

PREDIKTÍVNA ÚDRŽBA

Scenár digitalizácie s využitím umelej inteligencie



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 realistickejšie 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 dost 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 vynaložením veľkých 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** - za-integrovať 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 okamžitě vypnúť výrobu 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

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.

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 navrhnuť 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 sensorov 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 sensorov, 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.

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 akejkoľvek 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.

Infraštruktúra

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

- Sensory;
- 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.

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 kompletné 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.

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

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 prevádz-

ke 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.


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 literatúra¹ uvádza údaj návratnosti tri až päť rokov, čo je v porovnaní s návratnosťou iných častí technológie veľmi krátky čas.

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.
- **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 investície²;
- **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.



Tento text je súčasťou dokumentu ANALÝZA A NÁVRH MOŽNOSTÍ VÝSKUMU, VÝVOJA A APLIKÁCIE UMELEJ INTELIGENCIE NA SLOVENSKU - DIELO Č. 2 - MANUÁL PRE FIRMY NA ZAVEDENIE UMELEJ INTELIGENCIE. 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.