pre rozvíjajúce sa technológie.

Prínosy z aplikovania AI do oblasti kybernetickej bezpečnosti

- Znižovanie nákladov na detekciu lepším porozumením a opätovným použitím vzoriek na identifikovanie nových hrozieb. Môže tým prísť k redukcii času a úsilia na identifikáciu incidentov, ich preskúmanie a prijatie opatrení;
- Rýchlejšia odozva na útoky – čas na prijatie opatrení sa po zavedení umelej inteligencie skracuje o 12 % až 15 %;
- Vyššia efektívnosť bezpečnostných analytikov. Tí trávia množstvo času analyzovaním záznamov a časových snímok incidentov. Berúc do úvahy aj to, že ich je na trhu nedostatok, je efektívnejšie, ak sa môžu sústrediť na kvalitatívne parametre nálezov identifikovaných pomocou AI.

6.2.2 Zdravotníctvo

V zdravotníctve vieme využiť prakticky všetky dostupné technológie umelej inteligencie tak, ako sú uvedené v [Kapitole 4.1](#).

Zdravotnícke systémy zbierajú čoraz väčšie množstvo rôznych druhov dát. Poistovne, nemocnice či samotní lekári majú dáta o pacientoch, ich diagnózach a detaile liečby, ktoré sa postupne digitalizujú. Poistovne a nemocnice tiež zbierajú dáta o nákupoch medicínskej techniky, liekov a zdravotníckeho materiálu, či o časoch čakania pacienta na rôzne druhy výkonov.

Obrovské množstvo dát sa tiež akumuluje dôsledkom „datafikácie“ zdravia, teda merania zdravotných údajov ako tepu, či fyzickej aktivity vďaka telefónom, inteligentným hodinkám a podobným prístrojom. Segment je teda latentne zrelý na nasadenie nástrojov umelej inteligencie, ktoré sú od dát závislé.

Umelá inteligencia môže lekárom či zdravotníckym pracovníkom pomôcť všade tam, kde je ich rozhodovanie podmienené: napríklad s odbornou správou stanovením diagnózy v zmysle najmodernejších lekárskeho poznatkov a na základe správneho, úplného a včasného vyhodnotenia veľkého množstva údajov a informácií. Veľký objem týchto dát je možné previesť do tzv. štruktúrovaných dát, ktoré vie AI prečítať a predikovať možný postup (s využitím technológií neurónových sietí, *machine learningu*, expertného systému, ako aj genetických algoritmov).

Možné aplikovanie AI v zdravotníctve

Príklady využívania umelej inteligencie pre medicínske účely:

- Automatizované systémy na čítanie a rozoznávanie výstupov z modalít ako magnetické rezonancie, CT či EKG s podobnou alebo lepšou presnosťou než v prípade lekárov;

- Inteligentné chirurgické roboty;
- Riešenia na automatizáciu laboratórnej analýzy mikroskopických vzoriek;
- Vo využití technológií spracovania prirodzeného jazyka – pomoc softvéru pri analýze stavu pacienta na základe jeho reči, najmä v oblasti psychologických a psychiatrických vyšetrení (napr. lepšie rozpoznanie depresie – diagnózy, ktorá v súčasnosti ohrozuje stále väčší počet duševne aktívnych ľudí);
- Sekvencovanie ľudského genómu, teda „čítanie“ génov, ktorého cena každoročne klesá obrovským tempom. Na základe dát z génov je možné predikovať choroby pacienta či presnejšie špecifikovať onkologickú liečbu;
- Vo farmakologickom výskume, ktorý intenzívne využíva štatistické metódy a *machine learning*;
- Lepšie nastavenie systémov prevencie a kontroly liečby pacientov.

Príklady využívania umelej inteligencie pre administratívne účely:

- Aplikovanie strojového učenia do predzásoby liekov či zdravotníckych pomôcok, ktoré môžu zlepšiť ich dostupnosť vo vzdialenejších častiach krajiny;
- Identifikácie anomálií v predpisovaní liekov pomocou údajov zo zdravotných poisťovní;
- Na úrovni nemocníc lepšie využívanie dát bude môcť prispieť k lepšiemu plánovaniu pracovných zmien, využitiu priestorov či postelí.

Prínosy z aplikovania AI v zdravotníctve

Pri zohľadnení väčšieho množstva dát, než je schopný zhromaždiť a spracovať ktorýkoľvek individuálny lekár, bude možné zabezpečiť:

- Efektívnejšiu prevenciu chorôb;
- Personalizovanú liečbu pre pacienta;
- Nižšiu mieru plytvania v zdravotníctve;
- Nižšiu mieru preťaženia pre zdravotnícky personál;
- Dostupnosť zdravotnej starostlivosti.

6.2.3 Poľnohospodárstvo

Poľnohospodárstvo nezbiera také množstvo dát ako iné odbory ekonomiky. Na druhej strane, dostupnosť meteorologických dát spolu s čoraz väčšou cenovou dostupnosťou senzorov otvára priestor na zavedenie umelej inteligencie aj v tomto sektore. Popritom vysoký stupeň mechanizácie umožní nasadzovanie vstavaných systémov, ktoré potenciálne môžu nahradiť ľudskú prácu.

Možné aplikovanie AI v poľnohospodárstve

- **Poľnohospodárske roboty** – autonómne roboty, ktoré sú schopné vysokou presnosťou a efektívnosťou vykonávať ľudské práce ako napríklad zber plodín;
- **Monitoring rastlín a pôdy** – spracovanie dát zachytených senzormi či dronmi za účelom monitoringu zdravia rastlín a pôdy. Umelá inteligencia v tomto prípade vystupuje ako hlavný nástroj pre triedenie dát a vyvodzovanie záverov na základe vopred zadaných algoritmov.

- **Nástroje na predikciu**, napríklad algoritmy prepojené so satelitmi určené na predikciu počasia, analýzu udržateľnosti plodín a vyhodnocovanie fariem na prítomnosť chorôb a škodcov.

Prínosy z aplikovania AI v poľnohospodárstve

- Eliminácia problémov spojených s ubúdajúcim počtom pracovných síl;
- Reakcia na nedostatok sezónnych pracovných síl;
- Monitoring rastlín a pôdy a identifikovanie potenciálnych defektov a nedostatkov živín v pôde;
- Spresnenie a zefektívnenie poľnohospodárskych postupov;
- Zamedzenie nadmerného používania hnojív alebo neudržateľného využívania vody a pôdných zdrojov;
- Predvídanie environmentálnych dopadov na úrodu plodín, napr. dopady klimatických zmien.

6.2.4 Verejná správa

V oblasti verejnej správy môže potenciál umelej inteligencie zvýšiť kvalitu služieb v oblasti verejného sektora a zároveň zvýšiť ich efektívnosť. Vďaka AI bude v budúcnosti možné nielen spracovávať údaje, ale nasadiť aj strojové učenie ako hlavný prvok AI. Umožní to lepšiu kvalitu rozhodovania a rýchlejšie rozhodnutia.

Možné aplikovanie AI vo verejnej správe

Na použitie aplikácií založených na AI v administratíve a verejnej správe sa vytypovali nasledovné témy:

- **Rozpoznávanie obrázkov a videa** – automatické vyhodnotenie obrazových a videografických údajov;
- **Rozpoznávanie textov** – automatické hodnotenie textov (napr. faktúr);
- **Digitalizácia archívov** – vrátane vytvorenia potrebných metaúdajov na indexovanie alebo automatizované odpovedanie na „štandardné žiadosti“;
- **Preklady z jedného jazyka do požadovaného (úradného) jazyka** – automatické prekladové pomôcky pre hovorený jazyk v reálnom čase pre všetky dokumenty. Toto je užitočné najmä pre viacjazyčnú krajinu (masívne úspory nákladov);
- **Zvukové dokumenty** – automatické vyhodnotenie zvukových záznamov (napr. prieskumy o vstupe, zvukové záznamy zo schôdzí alebo digitalizácia zvukových archívov);
- **Interakcia so zákazníkmi – občanmi (chatboty a kontaktné miesta)** – tu sa spája rozpoznávanie obrázkov, zvukov a textov, existuje mnoho potenciálnych príkladov aplikácií, napríklad riešenie otázok týkajúcich sa fakturácie, parkovacích poplatkov, otváracích hodín úradov a ich agend alebo celého radu ďalších udalostí.

Prínosy z aplikovania AI vo verejnej správe

- Možnosť vybudovania univerzálnych pracovísk, na ktorých sa bude dať vykonať väčšina úkonov, s ktorými občania prichádzajú za úradníkmi;
- Možnosť konať proaktívne, na základe toho, že bez sporu došlo k naplneniu istých skutočností;

- Aktívna podpora úradníka vo vzťahu ku konkrétnemu prípadu na základe vyťažovania štruktúrovaných aj neštruktúrovaných dát;
- Odbúranie nejasností pri podaniach na základe pružnej navigácie občana v konkrétnej životnej situácii.

Právne základy, ochrana údajov a bezpečnosť údajov

Zamestnanci musia vedieť, že rozhodovacia právomoc zostane aj v budúcnosti u ľudí, že stroj nie je autonómny. Osobitná starostlivosť sa vyžaduje najmä v oblasti osobných údajov alebo údajov, ktoré sa môžu spájať s osobami. Je potrebné identifikovať potenciál prípadného zneužívania a je potrebné zabrániť zneužívaniu. Schopnosť systémov AI konať čoraz autonómnejšie podrobuje skúške existujúci právny rámec a ochrana dát.

V oblasti medzinárodnej spolupráce uplatnenia (výkonu) rozsudkov sa pripravujú projekty na úrovni EÚ, v ktorých bude možné výrazne nasadiť umelú inteligenciu. Nakoľko AI využíva algoritmy strojového učenia, vie pracovať s veľkými databázami (*big data*), je možné ju nasadiť v multilingválnom prostredí (cezhraničný výkon práva), je schopná na základe rozoznávania obrazu a textu porovnávať a vyhodnocovať veľké súbory a aktuálne reagovať na zmeny, Európska komisia navrhla priamu podporu vývoja príslušných technológií. Spracovanie veľkého objemu dát umožní rýchly exekutívny výkon práva či uplatnenie rozsudkov.

Súčasne sa pracuje na vývoji technológií v oblasti ochrany týchto informačných sietí, najmä ochrany pred kriminálnym prostredím, ktoré by tieto siete mohlo v cezhraničnom rozsahu napadnúť a tým ochromiť spoluprácu krajín EÚ pri výkone práva. Tieto iniciatívy sa zamerajú aj na etické, spoločenské a organizačné aspekty využitia umelej inteligencie na podporu výkonu práva.

6.2.5 Životné prostredie, ochrana klímy a energetika

Úvodom treba povedať, že nasadzovanie AI do rôznych odborov ľudskej činnosti bude mať za následok zefektívnenie týchto činností. Hovoríme predovšetkým o znižovaní energetickej a materiálnej náročnosti, čo samo o sebe bude znamenať pozitívny dopad na životné prostredie. V tejto kapitole nebudeme preto replikovať prínosy, ktoré bude mať zavedenie AI napríklad v priemysle alebo v poľnohospodárstve, aj keď to môžu byť prínosy k ochrane životného prostredia.

Zameriame sa na AI priamo v ekológii s presahom do energetiky, ktorá má na životné prostredie a zmeny klímy dominantný vplyv.

Možné aplikovanie AI pri ochrane životného prostredia

- AI je schopná transformovať súčasné metódy predpovedania počasia;
- Zlepšená predikcia dopytu a ponuky elektrickej energie smerujúca k efektívnemu využívaniu obnoviteľných zdrojov v distribuovanom *smart grid*, zlepšenie ukladania energie, riadenie energetickej záťaže, pomoc pri integrácii obnoviteľných zdrojov, dynamická cenotvorba a obchodovanie a vytváranie trhových incentív;
- Transformácia súčasného systému dopravy založená na nových obchodných modeloch a optimálnejšom využívaní dopravných prostriedkov. Populárnym príkladom využitia AI sú autonómne vozidlá, ktoré môžu prispieť k prechodu na mobilitu založenú na službách a zdieľanú dopravu. AI môže tiež pomôcť pri optimalizácii logistiky, a to prostredníctvom monitorovania výkonu vozidla a správania vodiča za pomoci senzorov;

- AI môže byť využitá aj v odpadovom hospodárstve. Príkladom konvergenencie medzi AI, senzormi a robotikou sú zariadenia na triedenie odpadu vybavené robotmi, ktoré sú zodpovedné za kontrolu kvality regenerovaných materiálov a separáciu rozdielných tokov odpadu. Rozpoznanie špecifických materiálov (prostredníctvom AI a „strojového videnia“/*machine vision*) a ich manipulácia (s použitím robotických ramien) zlepšujú kvalitu aj množstvo druhotného materiálu, ktorý možno ďalej opätovne použiť, čím sa znižuje dopyt po prvotných materiáloch a zároveň aj negatívne externality súvisiace s ich získavaním a výrobou;
- Simulácie prírodných udalostí a katastrof a ich prepojenie na dáta v reálnom čase, systémy varovania a návrh optimálnych reakcií;
- Dáta zo zastavaných zón môžu pomôcť ako pri plánovacej činnosti, tak aj pri optimalizácii dopravných tokov, spotrebe vody a energií;
- Satelitné dáta a informácie z rozličných online zdrojov, senzorov a databáz môžu vo vzájomnej kombinácii pomôcť monitorovať, modelovať a riadiť environmentálne systémy v oveľa väčšom rozsahu ako kedykoľvek predtým, či už ide o ilegálnu ťažbu dreva, znehodnocovanie vody, neoprávnený rybolov a pytliactvo, znečisťovanie vzduchu alebo záťaž z poľnohospodárskej činnosti.

Prínosy z aplikovania AI pri ochrane životného prostredia

- Lepšie porozumenie vplyvu klimatických zmien na počasie a životné prostredie;
- Podpora obnoviteľných zdrojov na úkor fosílnych palív. Možnosť minimalizovať/optimalizovať využívanie materiálov a energie, čo prispieva k zníženiu emisií skleníkových plynov;
- Znižovanie škôd pri živelných udalostiach a iných katastrofách;
- Monitorovanie nežiaducich ľudských aktivít, ich včasné postihovanie a predchádzanie týmto aktivitám;
- Zabezpečenie udržateľného rozvoja miest a obcí;
- Materiálové úspory, opätovné použitie, zmena ekodizajnu výrobkov a vyvíjanie nových výrobkov a služieb so zníženou materiálovou náročnosťou, resp. opätovným využitím v obehovom cykle;
- AI môže byť značným prínosom pre zelené a obehové hospodárstvo, keďže zlepšuje a automatizuje rozhodovanie, šetrí náklady a umožňuje lepšiu alokáciu zdrojov (z hľadiska výrobných faktorov aj využívania zdrojov). Vďaka AI sa automatizácia a robotika môžu využiť v odvetviach, ktoré si doteraz vyžadovali kognitívne „ľudské“ myslenie a zložité rozhodovanie.

6.2.6 Ďalšie oblasti, ktoré majú potenciál na zavedenie umelej inteligencie

- Školstvo
- Finančný sektor
- Doprava

6.2.7 Umelá inteligencia vo vnorených systémoch

Technológie už dnes umožňujú nasadenie rozličných riešení umelej inteligencie priamo do strojov, senzorov alebo komunikačných zariadení. Umelá inteligencia bude pri vnorených systémoch (angl. *embedded systems*) tak blízko k zariadeniu, ktoré nám jednoducho bude stačiť zapnúť alebo vypnúť. Vnorené systémy sa môžu aplikovať vo všetkých prezentovaných sektoroch.

Možné aplikovanie AI vo vnorených systémoch

- 1. Aditívna výroba** – reprezentuje technológie 3D tlače spojené s novým konceptom nízkosériovej, na mieru stavanej výroby v akomkoľvek prostredí. Ak by sme mali pomenovať len jeden kľúčový biznisový koncept, ktorý umožní firmám diverzifikovať ich výrobu a trhové zameranie, bude ním práve aditívna výroba. Súčasný ekosystém 3D tlače sa však ešte stále vyznačuje vysokou mierou chýb pri príprave súborov pre 3D tlač, ale aj pri korektnom nastavovaní zariadení pre úspešnú tlač. Hlavné výhody nasadenia AI pri aditívnej výrobe sú:
 - **Automatizovaná kontrola kvality** – AI je schopná v reálnom čase identifikovať nedokonalosti a chyby v produkcii, porovnávať ich s požiadavkami na výsledný produkt a prijímať korekčné opatrenia, napríklad naniesenie niekoľkých tenších vrstiev alebo úprava fyzikálnych parametrov tlače;
 - **Univerzálnosť** – umelá inteligencia je schopná oddeliť dizajn výsledného produktu od konkrétneho zariadenia, brať pritom do úvahy nielen parametre produktu a zariadenia na 3D tlač, ale aj aktuálnu vlhkosť, teplotu, vek materiálu, veľkosť trysky, rýchlosť nanášania, atď;
 - **Dizajn** – môže ísť napríklad o interaktívny dizajn, ktorým umelá inteligencia zobrazuje návrhárovi predpokladanú podobu výsledného produktu na základe doteraz realizovaných krokov a umožňuje mu robiť žiaduce zmeny v dizajne;
 - **Spätná väzba z automatizovanej kontroly kvality** – môže zároveň pomôcť dizajnérom k tomu, aby sa ich návrhy dali v budúcnosti ľahšie a efektívnejšie tlačiť;
 - **Učiace sa roboty**, ktoré dokážu byť autonómne a vykonávať zmysluplné úlohy³⁵ a taktiež inteligentné chirurgické roboty³⁶.
- 2. Strojové videnie v prirodzenom prostredí**, v ktorom treba vedieť vyhodnocovať snímaný obraz pod rozličnými uhlami, osvetlením aj pri zníženej kvalite obrazu. Patrí sem rozpoznávanie obrazu v oblasti bezpečnosti osôb a ochrany verejných priestorov, zvyšovanie bezpečnosti vozidiel vrátane prevádzky autonómnych vozidiel³⁷.
- 3. Analýza pocitov a nálad osôb na videu**, použiteľná v retaili, marketingu, vzdelávacom procese, ale aj napríklad pri práci s autistickými deťmi³⁸ s umelou inteligenciou nasadenou priamo v snímacom zariadení.
- 4. Prevzatie rizikových prác strojmi** – to sa v určitej miere deje už dnes, avšak stále pod kontrolou človeka. V budúcnosti aj práce ako napr. zneškodňovanie výbušnín, manipulácia s nebezpečnými chemikáliami, vŕtanie a zváranie budú môcť byť plne automatizované pomocou AI.

³⁵ HiPEDs - EPSRC Centre for Doctoral Training. [Dostupné online.](#)

³⁶ Cal-MR: Center for Automation and Learning for Medical Robotics. [Dostupné online.](#)

³⁷ Stanford Vision Lab. [Dostupné online.](#)

³⁸ First Faces in-the-wild Workshop-Challenge. [Dostupné online.](#)

Prínosy z aplikovania AI vo vnorených systémoch

- **Rýchlejšie reakčné časy** – decentralizované výpočty na malých zabudovaných systémoch umožňujú posilať výsledky výpočtu namiesto nespracovaných dát. Vo výsledku systém ako celok pracuje efektívnejšie a môže reagovať rýchlejšie;
- **Nižšie nároky na centrálny výpočtový výkon** – na druhej strane nová vlna AI vytvorí dopyt po oveľa väčšom počte senzorov a výpočtových uzlov;
- **Nižšie nároky na komunikačnú infraštruktúru** – AI môže bežať na malej inteligentnej mikroelektronike a senzoroch bez nutnosti pripájať sa na cloud alebo centrálné výpočtové kapacity;
- **Zvýšená bezpečnosť údajov** – keďže výpočet môže prebiehať offline, žiadne senzitivné údaje nemusia byť prenášané po sieti;
- **Skrátenie času vývoja** – AI dokáže skrátiť čas vývoja nových softvérových produktov. Ak miesto zložitých a ťažko algoritmizovateľných pravidiel, napríklad pri rozpoznávaní obrazu alebo predikcii porúch, nasadíme strojové učenie, vývoj nielen skrátime, ale aj dramaticky zlacníme;
- **Jednoduchšie udržiavanie a modifikácie** – moderné metódy softvérového vývoja umožňujú redukovat' zdrojový kód na minimum, takže je možné na riadiacu mikrojedinotku nasadiť program aj s učiacim sa algoritmom. Takýto zabudovaný systém môže zmeniť svoj účel alebo konfiguráciu na základe jednoduchého pokynu;
- **Zjednodušenie používania** – okrem „AI na hranie“ (ako je tá, ktorú máme k dispozícii v mobilných telefónoch) existuje množstvo podnikových, priemyselných a komerčných AI aplikácií, ktoré sú pre používateľov ťažko zrozumiteľné. Pri zabudovaných systémoch je 95 % komplexnosti skryté.

6.3 Odporúčania pre oblasť ľudských zdrojov

Trh práce sa mení a čoraz vo väčšej miere vyžaduje zručnosti vyššieho stupňa, zvýšenie digitálnej gramotnosti. Zároveň je potrebné zabezpečiť pracovníkov – expertov, ktorých bude trh práce potrebovať, poskytnúť im príležitosti pre ich odborný rozvoj a získavanie nových zručností. Nezanedbateľné sú aj požiadavky na uplatniteľnosť v nových podmienkach a spôsoby riešenia transformácie klasických/štandardných povolání na nové požiadavky trhu práce.

Uvedené musí byť primárne zohľadnené v príslušných odvetvových rozvojových politikách, vrátane podporných aktivít zameraných na rozvoj ľudských zdrojov. Proces rozvoja ľudských zdrojov v rámci inteligentného priemyslu musí zároveň zohľadňovať potreby všetkých účastníkov trhu práce, vrátane znevýhodnených osôb s cieľom podpory ich prístupu k vzdelávaniu najmä na účely získania, alebo udržania si zamestnania.

Rovnako musia byť nastavené opatrenia smerom k zvyšovaniu podielu zamestnaných absolventov, zvyšovaniu podielu zamestnaných absolventov v odbore vzdelávania a znižovaniu nákladov na rekvalifikáciu absolventov zapojením praxe do vzdelávania. Obzvlášť dôležité bude zabezpečiť rekvalifikáciu absolventov, ktorí nevedia nájsť uplatnenie v nimi vyštudovanom odbore vzdelávania a veľmi rýchlo po opustení školy im ponúknuť možnosť získať znalosti a zručnosti v odboroch požadovanými praxou, aby nezaberali miesto ľuďom s nižšou kvalifikáciou.

Treba vytvoriť také motivačné prostredie pre zamestnávateľov, aby nielen umožnili, ale priamo podporovali a podieľali sa na celoživotnom vzdelávaní a zvyšovaní kvalifikácie svojich zamestnancov, okrem iného aj zavedením tzv. superodpočtu týchto nákladov zo základu dane vo výške najmenej 100% – podobne ako je to pri nákladoch na výskum a vývoj – alebo poskytovaním cvičných technológií vybraným fakultám vysokých škôl a stredným odborným školám, nakoľko bez vysokokvalifikovaných pracovníkov nebude výskum a vývoj možné realizovať.

Podporované aktivity by mali prispieť k tomu, aby pri budovaní svojej kariérnej dráhy mal každý občan dostatok podpory na získanie sebaistoty v osvojovaní vlastných digitálnych zručností a chápal svoj kariérny rast a pracovné miesto v synergickom prepojení so svetom digitálnych technológií.

Digitálne pracovné miesto chápeme ako široké označenie pre akúkoľvek produktívnu činnosť človeka, pri ktorej efektívne a bezpečne využíva digitálne technológie k naplneniu stanovených cieľov a prispieva tak k spoločnému budovaniu a rozvoju digitálnej ekonomiky Slovenska.

Nasadzovanie umelej inteligencie nebude možné bez kvalifikovaných ľudských zdrojov ako na strane inovujúcich firiem, tak aj na strane ich dodávateľov. Z doménovo-orientovaných príkladov uvedených v kapitole 4.6 jasne vyplýva, že nasadenie toho-ktorého riešenia a dosiahnutie prínosov predpokladá doplnenie kvalifikácie na strane zadávateľov projektov a rozšírenie kapacít a nové profily na strane IT a konzultačných firiem.

Na strane zadávateľa bude potrebné mať pracovníkov s adekvátnym *know-how*:

- Vedúci výroby a procesní inžinieri a ďalší, ktorí budú spolupracovať s dátovými vedcami na určení problémov a cieľov, na nastavení kvalitatívnych parametrov, cieľov v oblasti manažmentu energetickej spotreby, plánovania, riadenia predajní, parametrov pre obsluhu zákazníka, online predaj, kvalitu a včasnosť servisu v existujúcom helpdesk pracovisku, call centre, atď.
- Pracovníci výstupnej kontroly, údržby a ďalší pracovníci, ktorí participujú pri tréningu AI systémov;
- Operátori, ktorí budú po preškolení vykonávať komplementárne úlohy a fungovať ako eskalačný stupeň;
- Informatici zodpovední za prevádzku výpočtovej techniky a sieťovej infraštruktúry;
- Technici zodpovední za nastavovanie a prevádzku senzorov/kamier;
- Pracovníci údržby zodpovední za čiastkové úlohy participujú na tréningu umelej inteligencie;
- Projektoví manažéri zodpovední za priebeh projektu ako celku.

Na strane dodávateľských a konzultačných firiem a výskumno-vývojových inštitúcií budeme potrebovať expertov s profilmi:

- Dátoví inžinieri spravujúci dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;
- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- Architekti IT spravujúci základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Vývojári aplikácií nasadzujúci modely do aplikácií s cieľom vytvárania produktov založených na dátach;

- Programátori a ďalší IKT špecialisti zodpovední za implementáciu harvdérových, ale aj softvérových riešení;
- Vývojári aplikácií so znalosťou *machine learning* algoritmov (Python, R a iných.), ktorí nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Experti na vizualizáciu a interpretáciu dát.
- Špecialisti na vision systémy, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- Technici a konštruktéri zodpovední za nastavovanie a prevádzku senzorov/kamier, mechanických komponentov a ich integráciu;
- Konzultanti so znalosťami základov dátovej etiky;
- Konzultanti so znalosťami GDPR;
- Integrovaní špecialisti so znalosťou REST alebo SOAP technológií komunikácie;
- Správcovia databáz
- Experti na technológiu konkrétneho chatbota alebo iného komerčného riešenia založeného na AI

Odporúčania

Z národného hľadiska je dôležitá komplexná, systémová, ale aj finančná reforma vzdelávacieho systému, zameranie sa na kvalitné školské prostredie využívajúce v maximálnej miere prenos a rozvoj poznania a produkujúce a podporujúce absolventov so zameraním na potreby spoločnosti, podnikateľského prostredia a hospodárskeho smerovania krajiny.

Vzhľadom na to, že trh práce sa mení a čoraz vo väčšej miere vyžaduje zručnosti vyššieho stupňa a zvýšenie digitálnej gramotnosti, v rámci vzdelávania na stredných a vysokých školách, ako aj v rámci celoživotného vzdelávania, je dôležité vytvoriť dostatočný priestor a kvalitnú ponuku pre občanov všetkých vekových kategórií.

Z praktických dôvodov implementácie prvkov inteligentného priemyslu je potrebné zamerať sa aj na vzdelávanie v oblasti technickej normalizácie a technických noriem, rozvoj zručností v používaní technických noriem a aplikácií poznatkov z technických noriem.

Je nevyhnutné zmapovať všetky profesie aktuálne žiadané na trhu práce a klasifikovať ich jednoduchou stupnicou podľa miery ich možného nahradenia technologickými riešeniami. Následne bude potrebné postupne identifikovať možné perspektívne oblasti, v ktorých nájdu svoje uplatnenie pracovníci s najväčšou mierou ohrozenia svojho pracovného miesta a rovnako tak zručnosti potrebné pre získanie novej pracovnej pozície. V ďalšom kroku bude potrebné zabezpečiť rôznorodé typy vzdelávania a formy získavania nových zručností pre takýchto pracovníkov, ako aj spôsob ich certifikácie.

Na riešenie vyššie uvedených problémov a komplexné zlepšenie podmienok pre implementáciu prvkov digitálnej transformácie so zameraním na priemysel boli do AP IP vložené konkrétne opatrenia podľa tabuľky nižšie.

Tabuľka 6.1 Prípravné opatrenia definované v Akčnom pláne inteligentného priemyslu

	Názov opatrenia	Zodpovedné subjekty	Termín
1	Identifikácia požiadaviek podnikateľskej sféry vo vzťahu k potrebným počtom a kvalifikovanosti ľudských zdrojov relevantných pre oblasť inteligentného priemyslu do roku 2025 a s výhľadom do roku 2030	MH SR, MPSVaR SR v spolupráci s podnikateľským sektorom	30. 03. 2019
2	Identifikácia aktuálnej ponuky vzdelávania a školiacich a tréningových programov relevantných pre oblasť inteligentného priemyslu	MŠVVaŠ SR, MPSVaR SR	31. 12. 2018
3	Vypracovanie Štúdie dopadov digitálnej transformácie a Inteligentný priemysel a odporúčaní na národnej úrovni v oblasti zamestnanosti, kvalifikácií a foriem práce – Práca 4.0	MPSVaR SR, MPSVaR SR, Sektorové rady	30. 06. 2019
4	Systémová zmena vzdelávacieho systému pripravujúceho pracovníkov pre potreby praxe a konkrétne inteligentného priemyslu	MŠVVaŠ SR, MPSVaR SR (Aliancia sektorových rád)	31. 12. 2020
5	Aktualizácia Programu informatizácie rezortu školstva do roku 2020 s výhľadom do roku 2030	MŠVVaŠ SR	31. 12. 2018
6	Potreba zvýšenia vedomostí a zručností mladých ľudí pre digitálnu dobu v rámci formálneho vzdelávania	MŠVVaŠ SR	31. 12. 2019 - priebežne
7	Prax ako súčasť štúdia technických odborov na stredných aj na vysokých školách	MŠVVaŠ SR, zamestnávateľa, VÚC	31. 12. 2019
8	Spolufinancovanie vysokoškolského vzdelávania súkromným kapitálom	MŠVVaŠ SR, MF SR	31. 12. 2019
9	Celoživotné vzdelávanie	MŠVVaŠ SR, MPSVaR SR (Aliancia sektorových rád)	31. 12. 2018
10	Programy a projekty na prispôsobovanie zručností pracovnej sily vrátane uchádzačov o zamestnanie (UoZ) kľúčovým požiadavkám inteligentného priemyslu na rozvoj soft zručností, sektorových (hard) zručností a programy zamerané na rozvoj digitálnych zručností za účasti zamestnávateľov	MPSVR SR, MH SR, zamestnávateľa, VÚC	2018 - 2020
11	Predvídanie potreby zručností v súlade s vývojom na trhu práce, zabezpečovanie prognóz vývoja na trhu práce a lepšia identifikácia dopytu po kvalifikovanej pracovnej sile	MPSVaR SR	31. 12. 2018 aktualizácia každý rok
12	Iniciovanie vzniku Centier digitálnych inovácií na Slovensku (CDI)	MH SR	30. 06. 2019
13	Podpora činnosti Digitálnej koalície	ÚPPVII	priebežne
14	Podpora činnosti univerzitných inkubátorov	MŠVVaŠ SR, MPSVaR SR, MH SR	31. 12. 2018

Tabuľka 6.2 Opatrenia v oblasti trhu práce a vzdelávania definované v Akčnom pláne inteligentného priemyslu

Označenie opatrenia	Názov opatrenia	Zodpovedné subjekty	Termín
1.1.1	Príprava programu informatizácie rezortu školstva do roku 2030	MŠVVŠ SR	31. 12. 2019
1.1.2	Systémová zmena vzdelávacieho systému pripravujúceho pracovníkov pre potreby praxe a hospodárstva	MŠVVŠ SR, MPSVR SR	31. 12. 2020
1.1.3	Celoživotné vzdelávanie – komplexná systémová zmena, stratégia a implementácia legislatívnych opatrení	MŠVVŠ SR, MPSVR SR	31. 12. 2019
1.1.4	Zriadenie pracovnej skupiny s cieľom vytvoriť koordinovaný mechanizmus na boj proti dezinformáciám	Predseda Bezpečnostnej rady SR	31. 12. 2019
1.1.5	Vypracovanie analýzy stavu digitálnych zručností na Slovensku s návrhom konkrétnych opatrení	ÚPVII, MŠVVŠ SR, ÚV SR, MPSVR SR	31. 12. 2020
1.1.6	Podpora aktivít vedúcich k zvýšeniu podielu žien v IT a digitálnom sektore	MŠVVŠ SR, ÚPVII, MPSVR SR a partneri venujúci sa tejto oblasti	30. 6. 2020, priebežne
1.1.7	Vypracovanie štúdie vplyvov digitálnej transformácie a odporúčaní na národnej úrovni v oblasti zamestnanosti, kvalifikácií a foriem práce – Práca 4.0	MPSVR SR, MŠVVŠ SR	31. 12. 2019
1.1.8	Podpora zvýšenia kompetencií mladých ľudí pre digitálnu dobu v rámci formálneho vzdelávania	MŠVVŠ SR	31. 12. 2019, priebežne
1.1.9	Iniciovanie činností vedúcich k posúdeniu dopadov využívania inteligentných systémov a digitálnych technológií na vývoj, zdravie a správanie človeka	MZ SR, ÚPVII	31. 12. 2019, priebežne
1.2.1	Zatraktívnenie podmienok zamestnávania informačných špecialistov v štátnej a verejnej správe	ÚV SR, MF SR	31. 12. 2021
1.2.2	Podpora získavania talentov na štúdium a zamestnávanie expertov zo zahraničia vrátane vysokých škôl a priemyslu	MPSVR SR, MŠVVŠ SR, MV SR, MH SR, ÚV SR, ÚPVII	30. 06. 2020

V krátkodobom horizonte je potrebné zrýchliť prípravu na vzdelanie v digitálnej dobe a navrhnuť kurzy pre dátovú vedu a programovanie pre všetky úrovne systému vzdelávania. Očakáva sa *Program informatizácie školstva 2030* a zavedenie rôznych pilotných projektov na skvalitnenie vzdelávania a jeho prispôsobenie digitálnej dobe (napríklad adaptívne vzdelávanie, kurzy manažérstva kvality výučby a iné).

Zároveň je potrebné zaviesť program rekvalifikácie a celoživotného zvyšovania digitálnych zručností s dôrazom na zlepšovanie analytických schopností a kritického myslenia. Digitálne zručnosti a kompetencie by sa mali podporovať od najnižšieho veku, pričom sa zväží využitie AI pre zvýšenie úspechu výukového procesu.

V pôsobnosti Aliancie sektorových rád a v spolupráci s [Digitálnou koalíciou – národnou koalíciou pre digitálne zručnosti a povolania Slovenskej republiky](#)³⁹ bude vypracovaná *Analýza stavu digitálnych zručností na Slovensku* s návrhom konkrétnych opatrení, zároveň je tu potreba aktívne sa zapájať do celoeurópskeho vzdelávacieho a rekvalifikačného programu zamestnancov v digitálnej ekonomike. Štát musí vytvoriť podmienky a nástroje na ochranu svojich občanov, najmä (ale nielen) tých najviac zraniteľných (deti, mládež a starší ľudia) pred negatívnymi konzekvenciami spojenými s nesprávnym a neprimeraným používaním digitálnych technológií.

Digitálna koalícia a národný projekt [IT akadémia – vzdelávanie pre 21.storočie](#)⁴⁰ majú ambíciu zaoberať sa identifikáciou kvalifikácií v oblasti IT v rámci vyššieho odborného vzdelávania a pomaturitného špecializačného vzdelávania s možnosťou prechodu na vysokoškolské štúdium. Vytvorením centrálného úložiska digitálneho edukačného obsahu a jeho následným kontinuálnym dopĺňaním sa vytvorí technologický základ (platforma) využívania digitálnych edukačných materiálov pre vzdelávanie na rôznych úrovniach a v rôznych oblastiach vzdelávania.

Ministerstvo školstva, vedy, výskumu a športu Slovenskej republiky bude v spolupráci s [IT Asociáciou Slovenska](#)⁴¹ a IT akadémiou spolupracovať na vzdelávaní učiteľov za účelom zvyšovania ich digitálnych zručností a kompetencií. Ministerstvo školstva, vedy, výskumu a športu SR tiež bude podporovať tvorbu programov spolupráce medzi školami v rámci programu Erasmus+ a e-Twinning. Implementácia programu informatizácie vzdelávacieho systému s výhľadom do roku 2030 zdefiniuje komplex aktivít a projektov, ktoré školy a pedagógov pripravujú na *digitálnu školu* a prinesú žiakmi a študentami očakávané digitálne prostredie do škôl. Systematicky bude tiež podporená tvorba nových otvorených digitálnych vzdelávacích zdrojov a ich zverejnenie na *Centrálnom úložisku digitálneho edukačného obsahu*⁴².

Modernizácia a otvorenie trhu práce

Je dôležité prispôbiť pravidlá trhu práce digitálnej dobe: umožniť zmysluplné a flexibilné sociálne poistenie pre pracovníkov v platformovej ekonomike a posúdiť dopady platformovej ekonomiky a zmeny práce v digitálnej dobe na pracovné právo a jeho inštitúty v kontexte subjektov, ktorých sa týka. Rovnako potrebujeme výrazne zjednodušiť možnosť získavania najlepších expertov zo zahraničia pre potreby inovatívnych podnikov, ako aj inštitúcií vedy a výskumu.

³⁹ Digitálna koalícia. [Dostupné online](#).

⁴⁰ IT akadémia. [Dostupné online](#).

⁴¹ ITAS. [Dostupné online](#).

⁴² Wiki: Centrálné úložisko digitálneho edukačného obsahu. [Dostupné online](#).

S cieľom ponúknuť pohľad zamestnávateľov na reformu formálneho vzdelávacieho systému predstavili zamestnávateľské zväzy ministerstvu školstva aj odbornej verejnosti materiály ako:

- Koncept reformy terciárneho vzdelávania na Slovensku z pohľadu Republikovej únie zamestnávateľov (ďalej aj „RÚZ“)⁴³;
- Koncept reformy odborného vzdelávania na Slovensku z pohľadu RÚZ⁴⁴.

Hlavnou slabinou slovenskej pracovnej sily napriek kvalite slovenských informatických fakúlt je slabá miera IT zručností pracovnej sily na Slovensku. Preto viacero zástupcov podnikateľského sektora v kombinácii s akademickou obcou požaduje zvýšenie financovania informatických študijných odborov.

Slovensko dnes totiž nie je schopné vychovať dostatok špecialistov v oblasti IKT, ktorí by boli schopní poskytnúť nevyhnutnú základňu na realizáciu digitálnej transformácie Slovenska. Bez danej podpory by šlo o ohrozenie ďalšieho rozvoja slovenského hospodárstva vo viacerých odvetviach, čím by sa zapríčinilo zaostávanie Slovenska v porovnaní s ostatnými krajinami EÚ.

Podľa Svetového ekonomického fóra budú v tejto reforme úspešné iba tie krajiny, ktoré si vytvoria flexibilné formy práce a značne rozvinú IT schopnosti v rámci svojho školstva. Slovensko dlhodobo ignoruje situáciu v rámci svojho vzdelávacieho systému, ktorý je podľa názoru viacerých odborných organizácií vo veľmi zlom stave a spolu s nepriaznivým demografickým vývojom hrozí, že Slovensko nebude zaradené do európskych a medzinárodných dodávateľských a odberateľských reťazcov. Tým by sa slovenská ekonomika dostala na perifériu v rámci európskeho hospodárskeho priestoru.

Ďalším významným faktorom, ktorý ovplyvňuje kvalitu prípravy budúcich IT špecialistov potrebných pri digitálnej transformácii všetkých odvetví ekonomiky ako aj verejnej správy, je neustále sa znižujúca úroveň prípravy žiakov z matematiky a informatiky na základných a stredných školách.

Zamestnávateľské zväzy v spolupráci s vysokými školami aj v tejto oblasti predstavili Analýzu požiadaviek vysokých škôl a trhu práce na absolventov stredných škôl z pohľadu matematickej gramotnosti a návrh opatrení na skvalitnenie matematického vzdelávania⁴⁵.

Táto analýza slúžila ako podklad pre prácu expertov pracovnej skupiny zriadenej ministerkou školstva na Štátnom pedagogickom ústave a ich práca by mala vyústiť do záverov a odporúčaní pre rezort školstva v danej oblasti.

Ďalším aspektom súvisiacim s reformou školstva je potreba zapojenia firiem do rozvoja celoživotného vzdelávania. Slovenské podniky sú stále slabo zainteresované do zvyšovania kvalifikácie vlastných zamestnancov a do prípravy školení pre nezamestnaných, ktorých je v súčasnosti veľmi náročné dostať späť na trh práce.

Na Slovensku chýba celonárodná informačná kampaň na podporu správneho identifikovania nových príležitostí, v akých sa musí školstvo rozvíjať. Slovenské podniky potrebujú vedenie a pomoc pri zavedení procesov digitálnej transformácie a inteligentného priemyslu a technológií.

⁴³ Koncept reformy terciárneho vzdelávania na Slovensku z pohľadu RÚZ . [Dostupné online](#).

⁴⁴ Koncept reformy odborného vzdelávania na Slovensku z pohľadu RÚZ. [Dostupné online](#).

⁴⁵ Šveda, D., Repovský, M., Ftáčnik, M.: Analýza požiadaviek vysokých škôl a trhu práce na absolventov stredných škôl z pohľadu matematickej gramotnosti. Dostupné [online](#).

Aj tento stav, ako aj neexistencia Stratégie celoživotného vzdelávania na Slovensku viedlo zamestnávateľov k predstaveniu materiálu *Návrhy RÚZ na zmeny v oblasti ďalšieho vzdelávania v rámci systému celoživotného vzdelávania na Slovensku 2018*⁴⁶.

6.4 Odporúčania pre operačné programy a partnerskú dohodu

V tomto dokumente ide výhradne o aktivity smerujúce k inováciám založeným na nástrojoch umelej inteligencie. Avšak princípy sa dajú použiť v oveľa širšom rozsahu a môžu byť aplikované na akúkoľvek podporu inovácií v slovenských firmách.

V rámci tohto ekosystému sa budú pod orkestráciou inštitúcií zameraných na rozvoj umelej inteligencie (Národný inštitút pre umelú inteligenciu, digitálne inovačné huby, združenia venujúce sa AI) realizovať dva typy aktivít:

1. Iniciačné aktivity

Tento typ aktivít bude mať predovšetkým motivačný, osvetový a vzdelávací charakter a mal by viesť k vytipovaniu budúcich projektov a projektových partnerov. Už v tejto fáze by sa teda mali aktivity zamerať na konkrétne odborné témy a zabezpečiť nadviazanie kontaktov medzi poskytovateľmi *know-how*, riešiteľmi a subjektami realizujúcimi inovácie.

Patrí sem aj využívanie dostupných *test-beds*. Oprávnenými výdavkami budú workshopy, semináre, hackathony, referenčné návštevy na Slovensku aj v zahraničí, ako aj úhrady za zapožičanie licencií a využívanie laboratórií či infraštruktúry v zmysle pravidla *test before invest*. Súčasťou oprávnených nákladov budú cestovné náklady, náklady na organizáciu eventov a úhrada prednášajúcim a konzultantom.

V prípravnej fáze projektu inovátor dostáva pomoc od vyššie uvedených inštitúcií alebo od konzultanta, ktorého angažovanie môže, ale nemusí zabezpečiť daná inštitúcia. Výsledkom prípravnej fázy môže byť analýza potrieb inovátora, analýza jeho interných kapacít, technického a IT prostredia, analýza projektových rizík, ako aj párovanie potrieb s ponukami na strane poskytovateľov a riešiteľov a hľadanie vhodných zdrojov financovania. Žiaducim finálnym výsledkom prípravnej fázy je úspešná žiadosť o projektové financovanie, zaradenie do úspešného konzorcia alebo iný typ zmluvného vzťahu, ktorý povedie k úspešnej inovácii.

2. Projektové aktivity

V realizačnej fáze pôjde o jasne ohraničené projekty s danými cieľmi, pracovnými balíkmi, financovaním a konzorciálnou štruktúrou. Vo výnimočných prípadoch budú partnermi len subjekt realizujúci inovácie a nositeľ *know-how*, ak vie byť zároveň riešiteľom a poskytovať implementačnú aj poimplementačnú projektovú podporu aj regionálne tam, kde je potrebná. V ďalších prípadoch budú partnermi prijímateľa projektu aspoň jeden poskytovateľ *know-how* a aspoň jeden riešiteľ, v iných prípadoch sa subjekt realizujúci inovácie stane členom nadnárodného konzorcia, v ktorom budú nositelia zdrojového *know-how* a riešitelia.

⁴⁶ Návrhy RÚZ na zmeny v oblasti ďalšieho vzdelávania v rámci systému celoživotného vzdelávania na Slovensku 2018. [Dostupné online.](#)

V ďalšom texte sú jednotlivé aktivity priradené k špecifickým cieľom a opatreniam. Zároveň je hviezdikami (*) indikovaný navrhovaný zdroj a schéma financovania.

Význam je nasledovný:

Vysvetlivka *: Tieto aktivity by mali byť financované so 100 % intenzitou pomoci. Organizačným a odborným garantom aktivít bude Národný inštitút pre umelú inteligenciu alebo digitálny inovačný hub.

Vysvetlivka **: Tieto aktivity by mali byť financované na základe *de minimis* schémy. Organizačným a odborným garantom aktivít bude Národný inštitút pre umelú inteligenciu alebo digitálny inovačný hub. Pre tento typ financovania odporúčame inštitucionalizovať a používať inovačné poukazy (tzv. *vouchery*).

Vysvetlivka ***: Tieto aktivity by mali byť financované s intenzitou, ktorá bude závislá od regiónu a od veľkosti podniku alebo výskumnej inštitúcie. V budúcom programovom období navrhujeme intenzitu navýšiť a zohľadniť aj potrebu zvyšovania konkurencieschopnosti podnikov v Bratislavskom kraji. Ak je partnerom projektu Národný inštitút pre umelú inteligenciu, intenzita pomoci pre ním realizované pracovné balíky je 100 %.

Zvláštny režim by mal platiť pre výskumné aktivity, ktoré môžu priniesť obrovský multiplikačný efekt. Treba brať do úvahy, že investor, ktorý bude zvažovať založenie výskumného centra na Slovensku, bude mať ponuky aspoň 50 % kofinancovania v mnohých iných európskych regiónoch. Slovensko musí v tejto konkurencii obstáť aj ponúkanou intenzitou pomoci, a to bez ohľadu na región a veľkosť podniku.

Vysvetlivka ****: V prípade, že je slovenský žiadateľ úspešný v inovačnom projekte financovanom z priamo riadeného programu (*Horizon Europe*⁴⁷, *DEP*⁴⁸, *CEP*⁴⁹ a iné), bude mať nárok na dotáciu z EŠIF v plnom rozsahu spolufinancovania, a to bez ohľadu na región či veľkosť podniku.

Aktivity, ktoré bude možné financovať z opatrení programového obdobia 2021 – 2027

1 INTELIGENTNEJŠIA EURÓPA – inovatívna a inteligentná transformácia hospodárstva

1.1 Rozšírenie výskumných a inovačných kapacít a využívania pokročilých technológií

1.1.1 Podpora spolupráce akademického sektora a podnikov

Iniciačné aktivity*:

Podpora prezentačných, osvetových a poradenských aktivít slovak.AI voči slovenským podnikom

- Sprostredkovanie výsledkov na Slovensku realizovaného výskumu slovenským podnikom prostredníctvom Národného inštitútu pre umelú inteligenciu, resp. slovak.AI; podpora sa vzťahuje aj na vyhľadávanie vhodných projektových partnerov a výskumných pracovísk;
- Podpora výskumu a vývoja v oblasti umelej inteligencie pre prioritné oblasti ako napr. kybernetická bezpečnosť, aditívna výroba i v ďalšie oblasti podľa aktuálneho vývoja na technologických trhoch;

⁴⁷ Horizon Europe - the next research and innovation framework programme. [Dostupné online.](#)

⁴⁸ Digital Europe Programme: a proposed €9.2 Billion of funding for 2021-2027. [Dostupné online.](#)

⁴⁹ Circular Economy - Implementation of the Circular Economy Action Plan. [Dostupné online.](#)

- Finančná podpora digitálnych inovačných hubov a Národného inštitútu pre umelú inteligenciu;
- Podpora sa vzťahuje aj na poradenstvo smerujúce k napísaniu a predloženiu žiadosti o financovanie.

Iniciačné aktivity:**

- Realizácia krátkodobých experimentov, testovania a preverovania vhodnosti technológií na pracoviskách slovenských akademických inštitúcií (v zmysle konceptu *test before invest*).

Projektové aktivity*:**

- Financovanie Národného inštitútu pre umelú inteligenciu, digitálnych inovačných hubov z projektov EŠIF za predpokladu, že partnerom projektu je aj slovenský podnik;
- Financovanie EŠIF projektov slovenských podnikov bez ohľadu na to, či partnerom projektu je Národný inštitút pre umelú inteligenciu, digitálny inovačný hub alebo iné pracovisko z akademickej sféry.

1.1.2 Podpora účasti slovenských subjektov v Európskom výskumnom priestore

Iniciačné aktivity*:

- Sprostredkovanie výsledkov nadnárodného výskumu slovenským podnikom prostredníctvom Národného inštitútu pre umelú inteligenciu a digitálnych inovačných hubov, podpora sa vzťahuje aj na vyhľadávanie vhodných projektových partnerov a zahraničných výskumných pracovísk.
- Podpora zapájania Národného inštitútu pre umelú inteligenciu a digitálnych inovačných hubov do medzinárodných projektov za predpokladu, že partnerom projektu je aj slovenský podnik;
- Podpora výskumu a vývoja v oblasti umelej inteligencie pre oblasti podľa aktuálneho vývoja na technologických trhoch a prioritách Slovenskej republiky;
- Podpora sa vzťahuje aj na poradenstvo smerujúce k napísaniu a predloženiu žiadosti o financovanie.

Iniciačné aktivity:**

- Realizácia krátkodobých experimentov, testovania a preverovania vhodnosti technológií na medzinárodnej úrovni (v zmysle konceptu *test before invest*).

Projektové aktivity**:**

- Podpora zapájania slovenských podnikov do projektov financovaných z priamo riadených programov.

1.2 Posilnenie rastu a konkurencieschopnosti malých a stredných podnikov, vrátane produktívnych investícií

1.2.1 Podpora malého a stredného podnikania

Iniciačné aktivity*:

- Vytváranie a udržiavanie katalógovo overených AI riešení a zabezpečenie prístupu k týmto katalógom pre malé a stredné podniky;

- Propagácia prínosov AI riešení pre malé a stredné podniky (ďalej len „MSP“) formou kampaní, konferencií, referenčných návštev a workshopov;
- Prezentácie projektových *best practices*, možných riešení a expertov;
- Sprostredkovanie výsledkov výskumu slovenským MSP prostredníctvom slovak.AI; podpora sa vzťahuje aj na vyhľadávanie vhodných projektových partnerov a výskumných pracovísk;
- Podpora vytvárania *spin-off* spoločností zameraných na diverzifikáciu materského portfólia, pomoc pri hľadaní rizikového kapitálu alebo strategického investora;
- Podporu redizajnu produktov, respektíve obmena ich vybavenia tak, aby firma mohla atakovať nové typy zákazníkov a nové trhy;
- Finančná podpora digitálnych inovačných hubov tak, aby mohlo byť rovnocenným partnerom digitálnych inovačných hubov v iných krajinách EÚ;
- Podpora sa vzťahuje aj na poradenstvo smerujúce k napísaniu a predloženiu žiadosti o financovanie.

Iniciačné aktivity:**

- Konzultácie a analýzy, ktoré umožnia MSP namapovať potenciál AI riešení na ich potreby pri výrobných, obslužných, obchodných a riadiacich procesoch;
- Realizácia krátkodobých experimentov, testovania a preverovania vhodnosti technológií (v zmysle konceptu *test before invest*).

Projektové aktivity*:**

- Financovanie projektov slovenských podnikov zameraných na umelú inteligenciu v rôznych oblastiach.

1.2.2 Internacionalizácia malého a stredného podnikania

Iniciačné aktivity*:

- Sprostredkovanie vedomostí o medzinárodne dostupných AI riešeniach slovenským MSP prostredníctvom Národného inštitútu pre umelú inteligenciu a digitálnych inovačných hubov alebo iným spôsobom;
- Podpora sa vzťahuje aj na vyhľadávanie vhodných projektových partnerov a zahraničných výskumných pracovísk;
- Podpora redizajnu produktov, respektíve obmena ich vybavenia tak, aby firma mohla atakovať nové typy zákazníkov a nové trhy;
- Pomoc pri získavaní certifikátov relevantných pre dané trhy; pritom ide o certifikáty firiem a produktov, ale aj o certifikáty expertov napríklad v oblasti kybernetickej bezpečnosti;
- Podpora pri náboe obchodných kapacít, pri ich zaškoľovaní a podľa možnosti aj pomoc s ich financovaním, kým nábeh obchodu nezabezpečí ich financovanie z predaja;
- Podpora obchodných a marketingových tímov pri nadväzovaní kontaktov na veľtrhoch a konferenciách, podpora členstiev v asociáciách a odborných združeniach;
- Podpora marketingových kampaní na cieľových trhoch, kofinancovanie sponzorstva konferencií, výroby doplnkových marketingových materiálov, brožúr a aktivít na sociálnych sieťach;
- Podpora sa vzťahuje aj na poradenstvo, konzultácie smerujúce k napísaniu a predloženiu žiadosti o financovanie.

Iniciačné aktivity:**

- Konzultácie a analýzy, ktoré umožnia MSP namapovať potenciál AI riešení zo Slovenska i zo zahraničia a ich potreby pri výrobných, obslužných, obchodných a riadiacich procesoch;
- Realizácia krátkodobých experimentov, testovania a preverovania vhodnosti technológií na medzinárodnej úrovni (v zmysle konceptu *test before invest*).

Projektové aktivity**:**

- Podpora zapájania slovenských MSP do projektov financovaných z priamo riadených programov.

1.2.3 Podpora sieťovania podnikateľských subjektov**Aktivity*:**

- Referenčné návštevy, informačné semináre, konferencie a workshopy v rámci Slovenska;
- Referenčné návštevy, informačné semináre, konferencie a workshopy mimo územia Slovenska;
- Prizývanie zahraničných konzultantov, spíkrov a expertov na akcie organizované na území Slovenska;
- Podpora AI portálu/portálov ako primárnej technologickej platformy pre sieťovanie slovenských podnikov, konzultantov, akademických pracovísk a riešiteľov, vrátane rozvoja portálu smerom viacjazyčnosti, integrácie s inými portálmi podobného typu a cezhraničnej spolupráci;
- Podpora odvetvovo alebo technicky koncipovaných platforiem a profesijných zoskupení zameraných na Industry 4.0, Internet vecí, kybernetickú bezpečnosť a iných platforiem, ktoré budú mať záujem participovať na podpore AI riešení.

1.3 Využívanie výhod digitalizácie pre občanov, podniky a vlády**1.3.1 Podpora rozvoja digitálneho a údajového hospodárstva a digitálna transformácia širšej ekonomiky, výskum, vývoj a aplikovanie moderných technológií s cieľom zvyšovať inovatívnu výkonnosť Slovenska a eliminovanie negatívneho dopadu digitalizácie na spoločnosť****Iniciačné aktivity**:**

- Konzultácie a analýzy, ktoré umožnia MSP namapovať potenciál AI riešení zo Slovenska i zo zahraničia a ich potreby pri výrobných, obslužných, obchodných a riadiacich procesoch;
- Realizácia krátkodobých experimentov, testovania a preverovania vhodnosti technológií na medzinárodnej úrovni (v zmysle konceptu *test before invest*).

Projektové aktivity*:**

- Financovanie EŠIF projektov slovenských podnikov v prioritných oblastiach digitálnej transformácie.

Projektové aktivity**:**

- Podpora zapájania slovenských MSP do projektov financovaných z priamo riadených programov.

2.1 Zvýšenie energetickej efektívnosti, podpora OZE a zníženie emisií skleníkových plynov

2.1.1 Zvýšenie energetickej efektívnosti a využívania OZE v podnikoch a zníženie energetickej náročnosti budov

Iniciačné aktivity:**

- Konzultácie a analýzy, ktoré umožnia MSP namapovať potenciál AI riešení zo Slovenska i zo zahraničia a ich potreby pri opatreniach na zvýšenie energetickej efektívnosti podnikov, respektíve efektívneho využívania OZE;
- Realizácia krátkodobých experimentov, testovania a preverovania vhodnosti technológií na medzinárodnej úrovni (v zmysle konceptu *test before invest*);

Projektové aktivity*:**

- Financovanie EŠIF projektov slovenských podnikov.

Projektové aktivity**:**

- Podpora zapájania slovenských MSP do projektov financovaných z priamo riadených programov.

1.4 Rozvoj zručností pre inteligentnú špecializáciu, priemyselnú transformáciu a podnikanie – ľudské zdroje pre inovatívne Slovensko a EÚ

1.4.1 Podpora kvality terciárneho vzdelávania orientovaného na pracovný trh

Aktivity:

- Vytváranie a implementácia programov spolupráce vysokých škôl s jednotlivými sektormi pre podporu inteligentnej špecializácie;
- Modernizácia vzdelávacej infraštruktúry vysokých škôl (zatraktívnenie podmienok štúdia najmä v študijných odboroch s nízkym počtom absolventov z pohľadu potrieb pracovného trhu pre potreby RIS-3);
- Posilnenie internacionalizácie vysokých škôl a medzinárodnej spolupráce;
- Pilotná príprava a implementácia širšieho spektra vysokoškolských študijných programov, vrátane vyššieho odborného vzdelávania a profesijne orientovaných bakalárskych študijných programov ako programov pre posilnenie adaptability v produktívnom veku;
- Zavedenie a využívanie inovatívnych (digitálnych a iných) metód v spôsobe vzdelávania (orientácia vzdelávania na študenta, rozvoj kompetencií v súlade s potrebami študenta),
- Programy na získavanie výskumníkov a vysokoškolských učiteľov;
- Tvorba a využívanie spoločných študijných programov medzi slovenskými univerzitami a zahraničnými univerzitami iných krajín EÚ, vrátane krajín v prístupovom procese a tretích krajín;
- Podpora programov mobility na podporu vysokých škôl zapojených do Európskej univerzity;
- Posilnenie financovania študijných odborov oblastí špecializácie RIS3 SK a oblastí, ktoré majú potenciál priniesť diverzifikáciu pre slovenské hospodárstvo, napr. IT oblasť, biotechnológie;

- Zvýšiť atraktivnosť sociálneho zabezpečenia študentov a materiálno-technického vybavenia univerzít so zameraním na študijné odbory pre oblasti špecializácie RIS-3 v záujme prevencie eliminácie ich odchodu;
- Zvýšiť atraktivnosť doktorandského štúdia;
- Podpora prevencie odchodu prostredníctvom zavedenia motivačných nástrojov pre študentov – napr. podnikových štipendií;
- Zavedenie jasných, transparentných a merateľných ukazovateľov kvality vzdelávacieho systému a jeho naviazanie na financovanie, najmä z pohľadu uplatniteľnosti absolventov vo vyštudovanom odbore.

1.4.2 Podpora ďalšieho vzdelávania v kontexte priemyselnej revolúcie 4.0 a inteligentnej špecializácie

Aktivity:

- Zvýšenie úrovne potrebných zručností pre inovatívnu a inteligentnú transformáciu hospodárstva SR;
- Príprava základných prvkov systému overenia potrebných zručností pre inovatívnu a inteligentnú transformáciu hospodárstva SR;
- Modernizácia materiálneho a technického vybavenia oprávnených vzdelávacích inštitúcií poskytujúcich overovanie kvalifikácií.

1.4.3 Podpora odborného vzdelávania a prípravy v kontexte priemyselnej revolúcie 4.0. a inteligentnej špecializácie

Aktivity:

- Prepojenie vzdelávania s potrebami trhu práce;
- Vzdelávanie pedagogických zamestnancov v oblasti práce s novými a modernými technológiami a zariadeniami;
- Podpora rozvoja vyššieho odborného vzdelávania na základe využitia skúseností dobrej praxe z duálneho vzdelávania;
- Podpora realizácie praktického vyučovania u zamestnávateľa, workshopov, stáží a pod.
- Pilotné overovanie prepojenia vyššieho odborného vzdelávania s prvým stupňom vysokoškolského vzdelávania;
- Pilotné overovanie podpory vstupu zamestnávateľov do počiatočného a ďalšieho profesijného vzdelávania učiteľov odborných predmetov a majstrov odbornej výchovy;
- Pilotné overovanie umiestňovania učiteľov odborných predmetov a majstrov odbornej výchovy na stáže do podnikov a firiem;
- Modernizácia materiálneho a technického vybavenia stredných odborných škôl.

1.4.4 Digitálne a podnikateľské zručnosti

Aktivity:

- Zadefinovanie a zapracovanie digitálnych kompetencií a zručností do všetkých štátnych a školských vzdelávacích programov;
- Zavedenie inovovaného systému vzdelávania v oblasti kybernetickej bezpečnosti;

- Vznik a podpora školení a praxe pre študentov, mladých podnikateľov a absolventov. S tým súvisiaca podpora kompetencií a digitálnych zručností mladých ľudí, ktoré vedú k vyššej bezpečnosti na internete pri používaní digitálnych technológií;
- Podpora vzniku systémov pre zavedenie a šírenie mediálnej gramotnosti na školách;
- Podpora systémov pre reformy výchovy a vzdelávania žiakov a študentov v zmysle kontinuálneho zvyšovania digitálnych kompetencií a zručností a personalizácie vzdelávania s využitím moderných digitálnych technológií;
- Vznik a podpora pilotných projektov pre šírenie dobrej praxe vo vzdelávaní ako napr. koncept podnikateľskej univerzity;
- Vznik a podpora projektov digitálnej transformácie vzdelávania a škôl na všetkých stupňoch vzdelávania;
- Projekty so zameraním na vnímanie dôležitosti digitálnej transformácie vzdelávania u rodičov, verejnosti, vo verejnej správe a prepojenie vzdelávania s podnikovou praxou;
- Podpora rozvoja digitálnych kompetencií a zručností v rámci celoživotného vzdelávania a s tým súvisiace vytvorenie podmienok pre priebežné flexibilné vytváranie vhodných interdisciplinárnych vzdelávacích programov na všetkých úrovniach vzdelávania;
- Podpora zvyšovania vyšších a špecializovaných zručností pre internet vecí (IoT), dátovú vedu, umelú inteligenciu, programovanie, pre potreby štúdií STEM, atď.;
- Podpora škôl v oblasti personálnych odborných kapacít (napr. „digitálny koordinátor“ po vzore iných krajín v EÚ);
- Projekty zamerané na rozvíjanie podnikateľského vzdelávania, vrátane cvičných firiem;
- Poskytovanie podpory vo forme domácich a/alebo zahraničných podnikových stáží;
- Inovačné workshopy na stredných a vysokých školách s cieľom prepojenia s podnikateľským sektorom;
- Hackathony a obdobné formy súťaží na stredných a vysokých školách za účasti odborníkov z praxe s cieľom riešenia regionálnych, ale aj celospoločenských výziev;
- Podpora aktivít vedúcich k zvýšeniu podielu žien v IT a digitálnom svete;

1.4.5 Digitálna koalícia – národná koalícia pre digitálne zručnosti a povolania Slovenskej republiky

Aktivity:

- Zabezpečenie kontinuálnej činnosti Digitálnej koalície;
- Podpora aktivít a projektov Digitálnej koalície, najmä so zameraním sa na prepájanie aktivít jej členov spolu s účelom popularizácie a podpory rozvoja digitálnych zručností;
- Aktívna podpora a plnenie záväzkov v Digitálnej koalícii zo strany ministerstiev a ich podriadených organizácií.

Príloha 1 Príklady riešení umelej inteligencie implementovaných autormi štúdie

A. Kooperácia medzi firmami

Výzva

Firmám na Slovensku chýbal nástroj na prehľadné vzájomnej kooperácie. Spolupráca je dnes najefektívnejším nástrojom na rýchly nárast konkurencieschopnosti, produktivity, flexibility, zníženia nákladov, získavania expertných služieb či riešenia problémov s nedostatkom špecialistov a aj bežných pracovníkov. Organizovaná spolupráca je najmä o úspešnej deľbe práce, špecializácii, unifikácii, efektívnej obchodnej výmene, zdieľaní zdrojov, technológií, voľných kapacít, *know-how*, obchodných kanálov, kontaktov, logistiky a podobne.

Spolupráca umožňuje rýchlu realizáciu inovácií a ich rýchle prenesenie do praxe, aby boli stále považované za inováciu. Predstavuje významný faktor tvorby synergií a znižovania podnikateľských rizík.

Riešenie

Vytvorenie kooperačného portálu www.spolupracuj.me. Portál má obvyklú podobu webstránky, na ktorej používatelia zadávajú svoje dopyty a ponuky. Štandardné vyhľadávanie pomocou kľúčových slov je rozšírené o technológiu neurónovej siete. Tá umožňuje portálu, aby sa na základe úspešne spárovaných dopytov a ponúk učilo, ako ponúknuť najlepšiu odpoveď.



Obrázok A 1 Logo portálu Spolupracuj.me

Ide o jednoducho použiteľný, ale komplexný nástroj na podporu podnikania vytvorený špeciálne pre potreby priemyselných firiem. Web slúži na hľadanie kooperačných prienikov a prepojenie firiem navzájom, ale aj na nadviazanie spolupráce firiem s konkrétnymi katedrami technických univerzít. Umelá inteligencia a prepracovaný systém spájania ponuky s dopytom šetrí čas a prináša nové možnosti

Funkcie portálu:

- **Opozitné ponuky, podobné ponuky a zhody** – portál páruje ponuky s dopytmi, notifikuje o tom používateľov (pozri Obrázok A 2);
- **Podstránka Výzvy a možnosť bezplatného posúdenia zámeru** – všetky priemyselné výzvy na jednom mieste, štruktúrované a prehľadné, pravidelná aktualizácia;
- **Možnosť bezplatného posúdenia potenciálu na superodpočet;**
- **Vyhľadávanie v portfóliu firiem** [Asociácie priemyselných zväzov](#) (ďalej aj „APZ“) – portál využíva informácie naprieč všetkými firmami združenými v APZ;
- **Pridaná informačná hodnota** – články z podnikateľského priemyselného prostredia.

Prínosy pre firmy

Efektívna kooperácia je mocným nástrojom pre rýchly nárast produktivity podnikov a podnikateľov na základe synergických efektov z dobre organizovanej spolupráce.

Po dlhých rokoch hľadania tu máme nástroj, ktorý môže výrazne zviditeľniť výskumno-vývojové kapacity a výskumnú infraštruktúru v Slovenskej republike a podporiť spoluprácu vo výskume a vývoji.

Na portáli môžu firmy ponúkať svoje produkty a služby, nájsť obchodného partnera či priestor pre ďalší rast. Firmám umožňuje riešiť aj praktické problémy, napríklad s dodávkami materiálu, služieb, aplikovaným výskumom, problémami vo výrobe a mnohé iné. Univerzitám a fakultám s technickým zameraním umožňuje ponúkať svoje kapacity a reagovať na konkrétne dopyty firiem.

Webový portál spolupracuj.me je akási virtuálna zasadačka, v ktorej môžete kontaktovať potenciálneho partnera, ktorý vás zaujme svojou ponukou alebo dopytom.

Používanie portálu:

- **Portál je verejný** – vyhľadávať a reagovať na ponuky či dopyty môže ktokoľvek (publikovať len registrované firemné profily);
- **Bezplatný prístup a vytvorenie profilu firmy** s neobmedzeným počtom firemných používateľov a publikovaných ponúk/dopytov;
- **Kontakty sa nezobrazujú**, aby sme zabránili spamu, kontaktovanie prebieha cez formulár;
- **Umelá inteligencia vo vyhľadávaní** a prepracovaný systém spájania ponuky s dopytom;
- **Jednoduchý nástroj, ktorý firmám šetrí čas i prostriedky** pri riešení každodenných podnikateľských výziev.

1. **Opozitné ponuky, podobné ponuky a zhody** – portál páruje ponuky s dopytmi, notifikuje o tom užívateľov



Výroba, obchod Zmeniť na výskum, vývoj, inovácie Úvod O portáli Referencie FAQ Kontakt Prihlásenie

Spolupracuj.me PONUKY DOPITY SPOLOČNOSTI ČLÁNKY MOJE KONTO

Ponuka • Portfólio služieb

Meteorologická stanica a meranie kvality ovzdušia

Zverejnené: 11.1.2019 Neobmedzená platnosť POSLAŤ MAILOM TLAČIŤ

EZE riešenie na meranie meteorologických hodnôt ovzdušia (teplota ovzdušia, vlhkosť ovzdušia aj rosným bodom a bodom mrazu, atmosférický tlak, solárna radiácia) prípadne iné meteorologické ukazovatele (zrážky, smer a rýchlosť vetra,...) alebo ukazovatele kvality ovzdušia (prach, CO₂, SO₂, NO₂, Benzén). Namerané veličiny sú zobrazené na prehľadnom portáli. Riešenie je využiteľné v rámci konceptu Smart city (inteligentné mesto) a Smart agriculture (inteligentné poľnohospodárstvo).

Mohlo by vás zaujímať

Stavak Telekom, s.r.o. Portfólio služieb

Meranie veličín prostredia (teplota, vlhkosť, CO₂, ...)

Meranie teploty, vlhkosti, CO₂, tlaku a iných potrebných hodnôt a prenos dát cez IoT sieť do prehľadného zobrazovacieho prostredia. Možnosť exportu a nastavenia notifikácií a alarmov.

ZOBRAZIŤ DETAIL PONUKY

ORANGE SLOVENSKO A.S.
Metodova 8, Bratislava
<https://www.orange.sk/>
CELÝ PROFIL

Kontaktovať spoločnosť

MENO
Zadajte meno...

SPOLOČNOSŤ
Zadajte vašu spoločnosť...

EMAIL

Obrázok A 2 Párovanie ponuky a dopytu

2. **Podstránka „výzvy“ a možnosť bezplatného posúdenia zámeru** – všetky priemyselné výzvy na jednom mieste, štruktúrované a prehľadne, pravidelná aktualizácia



Výroba, obchod Zmeniť na výskum, vývoj, inovácie Úvod O portáli Referencie FAQ Kontakt Prihlásenie

Spolupracuj.me PONUKY DOPITY SPOLOČNOSTI ČLÁNKY MOJE KONTO

ZDROJ FINANCOVANIA

- ☐ Európsky fond regionálneho rozvoja
- ☐ Európsky sociálny fond
- ☐ Štátny rozpočet
- ☐ Kohézny fond

SCHEMA POMOCI

- ☐ De minimis
- ☐ Schéma štátnej pomoci

OPRÁVNENÉ ÚZEMIE

- ☐ Bratislavský kraj
- ☐ Slovensko mimo Bratislavského kraja

OPRÁVNENÝ ŽIADATEĽ

- ☐ Fyzická osoba oprávnená podnikat' min. 36 mesiacov
- ☐ Právnická osoba oprávnená podnikat' min. 36 mesiacov
- ☐ Zamestnávateľ - podnikateľské subjekty
- ☐ Malé a stredné podniky
- ☐ Veľké podniky
- ☐ Organizácie štátnej správy
- ☐ Organizácie verejnej správy
- ☐ Mimovládne organizácie
- ☐ Neziskové organizácie
- ☐ Vysoké školy

Výzvy

Na jednom mieste tu nájdete pravidelne aktualizované výzvy na uchádzanie sa o finančné prostriedky z eurofondov. Zverejnené výzvy EÚ sú agregované zo stránok všetkých ministerstiev a iných štátnych inštitúcií.

Štátny rozpočet, kohézny fond

OPKZP-PO1-SC1M-2016-16

Výzva na predkladanie žiadostí o poskytnutie nenávratného finančného príspevku zameraná na prípravu na opätovné použitie a recykláciu nie nebezpečných odpadov. Oprávnené aktivity: A. Príprava na opätovné použitie nie nebezpečných odpadov, t.j.: Výstavba nových zariadení pre prípravu na opätovné použitie odpadov; B. Recyklácia nie nebezpečných odpadov, t.j.: Výstavba nových zariadení na recykláciu odpadov; C. Recyklácia odpadov z nebezpečných odpadov, t.j.: Výstavba nových zariadení na recykláciu odpadov z nebezpečných odpadov.

Oprávnený žiadateľ: Neziskové organizácie, Fyzické osoby, Právnické osoby, Subjekty územnej samosprávy

Celková suma: 12 500 000 €

Termíny: 28.02.2017 - 1. kolo, 30.06.2017 - 2. kolo, každé 4 mesiace - 3. až n-té kolo

Štátny rozpočet, kohézny fond

OPKZP-PO1-SC1M-2016-15

Špecifický cieľ 1.1.1 Zvýšenie miery zhodnocovania odpadov so zameraním na ich prípravu na opätovné použitie a recykláciu a podpora predchádzania vzniku odpadov. Výzva zameraná na prípravu na opätovné použitie a recykláciu nebezpečných odpadov. Oprávnené aktivity sú napr.: výstavba nových zariadení, nákup technológií a hmotných vecí pre prípravu na opätovné použitie alebo recykláciu nebezpečných odpadov. Oprávnenými žiadateľmi sú subjekty zo...

Oprávnený žiadateľ: Fyzické osoby, Právnické osoby, Subjekty územnej samosprávy

Celková suma: 12 500 000 €

Termíny: 15.02.2017 - 1. kolo, 15.06.2017 - 2. kolo, každé 4 mesiace - 3. až n-té kolo

Obrázok A 3 Informácie o možných zdrojoch financovania projektu

B. Analýza porúch pomocou umelej inteligencie

Výzva

Jedným zo základných nástrojov pri zlepšovaní údržby zariadení v podnikoch je zavedenie procesu analýzy vzniknutých porúch, hľadanie koreňovej príčiny (pomocou metodík 5 Prečo, Ishikawovho diagramu a pod.) a následne návrh a implementácia nápravných opatrení, aby sa v budúcnosti predišlo opakovaniu danej poruchy. Po zavedení týchto opatrení by sme navyše mali sledovať a vyhodnocovať, či dané opatrenia splnili účel a či boli skutočne efektívne.

Celý tento proces je však veľmi náročný a vyžaduje si, aby mu venovali čas tí najskúsenejší pracovníci. Z uvedeného dôvodu sa takýto proces zvykne implementovať len v tých najzávažnejších prípadoch. Zavedením systematického prístupu pri analýze porúch a dôsledným zavádzaním nápravných opatrení však dokážeme významne zvýšiť kvalitu a efektivitu prevádzky a údržby zariadení.

Vďaka softvérovej podpore v rámci informačného systému bolo možné dosiahnuť kontrolu nad celým procesom a aj vďaka využitiu umelej inteligencie minimalizovať náklady a prácnosť celého procesu.

Riešenie

1. Nahlásenie a zaznamenanie poruchy:

Nahlásenie poruchy prebieha na internetovom portáli, ku ktorému majú prístup zamestnanci prevádzky aj údržby (viď Obrázok B 1). Po zadaní popisu poruchy systém automaticky navrhne vhodnú kategorizáciu z číselníka porúch a pokúsi sa z textu identifikovať aj zariadenie na ktorom porucha vznikla. Zároveň prehľadá celú databázu a nájde podobné poruchy, ktoré vznikli v minulosti. Toto môže pomôcť zadávateľovi, ale aj riešiteľovi pri prvotnej analýze problému ako aj návrhu riešenia (napr. ak už v podniku tento typ poruchy v minulosti vznikol, je možné využiť skúsenosti kolegov, ktorí sa s ňou už stretli).

Obrázok B 1 Zadávanie poruchy formou požiadavky na opravu

2. Automatická identifikácia zodpovedného riešiteľa:

Všetky požiadavky sú systémom automaticky pridelené na základe definovanej matice zodpovednosti riešiteľovi, ktorému je zároveň zaslaný email so základnými informáciami o poruche.

3. Naplánovanie údržby a zaznamenanie vykonaných prác s nákladmi:

Zásah údržby je naplánovaný priamo v systéme, za čo zodpovedá riešiteľ. Zároveň sú v systéme sledované všetky náklady spojené s danou poruchou.

4. Automatické vyhodnotenie, či porucha spĺňa kritériá pre detailnú analýzu:

Systém automaticky vyhodnocuje, či boli splnené kritériá na detailnejšiu analýzu. V tomto prípade bol zvolený finančný limit na náklady spojené s opravou a pravidlo, že všetky poruchy, ktoré spôsobili výpadok vo výrobe, musia byť podrobne analyzované. Systém v takomto prípade riešiteľovi automaticky priradí novú úlohu na detailnú analýzu.

5. Analýza koreňovej príčiny a návrh nápravných opatrení:

Pracovník poverený tzv. posúdením udalosti musí vypracovať analýzu príčin a následkov. Systém ho tiež vyzýva na hľadanie koreňovej príčiny metódou 5 *Prečo*. Po zadaní možnej príčiny sa automaticky vytvorí nové vstupné pole s výzvou na zadanie dôvodu vzniku predošlej príčiny (pozri Obrázok B 2 Analýza koreňovej príčiny v systéme).

Vyplňte prosím všetky príčiny, ktoré by mohli viesť k vzniku udalosti:

Názov udalosti: **Poškodené hriadeľe**

Popis udalosti: Na hriadeľi k obracačke HK01 za prepravnikom došlo k úplnej destrukcii hriadeľa. Po privolaní pracovníka údržby už bola odastavená celá linka, pričom bolo nutné vymeniť nie len samotný hriadeľ ale celú ozubnicu s prevodovkou, nakoľko ulomená hriadeľ zablokovala aj ostatné

Analýza príčin:

- Kategória: zariadenie \ poškodený prvok, diel
 Popis: poškodený spodný hriadeľ
- Kategória: materiál \ chyba materiálu
 Popis: degenerované ložisko
- Kategória: človek \ nedodržanie postupov obsluhy
 Popis: preťaženie zariadenia
 - Prečo došlo k „preťaženie zariadenia“?
 Skúste sa zamyslieť či táto príčina nemôže mať hlbšie príčiny
 - Kategória: človek
 Popis: Prekročenie povolených otáčok
- Kategória: prostredie \ znečistenie, nánosy
 Popis: Zanesené ložisko
- Kategória:
 Popis:

Súvisiaca udalosť

Pridať podpríčinu Pridať alternatívnu príčinu Označiť za koreňovú Odstrániť

Obrázok B 2 Analýza koreňovej príčiny v systéme

Pracovník následne označí jednu z príčin za koreňovú. Na dokončenie posúdenia je tiež nutné navrhnúť nápravné opatrenia.

Systém nepovažuje úlohu za dokončenú bez toho, aby bola identifikovaná koreňová príčina, pričom je nutné mať zadané aspoň 2 ďalšie – sekundárne či alternatívne príčiny.


Zároveň musí byť zadané aspoň jedno nápravné opatrenie, ktoré rieši koreňovú príčinu.

6. Schvaľovanie analýzy a opatrení:

Po vypracovaní analýzy je výsledok automaticky odoslaný ďalším pracovníkom na schválenie. Zoznam pracovníkov je dynamicky vyhodnotený na základe typu poruchy či zariadenia, v princípe však ide o zástupcov údržby, prevádzky a pracovníkov zodpovedných za bezpečnosť.

Významným zjednodušením je v tomto prípade možnosť schváliť posúdenie priamo tlačidlom z emailu. V texte emailu je pritom opísané dané posúdenie, identifikované príčiny a navrhnuté opatrenia. V prípade zamietnutia je pracovník vyzvaný na zadanie zdôvodnenia a analýza je vrátená pôvodnému riešiteľovi na dopracovanie (pozri Obrázok B 3).

Posúdenie je považované za schválené až keď ho verifikujú všetci zainteresovaní pracovníci (ich zoznam sa dynamicky a prípad od prípadu mení podľa dohodnutých pravidiel).



Obrázok B 3 Schvaľovanie posúdenia z mobilného telefónu

7. Pridelenie riešiteľov zodpovedných za realizáciu opatrení a sledovanie termínov

Pre každé opatrenie je možné určiť zodpovedného pracovníka. Systém im následne po schválení posúdenia prideli úlohu a sleduje plnenie termínov. V prípade blížaceho sa omeškania pracovníka

upozorní a následne mu pravidelne zasiela zoznam zameškaných úloh (formou zoznamu v jednom e-maile).

V prípade, že realizácia opatrenia pozostáva z prác údržby sú tieto činnosti previazané s opatrením a opatrenie je automaticky označené za vyriešené po dokončení všetkých súvisiacich prác. Ak ide o opatrenie organizačného charakteru (napr. zmena prevádzkových inštrukcií a pod.), je nutné označiť ho za realizované manuálne.

Úloha je považovaná za splnenú, až keď je jej splnenie zaznamenané v systéme.

8. Automatické sledovanie efektívnosti opatrení

Akonáhle sú všetky opatrenia označené za vyriešené, na pozadí sa spustí monitoring, ktorého úlohou je identifikovať, či nedošlo k opakovaniu danej poruchy. Opatrenia sú automaticky označené za efektívne v prípade, že v priebehu jedného roka nedošlo k opakovaniu danej poruchy. V prípade, že v systéme bola identifikovaná porucha, ktorá je príliš podobná (skóre podobnosti je >80 %), systém automaticky vygeneruje úlohu na posúdenie efektívnosti opatrení. Po zobrazení detailu úlohy je pracovníkovi ponúknutý zoznam podobných porúch. Finálne rozhodnutie je tak na odborníkovi, avšak ten nemusí sledovať stovky porúch mesačne, aby zistil, či sa daná porucha nezopakovala. Monitoring za neho vykoná systém pomocou umelej inteligencie a pracovníka vyzve na zásah len v prípade, že existuje dôvodné podozrenie. Zásadne sa tým eliminuje množstvo práce, ktoré by musel pracovník vykonať. Namiesto stoviek porúch, ktoré by za normálnych musel prečítať a porovnať, systém pracovníkovi ponúkne už len jednotky záznamov ročne.

SK Bezděk Juraj 2

← Späť
Uložiť

PU: Vyhodnotenie efektívnosti opatrenia
 Úloha číslo: 0000043

Popis úlohy: Po vyriešení nápravných opatrení poruchovej udalosti "Porucha zariadenia na Klimatizácia_745" (0000001261/UDA) boli identifikované podobné poruchy. Zhodnotte prosím, či boli opatrenia efektívne. Opatrenia sa považujú za efektívne vtedy, ak zamedzili vzniku rovnakej poruchy na zariadeniach, na ktorých boli aplikované.

Riešiteľ: Bezděk Juraj 2

Typ úlohy: PU: Vyhodnotenie efektívnosti opatrenia

Pripomenúť pred termínom:

Termín: 30. 12. 2019

Názov udalosti
 Porucha zariadenia na Klimatizácia_745

Číslo udalosti
 0000001261/UDA

Popis udalosti
 klima neklímuje, len zápacha po plesni

Popis poruchy, ktorá bola posudzovaná

Podobné poruchy ktoré po vyriešení opatrenia vznikli (automaticky identifikovala umelá inteligencia)

Miera podobnosti	Dátum	Číslo udalosti	Názov udalosti	Prejav poruchy	Popis poruchy	Objekt
90,2	22.10.2019	0000001259/UDA	Porucha zariadenia na Klimatizácia_745	Poruchy\Časť objektu\B: budovy a stavby\bleskozvody, uzemnenie	klima klimuje ako ma, ale nekuri	
82,7	22.10.2019	0000001260/UDA	Porucha zariadenia na Klimatizácia_745	Poruchy\Časť objektu\B: budovy a stavby\vzduchotechnika, klimatizácia	klimatizácia smrdí	

Opatrenia, ktorých efektívu posudzujeme

Pre príčinu	Číslo	Názov	Popis	Stav	Dátum vyriešenia
Neboli nastavené pravidlá (človek/nedodržanie postupov údržby)	0000001261/UDA/1	Nastavenie pravidelnej údržby	Nastaviť plánovanie na pravidelnú údržbu klimatizácií v budove. Bolo zabudnuté	Realizované	18.12.2019

Rozhodnite prosím, či boli opatrenia efektívne

Opatrenia BOLI efektívne

Opatrenia NEBOLI efektívne

Finálne rozhodnutie, je na odborníkovi (treba zvážiť ďalšie okolnosti)

Obrázok B 4 Vyhodnocovanie efektívnosti opatrení na základe výskytu podobnej poruchy

Využitie umelej inteligencie

Pre realizáciu tohto riešenia malo využitie umelej inteligencie zásadný význam. Systém poruchy neporovnáva na základe číselníka porúch, či na základe zhody kľúčových slov (takéto technické riešenie sa ukázalo byť nedostatočné, nakoľko poruchy boli v praxi nesprávne kategorizované a texty porúch obsahovali veľa preklepov a tie isté poruchy boli formulované s využitím rôznych slov).

Využitie umelej inteligencie pri analýze textov nielen napomohlo pri kategorizácii poruchy počas zadávania do systému, ale predovšetkým identifikovalo podobné poruchy, vďaka čomu bolo možné zaviesť takmer automatické vyhodnocovanie efektívnosti opatrení (poloautomatické riešenie sa zvolilo z dôvodu, aby človek – odborník mal i naďalej posledné slovo, ale aj z dôvodu zlepšovania modelu, keď vďaka spätnej väzbe od odborníka sa umelá inteligencia dokáže ďalej učiť a zdokonaľovať).

Výsledný model je odolný voči preklepom a dokáže identifikovať podobné poruchy aj v prípade, že sú formulované úplne inými slovami. Dokáže zachytiť nielen zhodu významov slov, ale v obmedzenej miere aj podobnosť javov, ktoré sú v texte opísané.

Zásadnou výzvou pri implementácii bol fakt, že opisy porúch boli v slovenskom jazyku, navyše obsahovali veľké množstvo preklepov, slangových výrazov, skratiek a špecializovaných termínov, ktoré poznali len špecialisti z daného podniku.

Pri implementácii bol preto použitý model natrénovaný najskôr na väčšom objeme dát, ktorý však bol všeobecnejší (t. z., že obsahoval rôzne technické texty z verejne dostupných zdrojov) a následne bol „dotrénovaný“ na konkrétnych dátach zákazníka. Vďaka tomu bolo možné dosiahnuť výrazne vyššiu presnosť, než pri využití bežne dostupných komerčných riešení.

Založenie požiadavky

Nová požiadavka

Názov:

Vybavenie:
 Myslíte VZV - Manitou MC30 [# 182405533]?

Prejav:
 Myslíte iné čiastočné zlyhanie?

Popis problému:

Podobné poruchy Podobné poruchy, ktoré našla umelá inteligencia Skóre podobnosti

Micromotion č.1001 vypadáva 77%

Miera podobnosti: 77%
 Číslo udalosti: 24348
 Vybavenie: #3087
 Prejav: iné čiastočné zlyhanie
 Popis problému: Micromotion č.1001 vypadáva (jedná sa o elektronickú závalu-lebo prietok 2MBT je, iba ho neukazuje-jedná sa o pár sekúnd-potom to zas nabehne a je to v poriadku) info u pána ŠIMKA

VJEaS, vzv náj. 77%

Miera podobnosti: 77%
 Číslo udalosti: 20862
 Vybavenie: #182410122
 Prejav: iné čiastočné zlyhanie
 Popis problému: Náhradný vzv - s majákom : niekedy po vyúnutí motora nejde naštartovať 1-2 hod, niekedy po naštartovaní ide len na voľnobežné otáčky - po pridaní zhasne , je nespohľadlivý zrevidovať !

VJEaS, vzv náj. 42 77%

Miera podobnosti: 77%
 Číslo udalosti: 22769
 Vybavenie: #182410122
 Prejav: nefunguje
 Popis problému: motor zle štartuje a po naštartovaní po cc 20 sekundách zhasne

Obrázok B 5 Podobné poruchy sú nájdené okamžite, už počas zadávania popisu problému

Prínosy

Zníženie administratívnej záťaže

Takmer okamžitým prínosom zavedenia tohto systému bolo zníženie administratívnej záťaže. Predtým bol proces postavený na vyplňaní formulárov a tabuliek, ktoré bolo treba vytlačiť a nechať popísať, elektronizáciou sa ušetril čas pracovníkov a významne skrátila stredná doba riešenia udalosti z priemerných 30 dní na 2 dni.

Navyše sa eliminovali prípady, kedy analýza z rôznych dôvodov ani nebola riadne dokončená, pretože pracovník na ňu zabudol, nestihol ju vykonať a pod.

Zvýšenie transparentnosti

Po zavedení procesu si zainteresovaní pracovníci pochvaľovali transparentnosť. Tým, že boli údaje dostupné na jeden klik a boli prehľadne zobrazené v systéme, pracovníci boli o všetkých významných udalostiach automaticky notifikovaní a taktiež sa zlepšila všeobecná informovanosť o stave riešenia a detailoch.


Zníženie poruchovosti pri opakovaných poruchách

Vďaka automatickej identifikácii opakujúcich sa porúch a vyhodnocovaniu efektivity opatrení je omnoho jednoduchšie identifikovať opakované poruchy a venovať im náležitú pozornosť. Ak sa porucha opakovala a boli prijaté opatrenia, je zjavné, že buď bola zle identifikovaná koreňová príčina, alebo boli prijaté nevhodné či neefektívne opatrenia. Pre exaktné vyhodnotenie prínosov v tejto oblasti, žiaľ, nemáme dostupné údaje o opakovaných poruchách pred zavedením riešenia, avšak po zavedení systému sa už opakované poruchy vyskytujú len výnimočne.

Zavedením schvaľovacieho a pripomienkovacieho procesu sa tiež významne zvýšila kvalita vykonaných posúdení a prijatých opatrení.

Identifikácia problematických oblastí

Vďaka tomu, že systém má k dispozícii nielen údaje o poruchách, ale aj súvisiace náklady, je možné identifikovať poruchy, ktoré stoja podnik najviac peňazí. Táto analýza nie je pritom postavená na číselníku porúch. Ten zvyčajne nie je dostatočne podrobný a nedokáže zachytiť drobné rozdiely medzi poruchami v danej kategórii. Systém sa nespolieha len na kategorizáciu, ale pri analýze využíva aj texty samotných porúch a javov v nich opísaných. Umelá inteligencia dokáže analyzovať všetky tieto poruchy v priebehu minút a automaticky zostaviť kategórie porúch, ktoré sú si veľmi podobné. Následným prepojením s údajmi o nákladoch je možné zostaviť prehľad porúch, ktoré stoja podnik najviac peňazí. Týmto oblastiam treba venovať zvýšenú pozornosť.



Obrázok B 6 Identifikácia problematických oblastí

Uchovanie a zdieľanie znalostí

Nezanedbateľným efektom zavedenia systému je tiež uchovanie znalostí a skúsenosti ohľadom riešenia porúch – a to nielen vo forme záznamu o tom, že došlo k poruche, ale aj vrátane detailov, spôsobu uvažovania pri analýze koreňovej príčiny, pripomienok kolegov, atď. Tieto znalosti navyše nečakajú, kým ich niekto objaví, ale sú aktívne využívané. Pri vzniku poruchy systém dokáže zistiť, či sa s danou poruchou už v podniku niekto nestretol. V prípade, že sa nájde podobná porucha, môže si daný pracovník zobrazíť detaily o tom, ako danú poruchu v minulosti riešili, aké boli prijaté opatrenia, či boli efektívne, atď. Tiež vidí, kto sa danej poruche venoval a môže ho priamo kontaktovať. Vďaka tomu je možné čerpať zo skúseností kolegov, ktorí sa s daným problémom už stretli.

C. Anonymizovaný príklad (marketing a podpora predaja)

Výzva

Slovenská pobočka nemenovanej medzinárodne pôsobiacej spoločnosti v chemickom priemysle poskytuje globálne služby podpory obchodu a marketingu využívajúce technológie strojového učenia a umelej inteligencie.

Firma má nesmierne veľké portfólio chemických produktov. Ide rádovo o desiatky tisíc produktov, ktoré predáva v desiatkach krajín sveta. Obchod spoločnosti a výroba sú riadené na základe mnohých faktorov (napr. ročné obdobie, sezónne závislá produkcia, geografická závislosť, atď.). Databáza predaja obsahuje obrovský zoznam historických predajných transakcií po celom svete. Globálna konsolidácia dát z jednotlivých krajín a ich kvalita sú na vysokej úrovni. Obchodníkov zaujíma, čo majú ponúknuť konkrétnemu odberateľovi v určitom období roka tak, aby ponuka bola pre neho čo najrelevantnejšia.

Pred vznikom riešenia prišla otázka:

Je možné využiť existujúce big data ako vstup pre algoritmy, ktoré by vedeli podporiť obchodníkov v ich práci?

Pritom cieľom bolo zohľadniť i správanie podobných odberateľov v iných štátoch či na iných kontinentoch.

Riešenie

V princípe išlo o implementáciu riešenia u zákazníka, ktoré zlepší výkonnosť marketingu a predaja s použitím strojového učenia založeného na štatistike (*machine learning based on frequent pattern mining*).


To znamená, že zákazník má záujem využiť dáta, ktoré vlastní, na zefektívnenie budúceho obchodu. Na dosiahnutie tohto cieľa bolo vytvorené *end-to-end* riešenie na kľúč. Podmienkou zákazníka bolo využitie len *opensource* technológií. Výsledný nástroj je vo forme kontajnera v Docker-i využívajúceho technológie *Apache Spark* a *MLlib – Spark's scalable machine learning library*. Tento nástroj je schopný spracovať vložené dáta a vytvoriť customizovanú ponuku produktov pre najvhodnejších potenciálnych zákazníkov a zvýšiť objem budúceho predaja.

Na spracovanie dát bol použitý *FP growth* algoritmus, ktorý patrí do kategórie *frequent pattern mining* algoritmov, podkategória *pattern growth*. To znamená, že hľadáme opakujúce sa vzory v dátach a vzor je vyhlásený za častý len v prípade, ak jeho výskyt prekročí určitú minimálnu hranicu. Táto sa zadáva priamo používateľom na základe toho, aký výsledok potrebuje dosiahnuť. Výstupom je určitý súbor pravidiel, ktoré nám ukazujú pravdepodobnosť nákupu konkrétneho produktu na základe doteraz zaznamenaného nákupného správania odberateľov.

Prínosy pre zákazníka

Pre danú spoločnosť ako zákazníka sú veľmi zaujímavé hlavne tie výsledné pravidlá, ktoré ponúkajú produkty z úplne iných kategórií a podkategórií produktového portfólia. Tieto pravidlá dokážu identifikovať potenciálneho zákazníka z úplne iných segmentov, než v akých aktuálne obchoduje. Vznikajú tak obchodné príležitosti tzv. *Cross-selling*. K tým by sa s najväčšou pravdepodobnosťou totiž konvenčnými metódami nepodarilo dopracovať. Obchodníci medzi jednotlivými segmentami

nedokážu efektívne spolupracovať a zdieľať svoje portfólia zákazníkov. Na diagrame nižšie (pozri Obrázok C 1 Obrázok B 4 Akordový diagram výsledných pravidiel) AP.APY.APG a AP.APY.APF alebo AP.APY.APH a AP.APY.APF (názvy sú ilustračné).



Obrázok C 1 Akordový diagram výsledných pravidiel

D. Anonymizovaný príklad (podpora predaja, reporting)

Výzva

Základným parametrom pre udržateľný rozvoj v každej firme sú správne rozhodnutia. Rozhodnutia o nákupe, predaji, skladových zásobách, zamestnancoch ako aj marketingových kampaniach či otázka expanzie firmy. Kombinácia dostatočného množstva dát a hlavne ich kvality je základný predpoklad pre získanie správnych informácií, ktoré sú základom pre firemné rozhodnutia.

K tomu, aby sme predpoklad pretavili do reality, potrebujeme vybrať vhodný analytický nástroj, tzv. *business intelligence*, ktorý dokáže veľký objem dát nielen zozbierať, ale aj spojiť, spracovať a poskytnúť okamžité výstupy v podobe informácií pre manažérov malých i stredných podnikov.

Realitou je, že väčšina firiem stále používa na tento proces Excel, čo je síce výborný nástroj, ale pre spracovanie veľkého objemu dát dnes už nepostačujúci. Ekonomika čelí novej výzve, ktorou je digitalizácia a s ňou prichádza extrémne množstvo dát a ich rôznorodosť. Dnes veľké i malé firmy testujú možnosti umelej inteligencie, špeciálne strojové učenie známe ako *machine learning* je už realitou.

Kým človek stráca prehľad pri veľkom objeme dát, na druhej strane stroj to miluje – čím viac dát získa na učenie, tým kvalitnejšie odporúčania či rozhodnutia dokáže poskytnúť. A tu je naša príležitosť – využiť veľké množstvo dát a zaviesť pokročilé analytické techniky ako napr. *machine learning* aj do prostredia slovenských podnikateľov. Samozrejme, nie je to krátkodobá záležitosť, ale stratégia na najbližšie roky.

Nemenovaná spoločnosť je sieť maloobchodných predajní v oblasti chovateľských potrieb a krmív nadštandardnej kvality, ako aj živých zvierat.

Riešenie

Čo bolo potrebné spraviť na začiatku?

Na úvod sme potrebovali identifikovať všetky dátové zdroje, ktoré používajú a vybrať vhodný spôsob pre zber týchto dát. Požiadavka bola začať ERP dátovým zdrojom, kam prichádzajú dáta z POS terminálov, skladov, zamestnancov, dodávateľov i odberateľov.

Ako prvé sme riešili dátový mostík medzi ERP a našou synchronizačnou logikou *Jarvis*, ktorý sa dokáže napojiť na *endpoint*, na ktorom sú umiestnené dáta, prečítať ich a uložiť do dátového skladu alebo cloudu. Cieľom bolo odľahčiť firemnú ERP od ukladania i spracovania dát, pretože k tomu nie sú navrhnuté a častokrát obyčajný export trvá dlho, nehovoriac, ak chcete vytiahnuť historické dáta. Ak máte dáta vo *warehouse* alebo v cloude mimo ERP, dokážete akýkoľvek report spraviť do pár minút, nastaviť práva zobrazovania podľa citlivosti dát i možnosť ďalej využiť dáta napríklad na spomínaný *machine learning*.

Po nastavení dátového mostíka sme zozbierali všetky dáta danej spoločnosti týkajúce sa predaja, skladov a produktov za posledné 3 roky. Pre lepšiu predstavu – v rámci predaja ide o viac ako 5 miliónov záznamov ročne a v rámci skladových stavov okolo 0,5 milióna záznamov denne.

Naším cieľom je dáta ukladať na dennej báze ako snímku z konkrétneho dňa, takže v prípade skladov je vzorec: počet zalistovaných produktov X počet predajní ako denný záznam, ktoré sa historicky ukladajú.

Pri objeme dát za 3 roky v každej firme narážame na:

- Chybovosť: pri zápisoch prirodzene dochádza k preklepom;
- Chýbajúce dáta, prázdne polia v tabuľkách databázy predaja, produktov i skladov – najmenej vyplnené bývajú charakteristiky produktov (značka, kategória, dodávateľ, rok, sezóna, farba, atď.);
- Duplicitu názvov, nesprávnu diakritiku.

Dôležitým krokom po zbere dát je spraviť **Data Audit** – identifikovať dátové nedostatky, odstrániť chyby, prečistiť a normalizovať dáta. Aby sme nezostali len pri vytvorení takzvaného „stavu 0“, musíme optimalizovať aj procesy vo vnútri firmy tak, aby aj novovzniknuté záznamy spĺňali požiadavky zadefinované v smernici o dátovej kvalite.

Odporučili sme firme doriešiť *category management*. Začínali sme s kategorickým stromom, ktorý obsahoval 70 skupín (15 hlavných kategórií rozvinutých o úroveň nižšie) a postupne si klient zadefinoval 450 produktových skupín (15 hlavných kategórií rozvinutých až do piatej hĺbky). V tomto kroku je potrebná súčinnosť klienta i ERP poskytovateľa, čo sa nám v prípade tejto firmy podarilo. Výsledkom je výborne nastavená kategorizácia produktov a výborná datakvalita.

Keď máme dáta zozbierané a zvládnutú datakvalitu, môžeme prejsť na proces spracovania dát. Ide o spájanie tabuliek v databáze prostredníctvom unikátnej hodnoty na jednej strane a N hodnôt na strane druhej. Tým zabezpečíme, že dáta z viacerých zdrojov, viacerých databáz i viacerých tabuliek budú vzájomne prepojené a pri reportovaní dát vieme poskytnúť ucelený pohľad.

Vieme zistiť, aké produkty sa predali, pri akej cene, v akom čase, v akej predajni, pri akej zľave, z ktorej skupiny, akému zákazníkovi, pri akom stave na sklade, pri akej obrátke, pri akom zisku, atď. Aby sme tieto informácie mali v jednom zobrazení, na pozadí musíme spojiť viaceré zdroje. Na toto sú primárne určené ETL nástroje. Predstavuje skratku, ktorá charakterizuje celý proces *Extract – Transform – Load*. Teda „*extrahuj dáta z rôznych zdrojov (Extract), pospájaj ich podľa definovaných pravidiel, prípadne inak spracuj (Transform) a posuň výsledok na ďalšie spracovanie (Load)*“.

Spracované dáta pre túto spoločnosť sa zobrazujú cez reporting prostredníctvom webového rozhrania. Momentálne nástroj používa vedenie spoločnosti a ich regionálni manažéri. Reporty vedia sledovať nielen v kancelárii, ale aj priamo v teréne.

Dosiahli sme okamžitý prístup k informáciám na dennej báze, nakoľko dáta zozbierame vždy v noci po uzávierke, spracujeme a poskytneme do reportingovej aplikácie. Užívatelia majú reporty už preddefinované, takže zobrazené dáta sú vždy správne, nakoľko nie sú potrebné žiadne reportovacie vzorce či tvorba vizuálov.

Reporty sledujú na úrovni jednotlivých predajní stavy predaja za konkrétne obdobie, alebo vývoj predaja v čase za obdobie od hodiny až po mesiace na úroveň jednotlivých predajní až po celú sieť. Dôležitým reportom sú KPI ukazovatele, ktorými sme výrazne spresnili počítanie transakcií, priemerného košíka i priemernej predajnej ceny produktov na jednotlivé predajne. V minulosti počítali KPI zo všetkých transakcií, čiže aj zo storno položiek. Je to normálny stav každého klasického ERP softvéru. Naším cieľom sú však presné dáta, takže tieto storno položky sme odfiltrovali a zobrazili správne KPI hodnoty.

Rýchlosť, presnosť a správnosť poskytnutých informácií je zabezpečená, takže ďalším krokom bolo vytvoriť pokročilejšie analýzy, ktoré potrebuje spoločnosť sledovať. Ako príklad sme riešili report pre spotrebu, úhyn a expiráciu tovarových skupín alebo vyhodnocovanie akciových kampaní.

V prípade reportu pre spotrebu, úhyn a expiráciu sme s ERP poskytovateľom zadefinovali dátový typ tohto pohybu, aby sme ho vedeli identifikovať spomedzi všetkých pohybov a aby tento pohyb nevstupoval do predaja, takže vieme presne určiť, v akej hodnote, na akej predajni, v akom čase, aké produkty sa spotrebovali. Cieľom bolo zefektívniť procesy a náklady v rámci jednotlivých predajní.

V prípade vyhodnocovania akciových kampaní sme vytvorili report na mieru, v ktorom si používateľ reportu vyberie ľubovoľný čas a vo výstupe reportu sa zobrazia iba predaje akciových produktov vo vybranom termíne v porovnaní s obdobím pred a po akcii. Report sa zobrazí v jednom vizuále, takže používateľ si môže porovnať úspešnosť jednotlivých akciových kampaní okamžite, bez vytvárania X tabuliek a ich párovania v Exceli alebo inom tabuľkovom programe.

Prínosy pre zákazníka

Vďaka tomuto procesu sme dosiahli jednotné informácie naprieč celou firmou, *single source of truth*, pre potreby firemných rozhodnutí. Vieme rýchlo, jednoducho a zrozumiteľne zobrazíť informácie z dát, ktoré spoločnosť potrebuje k dennodenným rozhodnutiam.

Najbližší cieľ je nastaviť kvalitný vernostný program – nielen zber dát o zákazníkoch, čo je dnes bežné – ale hlavne poskytovať ciele informácie na základe segmentácie zákazníkov danej spoločnosti. Plánujeme spustiť model RFM analýzy, v ktorej zákazníkov dokážeme segmentovať do 11 skupín podľa ich posledného nákupu, frekvencie historických nákupov a výšky platieb jednotlivých nákupov, ktoré zákazník realizoval. Vďaka tomu dokážeme identifikovať TOP zákazníkov, verných, potenciálne verných, *sleepers*, *churners*, cenovo senzitívnych i stratených zákazníkov. Následne tieto skupiny sa oslovia rôznymi marketingovými kampaňami, aby zákazník cítil starostlivosť podľa jeho preferencií.

Zároveň kladieme dôraz na pokročilú analytiku a potrebu zaviesť *machine learning*.


Najbližšie výzvy sú:

- Segmentácia zákazníka a nastavenie cielenej reklamy na konkrétnu skupinu zákazníkov;
- Navrhnuť pre klienta model predikcie predaja, napr. správne nastavenie marketingovej kampane, ako správne namodelovať produktový mix pre akcie, aké ceny zvoliť pre maximálny efekt kampane;
- Analýza nákupného košíka – dnes poznáme hodnotu priemerného košíka, priemerný počet položiek košíka a vieme odhaliť korelácie medzi kategóriami a medzi produktmi.

E. Anonymizovaný príklad (marketing)

Výzva

Výzvou, ktorá stála pred zákazníkom bolo dosiahnuť čo najväčšiu mieru automatizácie marketingových procesov. Schéma zobrazená na obrázku (Obrázok E 1) zachytáva štandardný model marketingovej automatizácie a jej najdôležitejšie procesy. Žltou sú zvýraznené vstupné dáta, ktoré môžu byť buď historické alebo zbierané v reálnom čase. Zelenou sú zvýraznené zložky obsiahnuté v softvéri pre marketingovú automatizáciu. Modrou je označený výstup zo systému smerom k zákazníkovi či používateľovi. Na jednotlivé zložky a procesy sa v tomto príklade detailne zameriame.



Obrázok E 1 Štandardný model marketingovej automatizácie

Riešenie

V tomto texte budeme hovoriť o prvkoch umelej inteligencie, ktoré sú zabudované alebo vstavané do systému, ako je *SAP Marketing Cloud* a teda nie je potrebný ďalší vývoj. Môžeme povedať, že ide o *End-to-End* riešenia na kľúč vrátane vlastností platformy. Práve tá platforma, na ktorej je riešenie dodávané, umožňuje ďalšie rozšírenie systému vrátane rozsiahlej knižnice API pre prípadnú integráciu do systémov tretej strany. Neoddeliteľnou súčasťou produktu je tiež BI platforma pre vizualizáciu dát a tvorenie interaktívnych dashboardov *SAP Analytics Cloud*.

Softvér pre marketingovú komunikáciu

Jadrom celého automatizačného procesu je softvér, ktorý sa stará o vykonávanie automatizačných činností. Môže ísť o softvér vyvinutý na mieru pre účely konkrétnej spoločnosti alebo častejšie o

softvérovú platformu vyvinutú externou spoločnosťou, ktorá ju následne licencuje ďalším firmám, teda používateľom platformy.

Softvérová platforma obsahuje komponenty, ktoré sú schopné vytvárať automatizované pravidlá. Tieto komponenty na základe vstupu vykonávajú určitú akciu, teda výstup smerujúci k zákazníkovi. Pod vstupom máme na mysli vstupné dáta definované vyššie. Ak vstupné dáta nadobudnú určitú hodnotu definovanú v softvéri, pôsobia ako tzv. spúšťač, ktorý spustí automatickú úlohu. Ako základný príklad si môžeme predstaviť situáciu, v ktorej máme uložené dáta so zákazníckymi detailmi ako je meno, e-mailová adresa, pohlavie, dátum narodenia a pod. V momente, keď sa deň a mesiac narodenia zákazníka bude zhodovať s aktuálnym dňom a mesiacom, spustí sa automatizované pravidlo pre zaslanie prania k narodeninám.

Vstupné dáta

Dáta sú kritickou súčasťou marketingovej automatizácie a všetky nadväzujúce procesy sú úzko späté s ich množstvom a kvalitou. Spoločnosti dnes zbierajú obrovské množstvo dát, ktoré ich zákazníci generujú. Najčastejšie ide o dáta získané z digitálneho prostredia, ako sú návštevy webových stránok, stiahnutia mobilných aplikácií či interakcia na sociálnych sieťach. Môže však ísť aj o dáta získané z reálneho sveta, ako napríklad návštevnosť fyzickej pobočky obchodu, účasť na veľtrhu a pod. Veľký význam dát v marketingu charakterizuje pojem *data driven marketing*, čiže marketing poháňaný dátami.

Druhou skupinou sú aktuálne dáta. Ide o údaje, ktoré zbierame kontinuálne v prítomnosti. Oproti uloženým dátam je ich najväčšou odlišnosťou to, že môžu niesť informácie nielen o konkrétnych zákazníkoch, ku ktorým máme k dispozícii historické dáta, ale aj informácie o používateľoch, ktoré nie sme schopní identifikovať. Typickým príkladom sú dáta zozbierané na webových stránkach spoločností. Pri všetkých návštevníkoch môžeme merať, aký dlhý čas na stránkach trávia, aké príspevky či produkty si prezerajú, aké zariadenie k tomu používajú alebo kde sa nachádzajú. Takéto správanie je však často z hľadiska spoločnosti anonymné až do chvíle, kým sa zákazník napríklad prihlási do svojho používateľského profilu. Ak sme takéto dáta schopní priradiť ku konkrétnemu zákazníkovi, v momente, keď stratí svoju aktuálnu povahu, stávajú sa z nich dáta uložené alebo dáta historické.

Pri využití systému *SAP Marketing Cloud* sme sa snažili zodpovedať veľmi jednoducho definovanú obchodnú otázku: „Ako je pravdepodobné, že definované percento mojich zákazníkov odíde v budúcom časovom období?“ (*Churn*). Pre vyriešenie tejto úlohy ako prvé spustíme integrované procesy strojového učenia a začneme so zhromažďovaním správnej sady dát. Tieto dáta zahŕňajú marketingové interakcie, dohody, kampane, sťažnosti, demografické údaje či ďalšie údaje zákazníkov.

Zozbierané údaje sa následne spoja, predbežne spracujú podľa stanovených pravidiel (napríklad pre ochranu osobných údajov) a prevedú sa do cieľového formátu. Transformované dáta sú odoslané do *SAP Leonardo Machine Learning* platformy, v ktorej sú použité najmodernejšie algoritmy pre hlboké učenie na vytvorenie vysoko kvalitného modelu. Model detekuje skryté vzorky v dátach a je použitý na predikciu. Predpovedané výsledky sú posielané späť do marketingového systému ako skóre zákazníkov, napríklad skóre náchylnosti k odchodu ku konkurencii, alebo skóre náchylnosti ku kúpe určitého tovaru alebo služby. Používajú sa tiež na vykonanie marketingových rozhodnutí.

V skutočnosti sa AI, ktorá je zabudovaná do inteligentných marketingových systémov typu *SAP Marketing Cloud*, zakladá napríklad na nasledujúcich metódach:

Metódy pod dohľadom:

- Lineárny regresný model;
- Logistický regresný model;
- Generatívne modely učenia;
- Podpora vektorových strojov;
- Neurónové siete;
- Konvolučná neurónová sieť.

Metódy bez dohľadu:

- Zhľukovanie (*Clustering*);
- Zmiešané Gaussove modely;
- Analýza hlavných komponentov;
- Nezávislá analýza komponentov;
- Markovove reťazce;
- Opakujúca sa neurónová sieť.

Metódy s vlastným dohľadom:

- Latentná sémantická analýza;
- Štatistiky spoločného výskytu slov;
- *Word2Vec*.

Prínosy pre zákazníka

Konkrétne ukážky a využitie AI v praxi pre SME podniky

Inteligentné skóre: skóre afinity, najlepšia doba odoslania obchodných oznámení, vlastné skóre


Jedným z „hmatateľných“ výstupov využitia umelej inteligencie v oblasti marketingu je tzv. *skóre*. Skóre slúži na to, aby marketéri mohli lepšie porozumieť každému zákazníkovi alebo prospektovi. Skóre obohacuje profily zákazníkov, je to hodnotenie a predpoveď zákazníckeho správania v reálnom čase.

Je to aj kvantitatívne hodnotenie afinity kontaktu, náchylnosti ku kúpe určitého výrobku alebo služby, sentiment, preferencie, atď., určené na základe interakcií s organizáciou naprieč všetkými kontaktnými bodmi. Pomáha marketérom formovať predpoklady o budúcom správaní a rozhodnutiach pre konkrétneho existujúceho zákazníka, resp. potenciálneho zákazníka.


Skóre môže byť výstupom programovateľných pravidiel (ako je napríklad e-mailová afinita) a prediktívnych modelov (*buying propensity*). Skóre a kalkulácie sa vypočítavajú v reálnom čase a aktualizujú sa po každej interakcii zákazníka s organizáciou.

Používa sa naprieč celým marketingovým oddelením a pomáha lepšie plánovať, spravovať a vykonávať bežné i pokročilých marketingové aktivity. Marketér si môže vytvoriť celé také skóre, ktoré je relevantné pre cestu ich zákazníkov a odbor podnikania.

Skóre môžeme migrovať aj do ďalších systémov tretej strany (pozri Obrázok E 2).



Obrázok E 2 Zákaznícke skóre



Obrázok E 3 Využitie skóre v praxi (pri segmentácii)

Vopred nastavené skóre: e-mailová afinita

Veľmi prínosným poznatkom pri optimalizácii marketingových kampaní je informácia o tom, aké kanály najlepšie fungujú pri vybraných segmentoch zákazníkov. V tomto prípade sa pozrieme na e-mail. Pravidlá pre definovanie afinity na e-maily (pozri Obrázok E 4), alebo efektivity využitia e-mailu ako komunikačného kanálu môžu vyzerať nasledovne:

- Má kontakt e-mailovú adresu?

- Máme od kontaktu súhlas na zasielanie obchodných oznamov na jeho adresu?
- Poslali sme tomuto kontaktu aspoň 5 e-mailov?
- Afinita sa zvýši v závislosti od rýchlosti otvorenia e-mailu;
- Afinita sa zvýši, ak adresát kliká na odkaz v obsahu e-mailu;
- Metóda agregácie je „sumace“;
- Rozsah skóre je od 0 do 100.

Email Affinity

Details Persistence **Rules** Preview of Score Distribution

if

EmailOpenRate of the Contact is less than 10

And NoOfEmailsSent of the Contact is equal or greater 5

And EmailAdressAvailable of the C... exists in true

And EmailOptin of the Contact does not exist in by owner

Then

ScoreChange...: 5

if

EmailOpenRate of the Contact is between 10 30

And NoOfEmailsSent of the Contact is greater than 5

And EmailAdressAvailable of the C... exists in true

And EmailOptin of the Contact does not exist in by owner

Then

ScoreChange...: 15

Score distribution:

Open Rate	Click Rate	Score value
< 10%	< 1%	10
< 10%	1% - 3%	35
< 10%	3% - 10%	55
< 10%	>10%	85
10% - 30%	< 1%	20
10% - 30%	1% - 3%	45
10% - 30%	3% - 10%	65
10% - 30%	>10%	95
>30%	< 1%	25
>30%	1% - 3%	50
>30%	3% - 10%	70
>30%	>10%	100

Obrázok E 4 Pravidlá na definovanie e-mailovej afinity

Správa skóre: e-mailová afinita

Pre najefektívnejší spôsob využitia tohto skóre by mal marketér definovať tieto informácie:

- Definovať časový rámec na výpočet – minulý týždeň, posledných šesť mesiacov a pod.;
- Definovať frekvenciu výpočtu – denne, mesačne, atď.;
- Definovať, ako dlho sa má toto skóre ukladať – túto metódu je možné použiť na zistenie, ako sa skóre mení v čase.

Obrázok E 5 Správa skóre


Modely náchylnosti zákazníka k nákupu

Marketéri môžu tiež využívať prediktívne modelovanie na hodnotenie a charakterizáciu svojich zákazníkov. Hlavným prediktívnym scenárom v opísanom riešení je náchylnosť k spotrebiteľským nákupom, ale používateľ si môže tiež vytvoriť vlastné prediktívne scenáre pre iné prípady použitia, ako je napríklad riadenie odchodu zákazníkov.

Scenár náchylnosti k nákupu počíta skóre náchylnosti k nákupu pre každý z kontaktov v systéme. Výsledné skóre znamená, ako je pravdepodobné, že vybraný zákazník bude kupovať špecifikovaný produkt. Toto pomáha marketérom osloviť tých zákazníkov, ktorí majú najväčšiu pravdepodobnosť nákupu a neplývať energiu na tých zákazníkov, ktorí do tejto skupiny zatiaľ nepatria. Táto technológia pomáha marketérom byť relevantnejšími pre svojich zákazníkov a zároveň znížiť náklady marketingového oddelenia.

Model náklonnosti k nákupu – použitie predikčného skóre v segmentácii

Na obrázku (Obrázok E 6) vidíme, ako sú modely *Buying Propensity* využívané v segmentácii. Vidíme, že iba 16 % zákazníkov pokrýva 85 % danej zákazníkovej základne, pri ktorých je vysoká pravdepodobnosť nákupu konkrétneho produktu alebo kategórie produktu. Marketér sa teraz môže rozhodnúť osloviť zákazníkov s vysokou úrovňou personalizácie (uvedených 16 %), keďže je u nich veľká pravdepodobnosť nákupu.




Obrázok E 6 Prediktívne skóre – využitie v praxi

Customer Attribution

Cesty zákazníkov sa v digitálnom svete zvyčajne skladajú z mnohých kontaktných bodov, ktoré majú vplyv na konečné rozhodnutie o kúpe.

Atribučné modely, ako sú to *first-touch*, *last-touch*, atď. slúžia k priradeniu nákladov k zákazníkovi a vďaka tomu je možné lepšie porozumieť účelnosti marketingových výdavkov (pozri Obrázok E 7).




Obrázok E 7 Customer attribution

Pomocou atribučných modelov môže marketér jednoducho usporiadať všetky zákaznícke a marketingové dáta naprieč kanálmi do jediného pohľadu (s ohľadom na ich výkon).

Sleduje sa tu:


- Porovnanie výkonnosti jednotlivých kanálov (pozri Obrázok E 8);
- Tvorba taxonómií založených na značke a produkte – na odhalenie vplyvu produktu na výkon kampane.



Obrázok E 8 Porovnanie výkonnosti kanálov

V tomto prípade systém dovoľuje marketérovi určiť prírastkovú hodnotu, aby bolo možné pochopiť, či k predaju došlo z dôvodu marketingových aktivít alebo externých faktorov.

Ďalej je možné identifikovať špičky vývoja tržieb za účelom pochopenia, či marketingová aktivita viedla k predaju alebo tržby boli ovplyvnené sezónnosťou, vernosťou značke, offline marketingom, atď.




Obrázok E 9 Customer attribution – vizualizácia dát

Neoddeliteľnou súčasťou popísaného riešenia je tiež možnosť multidimenzionálneho porovnania dát v reálnom čase. Táto technológia umožňuje marketérovi definovať, ktoré taktiky „lákajú“ nových zákazníkov, a pri ktorých možno dosiahnuť, aby sa zákazníci znova vracali.

Marketér môže túto úlohu prakticky vyriešiť pomocou nasledovných aktivít:

- Vizualne rozdeliť výsledky horného a dolného „lievika“ na účely sprehľadnenia miery úsilia pri akvizíciách a retargetingu;
- Vykonať populáciu segmentu na základe typu zákazníka;
- Zistiť, ktoré metodiky a stratégie najlepšie korelujú s cieľom akvizícií a retenciou.



Obrázok E 10 Sledovanie výkonu marketingových kampaní


Technológie a vizualizácie dát v reálnom čase umožnia marketérovi zdokumentovať všetky zmeny výkonov marketingových kampaní, ku ktorým dochádza pri dennom meraní naprieč všetkými kanálmi. Pri následnej analýze môže marketér využiť sedemdňový kľzavý priemer na pochopenie vývoja efektivity marketingovej kampane v čase.

Hlboké učenie: *SAP Customer Retention*

Tento prvok umelej inteligencie pomôže užívateľovi nepretržite sledovať a predpovedať riziko odlivu zákazníkov tak, aby mohol včas reagovať a udržať si čo najviac zákazníkov.

System v tomto prípade zbiera údaje o kontaktných bodoch zákazníkov z rôznych zdrojov, identifikuje anomálne vzorce správania alebo udalosti súvisiace s odchodom ku konkurencii, poskytuje zoznam zákazníkov, pri ktorých hrozí odchod a odhaduje, kedy zhruba môže k odchodu dôjsť.


Proces automatizácie udržania si zákazníkov môže spočívať aj v tom, že systém v prípade vysoko rizikových zákazníkov automaticky vytvorí cieľové skupiny a osloví ich následne v rámci retenčných kampaní.



Obrázok E 11 Anomálne vzorce správania sa zákazníka a riziko odchodu

Automatická identifikácia kritických udalostí


Používateľ si môže sám nastaviť hlavné ukazovatele pre rôzne správanie zákazníkov, vrátane ich váh a koeficientov pre automatickú identifikáciu rizika (pozri Obrázok E 12).



Obrázok E 12 Automatická identifikácia kritických udalostí

Identifikácia zákazníkov, ktorí môžu spadať do rizikovej skupiny


Technológia grafov a štatistické metódy spomínané vyššie slúžia v opísanom riešení aj na identifikáciu zákazníkov, ktorých správanie začína byť rizikovým z pohľadu lojality (pozri Obrázok E 13).



Obrázok E 13 Rizikové skupiny zákazníkov

Smart Campaigns (inteligentné marketingové kampane)

Na obrázku (Obrázok E 14) vidíme, ako môže marketér využiť šablónu múdrej kampane pripravenej na báze AI. Marketér má následne možnosť zobrazovať, meniť, dopĺňať a upravovať cieľové skupiny, ktoré boli umelou inteligenciou vybrané na optimálny výkon kampane.



Obrázok E 14 Šablóna AI kampane

Opis vhodných a cenovo dostupných riešení pre SMB podniky pri implementácii SAP Customer Experience

SAP Customer Experience je rodina inteligentných riešení, ktorá spája produkty *SAP Marketing Cloud*, *SAP Commerce Cloud*, *SAP Customer Data Cloud*, *SAP Sales Cloud* a *SAP Service Cloud*. Kľúčovou výhodou tohto balíka riešení je *End-to-end* pokrytie všetkých podnikových procesov v oblasti zákazníckej skúsenosti, jednotné GUI (*Graphical User Interface* – grafické používateľské rozhranie), zladená používateľská skúsenosť, analytika s integrovanými prediktívnymi modelmi a mechanizmami strojového učenia.

SAP Marketing Cloud je inteligentný produkt, ktorý ponúka *best-of-class* riešenia v oblasti marketingovej automatizácie, dynamickú 360° profiláciu zákazníkov a personalizovaných *multichannel* kampaní, zameraných na zvyšovanie konverzií.

Medzi kľúčové faktory, ktoré odlišujú riešenie *SAP Marketing Cloud* od podobných riešení v tomto segmente patria najmä:

- Prepojený front- a back-office;
- Hotové biznis scenáre;
- Benchmarkové *best practice*, nazbierané za viac ako 40 rokov praxe a pôsobenia spoločnosti SAP na trhu;
- *In-memory* HANA technológie;
- Dátové centrá v Európe;
- Zjednotené užívateľské rozhranie;
- CX Labs v Európe (> 2000 alokovaných vývojárov);
- Minuloročná investícia do riešenia a synergie z oblasti CX predstavovala 10,59 mld. Eur.

Príloha 2 Zoznam expertov a externých konzultantov

Tabuľka P 1 Autori a asistenti štúdie zo Slovenskej technickej univerzity v Bratislave

Meno	Pozícia
Mária Bieliková	Autor
Michal Kompan	Autor
Martin Labaj	Autor
Peter Lacko	Autor
Zdenka Lenartová	Autor
Róbert Móro	Autor
Viera Rozinajová	Autor
Jakub Ševcech	Autor
Jitka Božíková	Asistent
Branislav Pecher	Asistent
Andrej Vitek	Asistent

Tabuľka P 2 Zástupcovia odbornej verejnosti, ktorí sa podieľali na posudzovaní jednotlivých výstupov

Meno	Odborný profil
Roman Behul	vedúci výskumu a vývoja, Atos IT Solutions and Services
Juraj Bezděk	vedúci výskumu, Sféra a.s.
Martin Drobný	šéfredaktor a výkonný riaditeľ PC Revue
Gabriel Fedorko	tajomník, IT Asociácia Slovenska
Emil Fitoš	prezident, IT Asociácia Slovenska
Andrej Greguš	spoluzakladateľ, nettle.AI
Pavol Halpert	výkonný riaditeľ, Korner Analytics, Blyss
Juraj Kadáš	manažér, IT Asociácia Slovenska
Tomáš Koctúr	software Solution Designer / Data Scientist, T-systems Slovakia s.r.o.
Pavol Kubán	výkonný riaditeľ a CEO, SCR technologies
Mario Lelovský	prvý viceprezident, IT Asociácia Slovenska a prvý viceprezident, Republiková únia zamestnávateľov
Stanislav Levársky	výkonný riaditeľ, GRISSP, j.s.a.
Daniel Minárik	chief Data Officer, Tatrabanka a.s.
Milan Oselský	vedúci oddelenia, IPSoft Slovakia
Michal Papučík	IT konzultant, BRAIN:IT s.r.o.
Karol Stračár	projektový manažér, Octigon, a.s.
Erich Šašinka	riaditeľ EEA s.r.o.
Marek Šebo	výkonný riaditeľ a AI konzultant, Cognexa
Filip Vittek	riaditeľ oddelenia Data Science, TeamViewer A.G.,
Petra Zappe	hlavná radkyňa, Americká obchodná komora na Slovensku
Lukáš Hatala	technický riaditeľ, DXC Technology
Dalibor Kačmář	národný technologický radca, Microsoft
Ivo Kovačič	technologický riaditeľ, Atos IT Solutions and Services
členovia Spolku pre spoločenské a etické dopady IT	

Príloha 3 Metodika dotazníkového prieskumu

V rámci prípravy štúdie sme zrealizovali dotazníkový prieskum, v ktorom sme sa snažili zmapovať aktuálny stav využívania a vývoja systémov umelej inteligencie na Slovensku a jej celkového vnímania.

Dotazník bol realizovaný od 8. 11. 2019 do 30. 11. 2019. V prvom kroku sme oslovovali spoločnosti, ktoré sú členmi špecializovaných asociácií a združení, konkrétne:

- Slovenského centra pre výskum umelej inteligencie – slovak.AI;
- Americkej obchodnej komory na Slovensku;
- IT Asociácie Slovenska;
- Republikovej únie zamestnávateľov.

Vzhľadom k tomu, že naším cieľom bolo osloviť čo najširšie spektrum spoločností na Slovensku, v druhom kroku sme prostredníctvom databázy Finstat oslovili aj ďalšie spoločnosti.

Dotazník obsahoval približne 25 otázok a bol určený pre tých zástupcov spoločností, ktorí by mali vedieť za danú spoločnosť zhodnotiť stav adopcie/vývoja AI. Otázky, ktoré boli kladené jednotlivým respondentom boli rôzne, líšili sa podľa odpovedi zvolenej v otázke „Akým spôsobom Vaša spoločnosť prichádza do kontaktu s umelou inteligenciou, tzv. AI technológiou?“, t. z., že iné otázky boli kladené spoločnostiam, ktoré sa so systémami umelej inteligencie nikdy nestretli a iné tým, ktoré systémy AI vyvíjajú.

Vzor dotazníka je uvedený na nasledujúcich stranách.

Vzor dotazníka

AI prieskum

Umelá inteligencia môže Slovensko posunúť vpred

Slovenská technická univerzita a Slovenské centrum pre výskum umelej inteligencie – slovak.AI spúšťa, pod záštitou Úradu podpredsedu vlády SR pre investície a informatizáciu, prieskum na zmapovanie súčasného stavu a potenciálu umelej inteligencie na Slovensku. [slovak.AI](#) je neutrálna, nezávislá a nezisková platforma, ktorej ambíciou je rozvíjať excelenciu a spájať expertov a záujemcov o umelú inteligenciu.

Veríme, že umelá inteligencia zásadným spôsobom zmení nielen naše životy, ale aj štruktúru nášho hospodárstva. Jedným z dôležitých predpokladov pre akceleráciu využitia umelej inteligencie a nastavenia štruktúry a formy podpory – či už pre súkromné, štátne, verejné alebo neziskové organizácie, je zmapovanie aktuálneho stavu: vývoja prvkov umelej inteligencie slovenskými IT spoločnosťami a využívania prvkov umelej inteligencie v priemyselných podnikoch na Slovensku.

Dotazník je určený pre tých zástupcov spoločností, ktorí tieto skutočnosti vedia za svoju spoločnosť zhodnotiť (majitelia spoločností, technickí riaditelia, IT manažéri a iní). Vyplnením tohto dotazníka pomôžete identifikovať aktuálny stav vnímania a využívania umelej inteligencie na Slovensku, čo umožní lepšie využitie budúcich investícií. **Váš vstup je veľmi dôležitý. Vyplnenie dotazníka trvá 10 minút.**

Čo spadá pod pojem umelá inteligencia? Pre účely tohto dotazníka budeme používať pojem umelá inteligencia ako odkaz na systémy, ktoré pre dosiahnutie daného cieľa konajú vo fyzickom alebo digitálnom priestore, analyzujú ho, usudzujú a vykonávajú akcie, pričom vykazujú inteligentné správanie. Inteligentné správanie má viacero aspektov, jeden z najdôležitejších je ten, že takéto systémy sa vedia “učiť”, a teda konať s určitou presnosťou a úspešnosťou aj v situáciách, ktoré nebolo v čase ich návrhu známe. Systémy založené na AI môžu byť čisto softvérové (napr. osobný asistent, rozpoznávanie reči a tváre atď.), alebo hardvérové so zabudovaným softvérom (napr. robotický systém, drony alebo aplikácie internetu vecí).

Súhlas so spracovaním osobných údajov (e-mail, IČO)

- ☐ Súhlasím so spracovaním osobných údajov spoločnosťou Slovenská technická univerzita v Bratislave, Slovenské centrum pre výskum umelej inteligencie – slovak.AI a PricewaterhouseCoopers Advisory s.r.o. pre účely prieskumu mapovania súčasného stavu a potenciálu rozvoja AI na Slovensku pre Úrad podpredsedu vlády SR pre investície a informatizáciu. Váš súhlas so spracovaním osobných údajov môžete kedykoľvek odvolať elektronicky na adrese sk-privacy@sk.pwc.com. (1)

Sekcia 1 - Demografické údaje

Prosím vyplňte nasledovné základné identifikačné údaje o Vašej firme

☐ Názov firmy (1) _____

☐ IČO (3) _____

1. Prosím uveďte orientačný počet zamestnancov Vašej firmy

- 0 - 9 (1)
- 10 - 49 (2)
- 50 - 249 (3)
- 250 a viac (4)

2. Aká je Vaša pozícia vo firme?

- Majiteľ spoločnosti / generálny riaditeľ (1)
- Technický manažér / riaditeľ (2)
- IT manažér / riaditeľ (3)
- Obchodný manažér / riaditeľ (4)
- Finančný manažér / riaditeľ (5)
- Prevádzkový manažér / riaditeľ (6)
- IT špecialista (7)
- Iná, prosím uveďte: (8) _____

3. Akým spôsobom Vaša spoločnosť prichádza do kontaktu s umelou inteligenciou, tzv. AI technológiou ("artificial intelligence")?

- Naša spoločnosť zatiaľ neprišla do kontaktu s AI technológiami a ani doteraz neuvažovala o zavedení AI riešenia (1)
- Naša spoločnosť zatiaľ neprišla do priameho kontaktu s AI technológiami, ale plánuje investovať do digitalizácie procesov, pričom nevieme povedať, či súčasťou sú aj nástroje AI (2)
- Naša spoločnosť zatiaľ neprišla do priameho kontaktu s AI technológiami, ale plánuje investovať do projektu digitalizácie, ktorého súčasťou je aj AI (9)
- Naša spoločnosť vyvíja produkty (môže zahŕňať aj výskum), ktoré zahŕňajú vlastné AI riešenia (3)
- Naša spoločnosť vyvíja AI riešenia (môže zahŕňať aj výskum), ktoré umožnia iným zahrnúť AI do svojich produktov (4)
- Naša spoločnosť používa externé dodané AI riešenia pre svoje produkty/systémy (5)
- Naša spoločnosť používa externé dodané AI riešenia pri interných procesoch / pre vlastnú efektivitu (6)
- Naša spoločnosť má skúsenosť s AI technológiami v inom smere (nasadzovanie AI technológií, konzultovanie, monitorovanie, dohľad, ...) (7)
- Iné, prosím uveďte: (8) _____

4. V akej oblasti Vaša spoločnosť vyvíja AI produkty alebo riešenia?

- Umelá inteligencia priamo v produktoch, ktoré predávame (1)
- Prediktívna údržba (2)
- Intelligentná procesná automatizácia (3)
- Optimalizácia výroby (4)
- Optimalizácia logistiky (5)
- Marketing a podpora predaja, retail (6)
- Online predaj (7)
- Riadenie kvality, výstupná či laboratórna kontrola (8)
- Intelligentné agenty a boty (9)
- Energetický manažment (10)
- Nevie sa vyjadriť (12)
- Iné, prosím uveďte: (11) _____

5. Prosím popíšte bližšie produkt / riešenie založené na AI, ktoré vyvíjate alebo poskytujete

6. Aké typy riešení / produktov s využitím AI technológií Vaša firma vyvíja?

- B2B ("business-to-business") (1)
- B2C ("business-to-customer") (2)
- Pre verejnú správu alebo neziskový sektor (3)
- Nevie sa vyjadriť (4)

7. V akom sektore Vaša spoločnosť implementuje AI riešenia alebo predáva AI produkty?

- Poľnohospodárstvo (1)
- Doprava a logistika (2)
- Finančné inštitúcie (banky, poisťovne a iné finančné inštitúcie) (3)
- Obchod / marketing (4)
- Energetika (5)
- Medicína a farmaceutický priemysel (6)
- Starostlivosť o životné prostredie (odpadové hospodárstvo a iné) (7)
- Nevie sa vyjadriť (9)
- Iné, prosím uveďte: (8) _____

8. Ktoré metódy a oblasti výskumu AI využívate vo Vašich riešeniach a produktoch?

- Reprezentácia znalostí a argumentácia (Knowledge representation & reasoning) (1)
- Plánovanie (Planning & scheduling) (2)
- Vyhľadávanie, optimalizácia (Searching, optimization) (3)
- Strojové učenie (Machine learning) (4)
- Spracovanie prirodzeného jazyka (Natural language processing) (5)
- Počítačové videnie (Computer vision) (6)
- Robotika a automatizácia (Robotics & automation) (10)
- Inteligentné agenty a boty (Agent & multi-agent systems) (7)
- AI aplikácie, platformy, soft. služby (AI applications, platforms, software services) (8)
- Nevie sa vyjadriť (11)
- Iné, prosím uveďte: (9) _____

9. Koľko Vašich zamestnancov sa venuje návrhu a implementácii metód AI do Vašich produktov a riešení? Prosím uveďte orientačný počet výskumníkov a vývojárov AI riešení a produktov vo Vašej firme zaokrúhlený na celé číslo.

10. Má Vaša spoločnosť výskumné oddelenie zamerané na AI technológie?

Pod výskumným oddelením sa myslí aktivita vykonávaná nad rámec vývoja AI technológií v oblasti základného alebo aplikovaného výskumu AI technológií.

- Vykonávame aj výskumné aktivity a máme určené samostatné výskumné pracovisko / oddelenie / tím (1)
- Naši vývojári vykonávajú výskum ako súčasť svojich bežných pracovných úloh (2)
- Nevýkonávame žiadne výskumné aktivity (3)
- Nevie sa vyjadriť (4)

11. Je alebo bola Vaša spoločnosť zapojená do národných výskumných projektov zameraných na AI?

- Áno (prosím definujte v akej oblasti): (1)

- Nie (2)

- Nevie sa vyjadriť (3)

12. Je alebo bola Vaša spoločnosť zapojená do európskych výskumných projektov zameraných na AI?

- Áno (prosím definujte v akej oblasti): (1)

- Nie (2)

- Nevie sa vyjadriť (3)

13. Akú výpočtovú infraštruktúru využívate pri práci s AI?

- Máme k dispozícii vlastnú infraštruktúru (1)
- Využívame cudziu / zdieľanú infraštruktúru (google, amazon, ...) (2)
- Nevie sa vyjadriť (3)

14. Aké je vlastníctvo dát, ktoré využívate pri výskume / aplikácii AI?

- Dáta sú vo vlastníctve našej spoločnosti (1)
- Dáta sú vo vlastníctve klienta (2)
- Využívame open-data (prosím uveďte zdroj dát): (3)

- Nevieť sa vyjadriť (6)

15. Venujete sa vo Vašej spoločnosti aj etickým otázkam vývoja a nasadzovania AI?

- 1 (vôbec to nepovažujeme za dôležité) (1)
- 2 (2)
- 3 (3)
- 4 (4)
- 5 (považujeme to za kľúčové) (5)

16. Prosím uveďte dôvod Vašej odpovede alebo popíšte bližšie, ako sa vo Vašej spoločnosti venujete téme etiky pri vývoji alebo výskume AI

17. Uveďte, aký AI produkt / riešenie využíva Vaša spoločnosť (aké prvky umelej inteligencie produkt / riešenie používa)

- Umelá inteligencia priamo v produktoch, ktoré predávame (1)
- Prediktívna údržba (2)
- Intelligentná procesná automatizácia (3)
- Optimalizácia výroby (4)
- Optimalizácia logistiky (5)
- Marketing a podpora predaja, retail (6)
- Online predaj (7)
- Riadenie kvality, výstupná či laboratórna kontrola (8)
- Intelligentné agenty a boty (9)
- Energetický manažment (10)
- Nevieť sa vyjadriť (12)
- Iné, prosím uveďte: (11) _____

18. Malo zavedenie AI produktov / riešení pre Vašu spoločnosť pozitívny dopad?

- Efekt neviem ešte vyčíslieť (1)
- Zavedenie AI malo pozitívny vplyv na efektivitu (2)
- Zavedenie AI malo pozitívny vplyv na ROI (3)
- Zavedenie AI malo pozitívny vplyv na efektivitu aj ROI (4)
- Nevieť sa vyjadriť (5)

19. V akej oblasti Vaša spoločnosť plánuje investovať do AI (v najbližších 1 - 3 rokoch)?

- Umelá inteligencia priamo v produktoch, ktoré predávame (1)
- Prediktívna údržba (2)
- Intelligentná procesná automatizácia (3)
- Optimalizácia výroby (4)
- Optimalizácia logistiky (5)
- Marketing a podpora predaja, retail (6)
- Online predaj (7)
- Riadenie kvality, výstupná či laboratórna kontrola (8)
- Intelligentné agenty a boty (9)
- Energetický manažment (10)
- Nevie sa vyjadriť (12)
- Iné, prosím uveďte: (11) _____

20. Akým spôsobom plánujete rozvíjať AI v budúcnosti (v najbližších 1 - 3 rokoch)?

- Interný vývoj AI riešenia šitý na mieru (1)
- Nákup špecializovaných AI riešení od tretích firiem (2)
- Partnerstvá s akademickou obcou (3)
- Vyhľadávaním externých AI expertov (4)
- Nákupom riešení vyvinutými a implementovanými v zahraničí (5)
- Nevie sa vyjadriť (7)
- Iným spôsobom, prosím uveďte: (6) _____

21. Čo by Vám najviac pomohlo pre zlepšenie využívania AI riešení / poskytovania produktov alebo služieb postavených na AI technológiách?

- Prehľad AI riešení vo svete a na Slovensku (1)
- Finančná podpora pri testovaní riešenia tzv. Proof of Concept (2)
- Lepšia/zrozumiteľnejšia ponuka AI riešení (3)
- Väčšie množstvo AI expertov (5)
- Nevie sa vyjadriť (4)
- Iné, prosím uveďte: (7) _____

22. Prosím popíšte bližšie čo by Vám pomohlo pre zlepšenie využívania AI riešení / poskytovania produktov alebo služieb postavených na AI technológiách

23. Ktorá oblasť má podľa Vás pre Slovensko najväčší potenciál pre rozvoj a aplikáciu AI?

	Veľký potenciál (1)	Skôr väčší potenciál (2)	Neviem sa vyjadriť (3)	Skôr menší potenciál (4)	Takmer žiadny potenciál (5)
Zdravotníctvo (1)	☐	☐	☐	☐	☐
Doprava (2)	☐	☐	☐	☐	☐
Výrobný priemysel (3)	☐	☐	☐	☐	☐
Životné prostredie (4)	☐	☐	☐	☐	☐
Energetika (5)	☐	☐	☐	☐	☐
Stavebníctvo (6)	☐	☐	☐	☐	☐
Finančné inštitúcie (banky, poisťovne a iné finančné inštitúcie) (7)	☐	☐	☐	☐	☐
Poľnohospodárstvo (8)	☐	☐	☐	☐	☐
Sociálna pomoc (9)	☐	☐	☐	☐	☐
Obchod, marketing (10)	☐	☐	☐	☐	☐
Iné, prosím uveďte: (11)	☐	☐	☐	☐	☐

24. Prosím vyjadrite akýkoľvek iný postreh k príležitostiam a rozvoju AI na Slovensku

25. Má Vaša spoločnosť záujem zdieľať príklad dobrej praxe pri zavedení AI do praxe?
Príklady dobrej praxe môžu byť súčasťou pripravovaného verejného dokumentu s názvom "Manuál pre firmy na zavedenie umelej inteligencie", ktorý bude zdieľaný s priemyselnými firmami na Slovensku a je vypracovávaný pod záštitou STU, slovak.AI a ÚPVII SR.

- Áno (1)
- Nie (2)