

OPTIMALIZÁCIA VÝROBY

Scenár digitalizácie s využitím umelej inteligencie



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

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.).

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.).

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.

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.

Ludia

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.

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 míľniky 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

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.

Kvantitatívne prínosy

- Priame úspory zdrojov (eliminácia/uvolnenie 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.

Riziká

Treba si uvedomiť, že pri väčšine projektov je predriadnou 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.



Tento text je súčasťou dokumentu ANALÝZA A NÁVRH MOŽNOSTÍ VÝSKUMU, VÝVOJA A APLIKÁCIE UMELEJ INTELEGENCIE NA SLOVENSKU - DIELO Č. 2 - MANUÁL PRE FIRMY NA ZAVEDENIE UMELEJ INTELEGENCIE. Dielo bolo vypracované 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 tomto texte, ak nie je uvedené inak, sú aktuálne k dátumu odovzdania správy.

© 2019, 2020 Slovenská technická univerzita v Bratislave, Úrad podpredsedu vlády SR pre investície a informatizáciu. Všetky práva vyhradené.