



ŽILINSKÁ UNIVERZITA V ŽILINE
Strojnícka
fakulta

AUTOREFERÁT DIZERTAČNEJ PRÁCE

Žilina, 2024

Ing. Katarína Štaffenová



ŽILINSKÁ UNIVERZITA V ŽILINE
Strojnícka
fakulta

Ing. Katarína Štaffenová

AUTOREFERÁT DIZERTAČNEJ PRÁCE

PREDIKČNÝ MODEL PRE INTELIGENTNÝ SYSTÉM ÚDRŽBY

Na získanie akademického titulu **doktor**
(„**philosophiae doctor**“, v skratke „**PhD.**“)
v študijnom odbore Strojárstvo
v študijnom programe Priemyselné inžinierstvo

Žilina 2024

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia na Žilinskej univerzite v Žiline, Strojníckej fakulte, Katedre priemyselného inžinierstva.

Predkladateľ: Ing. Katarína Štaffenová
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra priemyselného inžinierstva

Školiteľ: doc. Ing. Miroslav Rakyta, PhD.
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra priemyselného inžinierstva

Oponenti:

1. prof. Ing. Peter Trebuňa, PhD.
Technická univerzita v Košiciach
Strojnícka fakulta
Katedra priemyselného a digitálneho inžinierstva
2. doc. Ing. Juraj Grenčík, PhD.
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra dopravnej a manipulačnej techniky
3. Ing. Marek Minda PhD.
Nemak Slovakia, s. r. o.
Žiar nad Hronom

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa koná dňa 27.08.2024 o 11:30 hod. v miestnosti BA205 na SjF, Univerzitná 8215/1, 010 26, Žilina, pred komisiou pre obhajobu dizertačnej práce schválenou odborovou komisiou v študijnom odbore Strojárstvo, v študijnom programe priemyselné inžinierstvo, vymenovanou dekanom Strojníckej fakulty, Žilinskej univerzity v Žiline.

S dizertačnou prácou je možné sa oboznámiť na referáte pre vedu a výskum dekanátu SjF, UNIZA, Univerzitná 8215/1, 010 26 Žilina.

prof. Ing. Martin Krajčovič, PhD. v. r.
predseda komisie pre obhajobu dizertačnej práce

ÚVOD

Údržba je systematická činnosť s účelom udržiavať stroje v prevádzkyschopnom stave a zlepšovať ich dostupnosť. Postupne sa k tomuto procesu pridali ďalšie úlohy, ako je predpovedanie porúch, diagnostika, modernizácia strojov a zariadení a ďalšie.

V dohľadnej budúcnosti bude celý výrobný systém inteligentný a schopný spolupracovať s ľuďmi. Odjakživa sa ľudstvo snažilo inovovať a vytvárať nové zariadenia a stroje na zjednodušenie práce. Aj keď vynášli niečo nové, vždy nastala potreba zdokonaľovať existujúce technológie. Na začiatku bola priorita len výroba nových zariadení a strojov, no postupne si ľudia uvedomili, že je nevyhnutná nielen ich výroba, ale aj udržiavanie v prevádzkyschopnom stave.

Údržba strojov a zariadení je kritickým prvkom v každom priemyselnom podniku, bez ohľadu na ich veľkosť či odvetvie. Tradičné metódy údržby, ako napríklad preventívna údržba a údržba po poruche, boli po dlhú dobu základom v podnikovom prostredí. Avšak v súčasnosti, v dobe rýchleho technologického pokroku a digitálnej transformácie, sa smeruje k efektívnejším a výkonnejším spôsobom údržby, a to najmä vďaka prediktívnej údržbe a implementácii predikčných modelov.

Prediktívna údržba predstavuje nový prístup k údržbe, ktorý využíva pokročilé technológie, ako je technická diagnostika, umelá inteligencia a strojové učenie, na predpovedanie budúcich porúch alebo potenciálnych problémov ešte predtým, než vzniknú. Tento prístup má mnohé výhody oproti tradičným metódam údržby. Okrem znižovania nákladov na opravy a minimalizovania výpadkov výroby, prediktívna údržba umožňuje plánovať údržbu vopred, čo zvyšuje efektivitu prevádzky a znižuje čas strávený nedostupnosťou strojov.

Implementácia predikčných modelov je nevyhnutná pre úspešnú realizáciu prediktívnej údržby. Tieto modely dokážu analyzovať obrovské množstvo dát získaných zo senzorov a rôznych systémov, a na základe týchto údajov predpovedať budúce udalosti alebo poruchy. Vďaka strojovému učeniu sa tieto modely s časom stále zlepšujú a prispôbujú na konkrétne prevádzkové podmienky a prostredia, čo zvyšuje ich presnosť a spoľahlivosť.

Vytváranie a implementácia inteligentných systémov údržby je neoddeliteľnou súčasťou moderného priemyslu a výroby. Tieto systémy využívajú pokročilé technológie a algoritmy na automatickú analýzu a spracovanie údajov zo senzorov a ďalších zdrojov. Na základe týchto informácií prijímajú rozhodnutia týkajúce sa údržby a opráv. Integrácia týchto inteligentných systémov údržby do celkového inteligentného systému výroby umožňuje automatizáciu a optimalizáciu údržbových procesov, čo vedie k zvýšeniu výkonnosti, zníženiu nákladov a zlepšeniu konkurencieschopnosti podniku.

Prediktívna údržba a implementácia predikčných modelov sú kľúčové pre zabezpečenie spoľahlivosti a efektivity údržby vo výrobnom prostredí. Rovnako dôležité je aj vytváranie a implementácia inteligentných systémov údržby, ktoré poskytujú podporu a optimalizujú údržbové procesy v rámci celého inteligentného systému výroby.

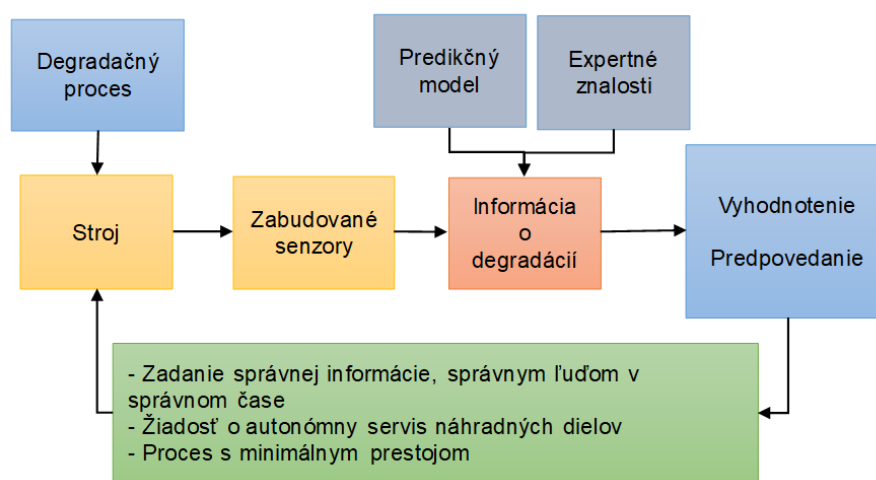
Záverečná práca vznikla s podporou financovania z grantu Agentúry na podporu výskumu a vývoja č. APVV-19-0305.

PREHĽAD PROBLEMATIKY

Hlavnou témou, ktorou sa zaoberá dizertačná práca je návrh a implementácia predikčného modelu, založeného na bázy vyšších štatistických metód a algoritmov strojového učenia pre potreby prediktívnej údržby ako súčasť inteligentného systému údržby.

Inteligentné systémy údržby

Inteligentný systém údržby je systém, ktorý využíva zozbierané údaje zo strojov, na predikovania a predpovedanie možného zlyhania. Výskyt zlyhaní v strojoch môže byť nákladný a dokonca katastrofický. Aby sa predišlo zlyhaniam, musí existovať systém správania stroja a poskytovať pokyny na preventívnu údržbu. (Moore, 2006)



Obr. 1 Inteligentný systém údržby (Lee, 2004)

Analýza správania strojov sa stala možnou pomocou inteligentných senzorov, systémov zberu údajov, možností ukladania a prenosu údajov a nástrojov na analýzu údajov. Jedná sa o rovnakú sadu nástrojov vyvinutých pre predpovede. Inteligentný systém údržby je systém, ktorý využíva nástroje na analýzu údajov, podporu rozhodovania, predpovedania a zabránenie potenciálnemu zlyhaniu strojov. Nedávny pokrok v oblasti informačných technológií, počítačov a elektroniky uľahčil návrh a implementáciu takýchto systémov. (Moore, 2006)

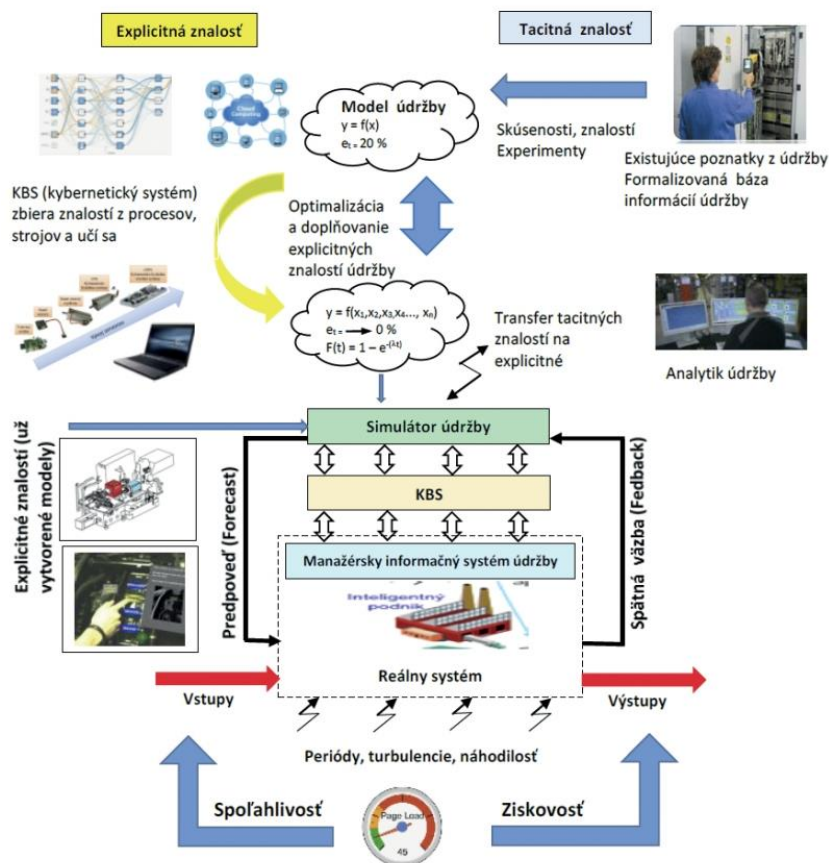
Inteligentné riadenie údržby sa vo veľkej miere spolieha na riešenie výpočtových problémov, ktorých jadrom sú prognostické a optimalizačné algoritmy. V niektorých aplikáciách je množstvo zozbieraných údajov, ktoré sú objemné a vysokofrekvenčné, čo si vyžaduje efektívne predbežné spracovanie údajov a výpočtový výkon. (Sirvio, 2015)

Systémovú prognózu, t. j. techniky predpovedania stavu možno rozdeliť na kvalitatívne a kvantitatívne metódy. Kvalitatívne metódy sa dajú lepšie použiť na predpovedanie rušivých zmien v systéme víziou budúceho stavu stroja s prihliadnutím na rôzne aspekty a oblasti. Kvalitatívne prognózovanie môže byť založené na odborných názoroch. (Wakefield, 2014)

Koncept inteligentného systému údržby

V procese, v ktorom sa stretávajú záujmy rozmanitých subjektov trhu a súčasne pri neustálych zmenách požiadaviek zákazníkov sa vytvára tlak, ktorý vplyva na výber nového údržbového systému a nastavenie inovačnej schopnosti výrobných a montážnych podnikov spojenej s implementáciou inteligentných technológií a diagnostickej techniky do výroby. V súčasnosti je hlavným cieľom priemyselných podnikov dosiahnuť rýchlu adaptáciu vzhľadom k inicializácii novej výroby a schopnosti reakcie voči vyskytujúcim sa chybám pomocou inteligentného údržbového systému na báze konceptu Industry 4.0. (Rakyta, 2017)

Inovativnosť, výhody a prínosy inteligentného údržbového systému je možné overiť pomocou monitorovania ukazovateľov prevádzkovej spoľahlivosti a hodnotenia efektívnosti systému údržby. Takéto inovatívne inteligentné riešenia v systéme údržby vytvárajú o podniku úplne nový obraz a menia pracoviská na inteligentné pracoviská (Obr. 2). (Rakyta, 2017)



Obr. 2 Koncept inteligentného systému údržby (Rakyta, 2017)

Prvým krokom je zabezpečiť ich prepojenie a zber údajov zo zariadení previesť od manuálnych papierových kontrol k systémom automatizovaného zberu, ktorý zlepšuje kvalitu údajov a eliminuje množstvo a čas. Monitorovanie zariadení z centra alebo z akéhokoľvek miesta vo výrobe pomocou internetu vecí rozširuje počet a rôznorodosť parametrov, ktoré možno sledovať a použiť na zabezpečenie pravidelného monitorovania mechanického stavu zariadení, prevádzkovej spoľahlivosti, nákladov na odstávky spôsobené poruchami strojov. (Rakyta, 2017)

TÉZY DIZERTAČNEJ PRÁCE

Hlavný cieľ doktorskej dizertačnej práce

Hlavný cieľ doktorskej dizertačnej práce je definovaný ako **návrh predikčného modelu pre inteligentný systém údržby**.

Parciálne ciele doktorskej dizertačnej práce

- Spracovanie teoretického prehľadu poznatkov z oblasti údržby a inteligentnej údržby.
- Sumarizovanie a popísanie súčasného stavu riešenej oblasti.
- Popísať integráciu predikčného modelu v koncepcii inteligentného systému údržby s previazaním na ostatné prvky výrobného systému.
- Navrhnuť predikčný model pre inteligentný systém údržby s podporou strojového učenia.
- Navrhnuť implementáciu predikčného modelu.
- Experimentálne overiť navrhovaný model v priemyselnej praxi.

Formulácia vedeckého problému

V súčasnosti sa podniky v priemyselnej oblasti snažia zlepšovať svoju konkurencieschopnosť na presýtenom trhu. Veľa pozornosti sa kladie na optimalizáciu výroby, ktorá predstavuje hlavný proces vo výrobných podnikoch a logistike, ktorá predstavuje najdôležitejší obslužný proces vo výrobných podnikoch. Údržba ako podporný proces zostáva v pozadí, aj keď optimalizáciou a neustálym zlepšovaním procesov údržby je možné niekoľkonásobne zlepšiť hlavný proces, ktorým je výroba, ale aj ostatné pomocné procesy.

S príchodom nových technológií je veľa možností ako údržbu v podniku zlepšovať. Komplexným riešením je zavedenie inteligentného systému údržby spolu s inteligentným systémom výroby. Pod inteligentným systémom údržby sa rozumie systém pokrývajúci všetky činnosti údržby, schopný predikovať nežiadúce stavy, ktorý neustále komunikuje s inteligentným systémom výroby, manažérskymi informačnými systémami, dokáže prijímať relevantné informácie, analyzovať ich a následne výsledky analýzy zobrazovať v používateľsky prijateľnom rozhraní a prostredí.

V údržbe vznikajú viaceré problémy, ktoré napomáha riešiť inteligentný systém údržby:

- plánovaná údržba je nevyhovujúca z pohľadu plánovania výroby a stroj nie je možné z výroby uvoľniť na vykonanie údržbových činností,
- zariadenie je k dispozícii, ale chýbajú dostupné zdrojové kapacity, či už sa jedná o hmotné, nehmotné, finančné alebo ľudské zdroje,
- jedným z ďalších problémov je situácia, kedy je zariadenie vydané na činnosti údržby, sú k dispozícii potrebné zdroje, ale nie sú na sklade náhradné diely podľa normy.

Tieto problémy majú za následok vysoké prestoje na strojoch a zvyšovanie nákladov na údržbu pri nedostatočnom integrovaní inteligentného systému údržby.

Riešením je implementácia inteligentného systému údržby s predikčným modelom. V nadväznosti na analýzu súčasného stavu a na tieto skutočnosti, výskumný problém, na ktorý sa zameriava táto práca je návrh predikčného modelu pre inteligentný systém údržby. V súčasnosti sa v literatúre takto komplexne spracovaný model, ako je popísaný v tejto práci, nenachádza. V dostupnej literatúre sa momentálne nachádza len popísanie technickej diagnostiky a štatistické vyhodnocovanie pravdepodobnosti.


Použité vedecké metódy

Pri spracovaní doktorskej dizertačnej práce boli použité nasledovné vedecké metódy:

- abstrakcia – transformácia informácií zo zmyslovej do racionálnej úrovne,
- algoritmizácia - proces vytvárania presne definovaných krokov na splnenie určitej inštrukcie alebo úlohy,
- analýza – metóda využívajúca rozbor a rozklad na jednotlivé súčasti,
- dedukcia – postup transformácie premís za pomoci pravidiel a postupov k novým tvrdeniam,
- experimentovanie – osobné zasahovanie konkrétneho riešiteľa do vybraného systému s cieľom získať v maximálnej možnej miere, čo najviac výsledkov,
- indukcia –skúmanie faktov, javov a udalostí na základe čoho môžeme vykonať všeobecný záver,
- matematicko-štatistické metódy – korelačné analýzy a základné matematické operácie,
- porovnanie – stanovenie zhody a rozdielov dvoch a viac rôznych objektov, alebo javov,
- syntéza – opak analýzy, využíva spájanie častí, súvislosti a vzťahov do celku,
- systémový prístup – nevyhnutný pre komplexné chápanie rôznych javov v súvislostiach.

NÁVRH RIEŠENIA – PREDIKČNÝ MODEL PRE INTELIGENTNÝ SYSTÉM ÚDRŽBY

Predikčný model je neoddeliteľnou súčasťou inteligentných systémov údržby. Vychádza z prediktívnej údržby, ktorá sa snaží adresovať problém správneho určenia momentu pre údržbu s využitím pokročilých štatistických metód a umelej inteligencie. Údržba každého zariadenia, ktorá je založená na predikcii, je posudzovaná a plánovaná na základe aktuálneho stavu zariadenia, pričom prostredníctvom rôznych predikčných modelov nastáva snaha odhadnúť dátum a čas poruchy. Následne je možné skrátiť alebo predĺžiť údržbové cykly podľa stavu daného zariadenia.



Obr. 3 Prepojenie súčasného a inteligentného systému údržby pomocou predikčného modelu
(vlastné spracovanie)

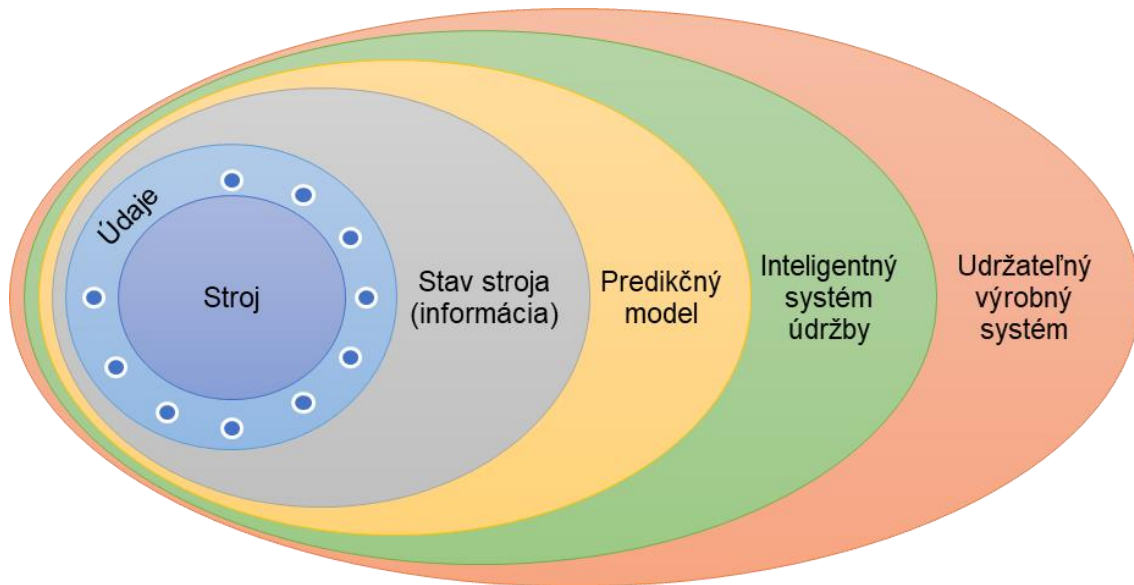
Na to, aby bolo možné presne určiť stav zariadenia je potrebné používať rôzne diagnostické postupy a zariadenia. Klasickú preventívnu údržbu je možné realizovať aj bez umelej inteligencie a inteligentných snímačov. Na takýto typ údržby sú využívané základné diagnostické nástroje ako napríklad ultrazvukové merania, kvalita oleja a pod. Takéto diagnostické úkony sú väčšinou nákladné a nie vždy sa dajú realizovať počas prevádzky zariadenia.

Zásadný zlom prinášajú práve inteligentné senzory a pokrokové predikčné modely, ktoré sú schopné väčšinu týchto diagnostických činností plne automatizovať. Zavedenie takéhoto automatického monitoringu prispieva k drastickému zvýšeniu presnosti predikcie a zníženiu potreby nákladných diagnostických kontrol. Automatický monitoring je taktiež možné nasadať nie len na najkritickejších zariadeniach, ale na všetkých dôležitých strojoch. Vďaka neustálemu monitoringu je možné identifikovať aj javy a stav stroja, ktoré by nebolo možné identifikovať tradičným spôsobom.

Napriek výhodám umelej inteligencie v údržbe, je stále výhodné používať niektoré tradičné prístupy k monitorovaniu stavu zariadenia. Predikčný model by mal disponovať statickými modulmi, teda takými, pri ktorých nevyužívame umelú inteligenciu, ale sú ľahko implementovateľné na strategicky menej dôležité stroje a dynamickými modulmi využívajúcimi umelú inteligenciu na efektívne vyhodnotenie predikcie porúch v dostatočnom čase na zaplánovanie potrebných činností údržby.

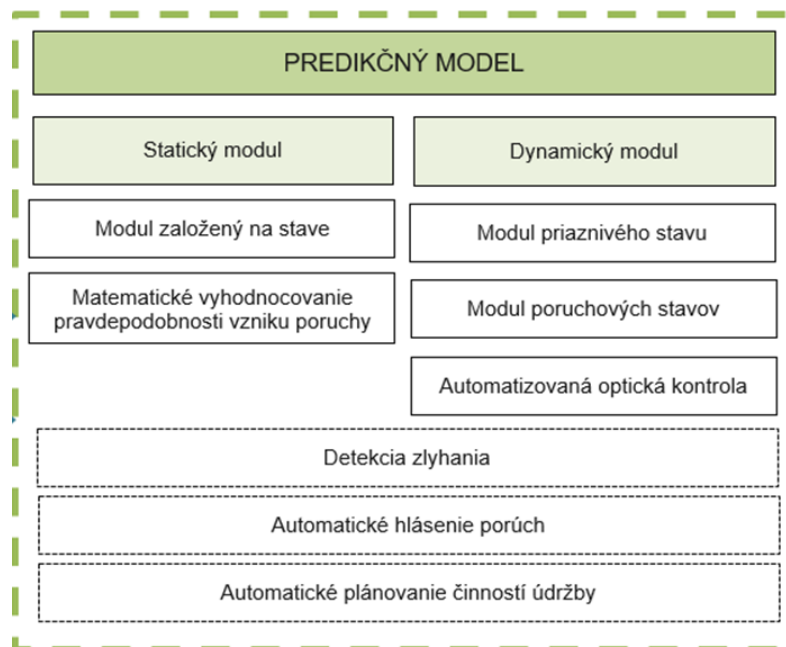
Predikčný model spája súčasný systém údržby a inteligentný systém údržby na celopodnikovej úrovni (Obr. 4). Vždy musí vychádzať zo súčasného stavu zariadenia a historických údajov na danom zariadení. Výstupy z prediktívneho modelu vstupujú do inteligentného systému údržby ako informácie, ktoré je nutné zapracovať do automatického hlásenia porúch v správnom čase a správnym ľuďom,

automatického plánovania činností údržby a automatickej inventarizácie nástrojov a náhradných dielov.



Obr. 4 Pozícia inteligentného systému údržby vzhľadom na stroj a udržateľný výrobný systém (vlastné spracovanie)

Samotný navrhnutý predikčný model pozostáva zo statických a dynamických modulov. Statické module sú navrhnuté na princípe technickej diagnostiky a vyššej štatistiky. Dynamické module, okrem technickej diagnostiky a vyššej štatistiky, využívajú umelú inteligenciu v type strojového učenia, teda ako inteligentné samo-učiace sa algoritmy.



Obr. 5 Predikčný model v inteligentnom systéme údržby (vlastné spracovanie)

Ďalším prínosom predikčného modelu do inteligentného systému údržby je automatické hlásenie porúch príslušným pracovníkom údržby podľa jednotlivých modulov a závažnosti detegovaného


problému. Vďaka komunikácií s MES a ľudskými zdrojmi je predikčný model schopný operatívne, automatiky a online hlásiť získanú predikciu nepriaznivých stavov.

Návrh statického modulu pre predikčný model

Pri statickom module predikčného modelu sa využívajú technológie základného monitoringu. Pri statických predikciách je výhoda nízkej ceny zavedenia. Na druhú stranu pri tomto type zavedenia je možnosť k získaniu „falošných chýb“, ktoré sú spôsobené nesprávnym nastavením systému. Taktiež je možné, že sa na anomáliu na zariadení príde príliš neskoro, čo vedie k nezvratným poruchám a dlhým technickým prestojom. Pokiaľ sa tieto systémy správne nasadia a nastaví, podľa jednotlivých strojov a ich kritických konštrukčných celkov, môžu byť veľmi nápomocné pri riešení konceptu predikčného modelu na celopodnikovej úrovni. Pre návrh predikčného modelu boli navrhnuté dva statické module.

Modul založený na stave

Primárna myšlienka tohto modulu je v údržbe na základe technického stavu. Tento modul vychádza zo základného monitoringu pomocou snímačov. Základnou myšlienkou je konvenčné hodnotenie správania procesov na základe statických limitov. Tým, že sa do modulu neimplementuje umelá inteligencia, je určený spodný a horný limit pozorovanej hodnoty. Modul sa nezaobrá hodnotami, ktorá sú v rámci stanoveného intervalu, ale vyhodnotí prekročenie spodného alebo horného limitu daného intervalu.



Obr. 6 Demonštrácia správania sa hodnôt sledovaného parametra v statickom module založenom na stave (vlastné spracovanie)

Matematické vyhodnocovanie pravdepodobnosti vzniku poruchy

Modul matematického vyhodnocovania pravdepodobnosti vzniku poruchy je možné využiť na všetky stroje v podniku. Tento modul predstavuje statické vyhodnocovanie založené na teórii spoľahlivosti stroja, konkrétne vyhodnocovaní pravdepodobnosti vzniku poruchy bez využitia umelej inteligencie.

Následne môžeme určiť pravdepodobnosť poruchy, pre zjednodušenie predpokladáme exponenciálne rozdelenie doby prevádzky medzi poruchami, ako:

$$P(t) = 1 - \exp(-\lambda t), \quad (1)$$

kde $P(t)$ predstavuje pravdepodobnosť poruchy, λ predstavuje intenzitu porúch a t predstavuje čas prevádzky.


Návrh dynamického modulu pre predikčný model

Pri dynamických moduloch predikčného systému pre inteligentný systém údržby sa využívajú možnosti technológií umelej inteligencie na úrovni samoučiaceho sa stroja. Strojové učenie je postavené na

možnosti používať algoritmus, ktorý je schopný vyhodnotiť veci, ktoré pozná bez potreby usmernenia používateľom a je schopný sa vytréňovať a naučiť nové veci, s ktorými sa zatiaľ nestretol. Vďaka týmto predpokladom je to skvelý nástroj a technológia pre využitie v oblasti údržby. Pre využitie umelej inteligencie v oblasti údržby na predikovanie stavu zariadenia je nevyhnutné mať implementované snímače a akčné členy na kritických konštrukčných celkoch. Taktiež je nutné mať k dispozícii výkonný server, kde môže inteligentný algoritmus bežať nonstop, bez zastavenia.

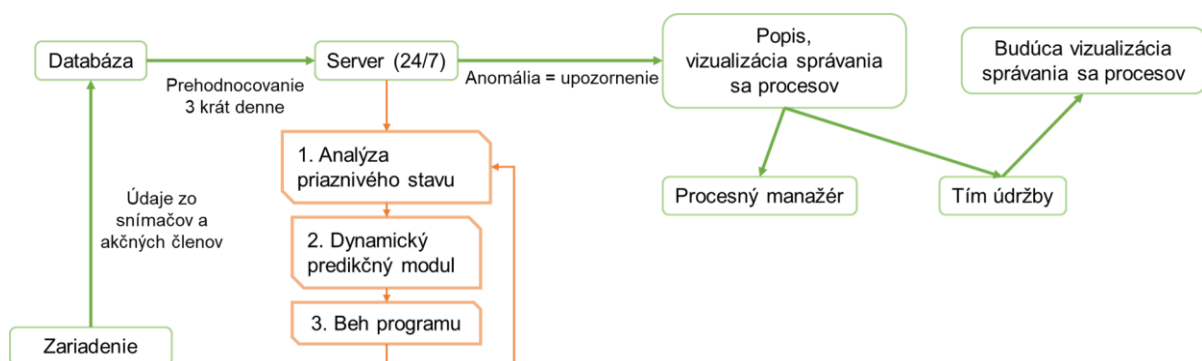
Modul priaznivého stavu

Modul priaznivého stavu predstavuje dynamický modul predikčného modelu. V tomto module sa využíva umelá inteligencia na procesné hodnotenie trendov na základe priaznivého stavu. Podstata tohto modulu je postavená na teórií štatistických trendov v závislosti dvoch kvantitatívnych premenných, ktoré sú v tomto prípade čas a hodnota parametra. Tento modul je vhodný pre stroje kategórie AAA, AA a A, teda strojov s vysokou prioritou, na ktorých keby došlo k výpadku má to veľký dopad na výrobný závod. Veľká výhoda tohto modulu je v malom súbore údajov. Údaje, ktoré vstupujú do predikčného algoritmu sú z inteligentných snímačov a akčných členov v reálnom čase, nie sú potrebné historické dáta o stave zlyhania zariadenia. Ďalšou výhodou využitia tohto modulu je zistenie anomálie okamžite, keď k nej dôjde, pričom nám ponúka predikciu poruchy v dostatočnom predstihu na zaplánovanie činnosti údržby. Navrhnutý modul nedokáže udať žiadny konkrétny dôvod výskytu anomálie.



Obr. 7 Demonštrácia správania sa hodnôt sledovaného parametra v dynamickom module priaznivého stavu (vlastné spracovanie)

Na obrázku (Obr. 8) je vyobrazená navrhovaná dátová architektúra.



Obr. 8 Návrh logiky dátovej architektúry modulu priaznivého stavu (vlastné spracovanie)

Návrh dátovej architektúry začína pri samotnom stroji. Na stroji sú implementované snímače a akčné členy, ktoré posielajú údaje do databázy. Databáza tieto údaje ukladá a posieľa na server, ktorý beží nonstop. Na serveri je najskôr procesným manažérom vytvorený modul priaznivého stavu podľa analýzy údajov tesne po servise. Následne tento modul vytvára dynamický predikčný modul, v ktorom algoritmus umelej inteligencie prehodnocuje dáta a vyhodnocuje štatistické trendy v priebehu behu celého programu. Pokiaľ umelá inteligencia deteguje zmenu trendu, server okamžite posieľa upozornenie o výskyte anomálie na konkrétnom stroji. Upozornenie zahŕňa popis anomálie a vizualizáciu správania sa procesu prostredníctvom grafu závislosti sledovaného parametra a času. Toto upozornenie posieľa e-mailom a systému BI procesnému inžinierovi a tímu údržby. Procesný inžinier spolu s tímom údržby vyhodnotia anomáliu, navrhnú činnosti údržby a zaplánujú tieto činnosti vzhľadom na výrobu a požiadavky dostupnosti stroja. Po vykonaní týchto činností je nutné vytrénovať nový modul priaznivého stavu spolu a celý proces sa opakuje.

Najväčšie výhody navrhovaného dynamického modulu priaznivého stavu predikčného modelu pre inteligentné systémy údržby sú:

- včasne rozpoznanie nadchádzajúceho technického prestoja,
- zabránenie zložitým opravám, ktoré by muselo vykonať technické oddelenie alebo externá firma,
- významný ročný nárast produktivity,
- zvýšenie dostupnosti zariadenia a tým aj OEE.

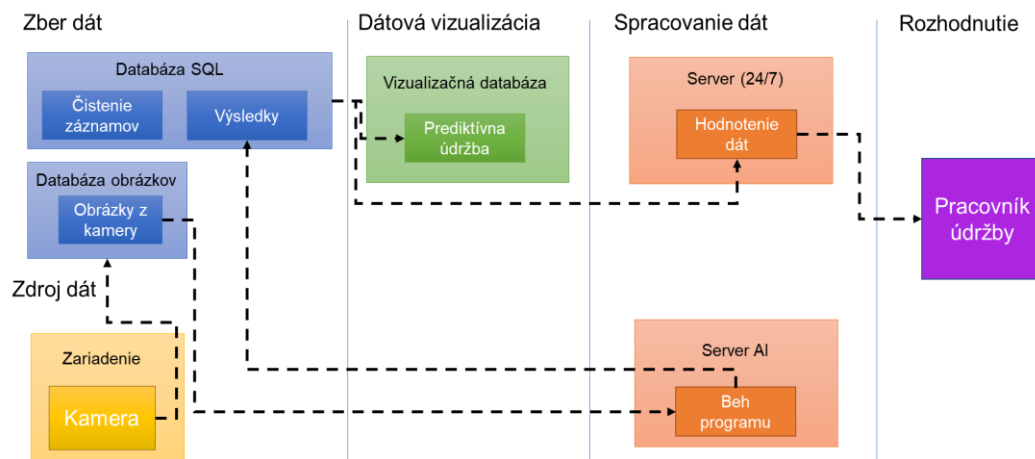
Sledovaný parameter na stroji má kvantitatívny charakter. Druhým údajom vstupujúcim do štatistického prepočtu je čas. Jeden navrhovaný spôsob zistenia závislosti týchto dvoch údajov je využitie štatistickej teórie vyhodnotenia závislosti dvoch kvantitatívnych premenných s využitím Pearsonovho korelačného koeficientu. Druhým spôsobom je štatistická teória časových radov a analýza ich trendovej zložky.

Automatická optická kontrola

Modul automatickej optickej kontroly je jeden z navrhovaných dynamických modulov predikčného modelu pri inteligentnom systéme údržby. Je to nový prístup, ktorý je prebraný z manažérstva kvality do manažérstva údržby. Základný princíp fungovania automatickej optickej kontroly spočíva v nasadení umelej inteligencie, ktorá rozpoznáva obrázky nástrojov a kritických konštrukčných celkov stroja, posielané z kamery. Okrem číselnej hodnoty nám tento modul dokáže vygenerovať stav opotrebenia nástroja alebo kritického konštrukčného celku vo vizualizácií „OK“ a „NOK“.

Na zaradení je nainštalovaná obyčajná kamera, ktorá robí fotky – obrázky. Tieto obrázky sa následne ukladajú do databázy. Obrázky sú zosnímané v pravidelnom intervale podľa potrieb a typu stroja. Následne systém umelej inteligencie preberie z databázy každý obrázok a ohodnotí pravdepodobnosť výskytu anomálie. Túto informáciu uloží do databázy výsledkov. Tieto výsledky vstupujú do hodnotenia dát a vypočítavajú pravdepodobnosť vzniku anomálie v nadväznosti na výsledky, ktoré vyhodnotila umelá inteligencia. Taktiež vstupujú aj do vizualizačnej databázy, ktorá obsahuje vizualizačný systém a pracovníci údržby si môžu pozrieť vyhodnotenie dát na časovej osi v závislosti od definovaných premenných. Pokiaľ server na vyhodnotenie dát podľa štatistických pravidiel vyhodnotí určitý trend,

napríklad nárast opotrebenia, pošle notifikáciu na pracovisko údržby. Táto dátová štruktúra je vyobrazená na obrázku (Obr. 9).



Obr. 9 Návrh dátovej architektúry pre modul automatickej optickej kontroly (vlastné spracovanie)

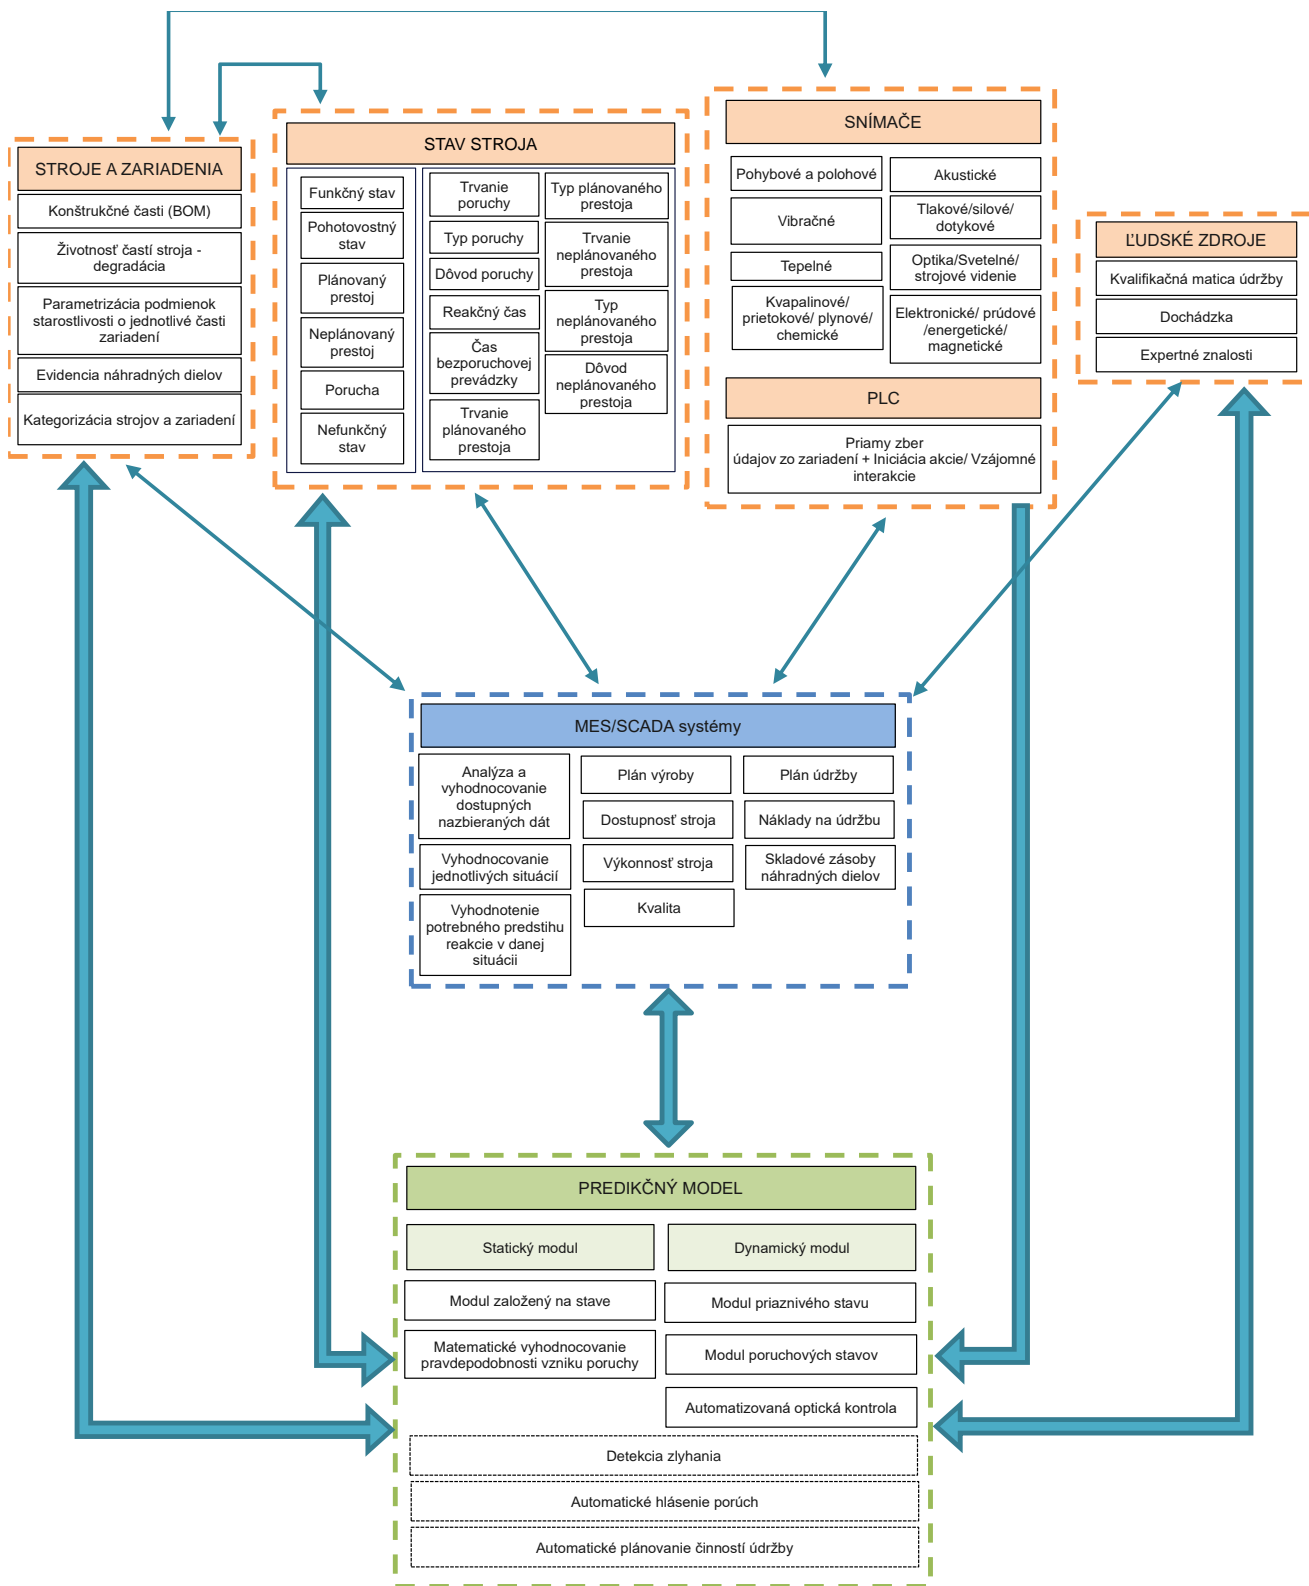
Návrh zaradenia predikčného modelu v rámci inteligentného systému údržby

Návrh zaradenia predikčného modelu údržby v rámci inteligentného systému údržby musí zahŕňať všetky potrebné dáta a prepojenia, aby bol efektívny a využitý.

Údržba zahŕňa činnosti a procesy, ktorých cieľom je udržať aktíva v prevádzkyschopnom stave. Nesmieme zabúdať na to, že údržba predstavuje len podporný proces pre výrobu. Vždy sa údržba musí previazať s výrobou, pretože bez zadaných kritérií pre výrobu, údržba stráca zmysel a taktiež bez činností údržby nie je možné udržať efektívnu a pružnú výrobu. Preto je veľmi dôležité aby tieto dva útvary v podniku medzi sebou neprestajne komunikovali a vytvorili tak inteligentný systém na celopodnikovej úrovni. Takisto ako je údržba podporným útvarom pre výrobu, je inteligentný systém údržby podporným systémom pre inteligentné systémy výroby.

Predikčný model musí zbierať vstupné údaje zo strojov a zariadení, z ľudských a hmotných zdrojov, ale taktiež aj z nadradeného systému výroby, ktorý väčšinou predstavujú MES (Manufacturing Execution System – výrobný informačný systém) a SCADA (Supervisory Control And Data Acquisition – dispečerské riadenie a zber dát) systémy. Na nasledujúcom obrázku (Obr. 10) sa nachádza návrh celkového zasadenia predikčného modelu v rámci inteligentného systému údržby.

Návrh implementácie predikčného modelu v rámci inteligentného systému údržby je postavený na štyroch základných informačných zdrojoch, ktoré predstavujú stroje a zariadenia, stav strojov, snímače a PLC (Programovateľný logický automat) a ľudské zdroje. Najdôležitejším prepojením je prepojenie predikčného modelu s nadradenými výrobnými informačnými systémami.



Obr. 10 Návrh zaradenia predikčného modelu v rámci inteligentného systému údržby (vlastné spracovanie)

Vstupné údaje zo strojov a zariadení

Stroj je základňou pre priemyselnú údržbu. Priemyselná výroba funguje na výrobe produktov pomocou rôznych strojov s rôznymi technológiami. Pokiaľ stroj dosiahne nefunkčný stav, nie je schopný vyrábať daný produkt, teda stráca schopnosť plniť svoju funkciu. Predikčný model pre inteligentný systém údržby má v svojej najjednoduchšej podstate predchádzať nefunkčným stavom strojov a zariadení

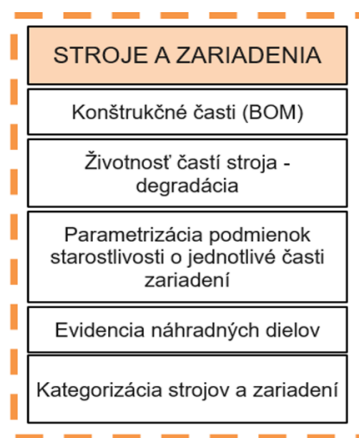
s využitím princípov prediktívnej údržby a najnovšími dostupnými technológiami, ako je napríklad umelá inteligencia vo forme strojového učenia.

Efektívnosť predikčného modelu závisí od samotného stroja. Všeobecné informácie ku každému stroju by mali obsahovať:

- popis objektov a dáta o ich umiestnení,
- popis činností preventívnej údržby a údržby po poruche,
- história preventívnej údržby a údržby po poruche,
- podávanie správ o poruchách a vadách vrátane prevádzkových podmienok,
- modifikácie objektu,
- informácie o materiáloch a náhradných dieloch,
- pracovný postup na objekte,
- stav konfigurácie produktu a dáta o tomto stave,
- servisné dokumenty vydávané výrobcom.

Údaje ekonomického charakteru v súvislosti na náklady údržby by sa mali zbierať, analyzovať a optimalizovať v rámci manažérskeho informačného systému.

Čo sa týka strojov a zariadení je nutné disponovať týmito informáciami pre predikčný model (Obr. 11):



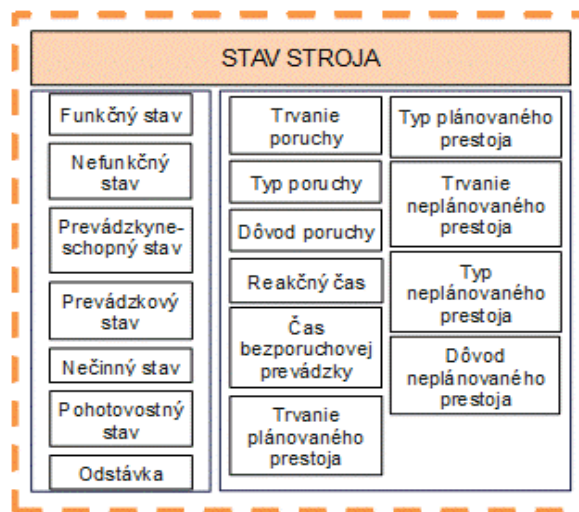
Obr. 11 Stroje a zariadenia v inteligentnom systéme údržby (vlastné spracovanie)

- konštrukčné časti a ich kritickosť,
- životnosť častí stroja,
- parametrizácia podmienok starostlivosti o jednotlivé časti zariadení,
- evidencia náhradných dielov,
- kategorizácia strojov a zariadení.

Vstupné údaje zo stavu stroja

Na to aby sme boli schopní vytvoriť a implementovať efektívny predikčný model, musíme poznať stav stroja a dôvod, prečo k takémuto stavu došlo. Keďže niektoré statické module predikčného modelu

vychádzajú z historických dát je nutné nie len definovať stav stroja, ale aj časové vyčíslenie trvania tohto stavu.

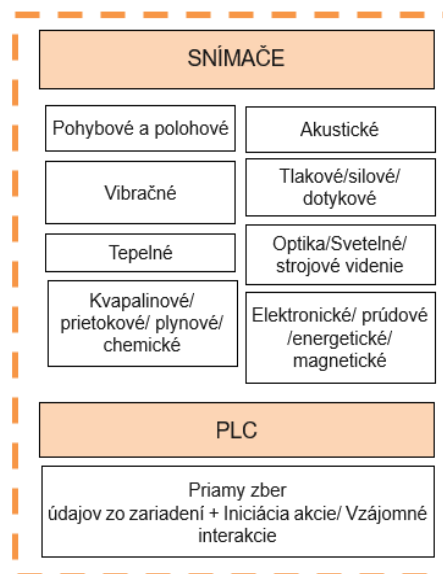


Obr. 12 Stav stroja v inteligentnom systéme údržby (vlastné spracovanie)

Stroj môže mať niekoľko stavov a je nutné tieto stavy identifikovať, zaznamenávať a uchovávať. Ďalej sú to veľmi dôležité vstupné dáta, bez ktorých nebude navrhnutý predikčný model fungovať.

Vstupné údaje zo snímačov

Snímače zaraďujeme k technickým prostriedkom na zber údajov. Sú to zariadenia, ktoré vnímajú podnety založené na fyzikálnych vlastnostiach a odpovedajú prostredníctvom elektrických signálov. Citlivá časť snímača je označovaná ako senzor. Snímač sledovanú fyzikálnu veličinu, ktorou je sledovaný parameter, transformuje na meraciu veličinu podľa definovaného princípu.



Obr. 13 Snímače v inteligentnom systéme údržby (vlastné spracovanie)

Každý snímač funguje na prevode energie. Ide o prenos energie z objektu merania na snímač. Týmto spôsobom dôjde k prenosu informácie.

V pokročilých systémoch údržby, ktoré sú inteligentné je možné využívať aj tzv. inteligentné snímače. Medzi základné požiadavky kladené na inteligentné snímače v súčasnosti patria najmä programovateľné zosilnenie, linearizácia, filtrácia a normalizácia meraného signálu, možnosť automatickej korekcie vplyvu parazitných veličín, pokročilé metódy potlačenia šumu a verifikácia nameraných údajov, autokalibrácia a autodiagnostika, štatistické funkcie, stráženie medzí a možnosť priameho zapojenia snímača do distribuovaných systémov pomocou vhodnej digitálnej komunikačnej zbernice.

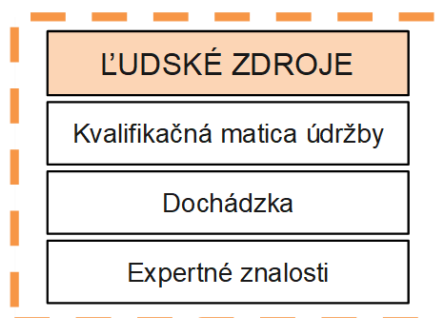
Snímač musí byť časťou väčšieho systému, ktorý môže zahŕňať iné senzory, prevodníky, prispôsobovacie obvody, signálové procesory, pamäťové zariadenia a aktuátory. Umiestnenie samotného snímača na stroji je spojené s kategorizáciou strojov a definovaním kritických konštrukčných častí strojov. Týmto spôsobom sme schopný získavať údaje o technickom stave zariadenia. Snímače sú nevyhnutnou súčasťou implementácie predikčného modelu, bez snímania technických parametrov na stroji nie je možné implementovať navrhovaný predikčný model. Výhodou je automatická implementácia snímačov pri návrhu stroja a ich osadenie pri konštrukcii nových strojov. Pri starších je možné snímače dodatočne nainštalovať.

Vstupné údaje z hľadiska ľudských zdrojov

Ľudské zdroje boli, sú a budú najdôležitejším faktorom zaistenia údržby. Je jedno, či je reč o interných alebo externých pracovníkoch. Všeobecná príprava pracovníkov údržby je záležitosť školstva (od odborné učilišťa až po vysokoškolské), ale aj výrobných podnikov. Mimoriadna príprava musí byť venovaná príprave mechatronického zamerania, čiže pracovníkov, ktorý zvládajú elektronické aj mechanické systémy.

Ľudské zdroje stále predstavujú v manažérstve údržby kľúčovú úlohu pri rozhodovaní, plánovaní a rozvrhovaní údržby. Predikčný model by mal predikovať neželaný stav a navrhnúť činnosti údržby predchádzajúce neželanému stavu. Tieto informácie posielajú pracovníkom údržby a konečné rozhodnutie je na človeku.

Predikčný model v momentálnom pokroku technológií nie je schopný ovládať tzv. samoúdržbu. Samoúdržba predstavuje stav strojov v budúcnosti, ktoré budú vedieť na sebe vykonať údržbu za pomoci iných zariadení prepojených inteligentnými systémami s využitím umelej inteligencie na vysokej úrovni. Momentálne tento stav nie je možný, preto je nevyhnutnosť ľudských zdrojov. Pokiaľ predikčný model odhalí anomáliu na stroji, pošle informáciu zodpovednému pracovníkovi údržby s návrhom činností na odstránenie abnormality na stroji a pracovník údržby tomu nebude venovať pozornosť, predikčný model stráca efektívnosť a v konečnom dôsledku aj význam.



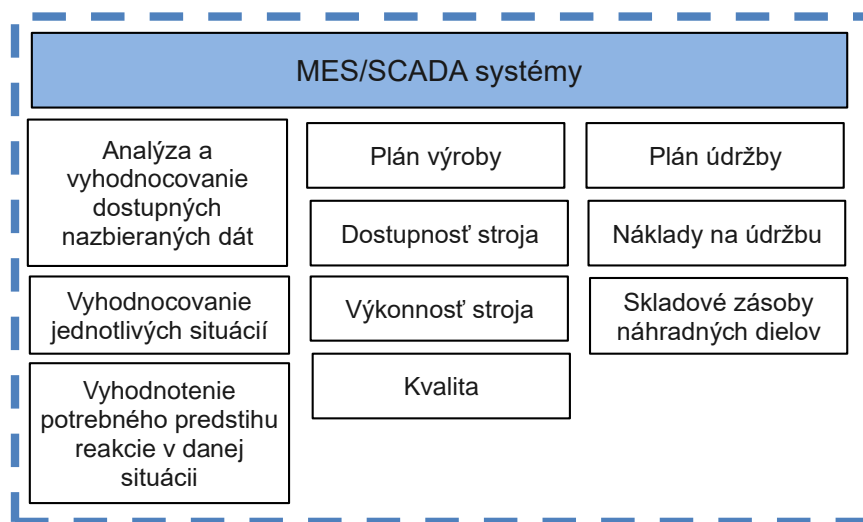
Obr. 14 Ľudské zdroje v inteligentnom systéme údržby (vlastné spracovanie)

Predikčný model by mal byť súčasťou stratégie údržby a mali by ho pracovníci údržby využívať ako užitočný nástroj na predchádzanie nežiadúcim stavom na stroji ako je porucha, alebo nezvratné poškodenie stroja. V rámci ľudských zdrojov s prepojením predikčného modelu je nutné, aby predikčný model disponoval tromi informáciami, ktorými sú kvalifikačná matica údržby, dochádzka a expertné znalosti (Obr. 14).

Prepojenie predikčného modelu s výrobným informačným systémom

Ako už bolo spomínané, údržba je podporný proces pre výrobu a musí jej umožňovať efektívne plniť stanovené ciele. Preto aj inteligentný systém údržby je len podporným systémom inteligentných výrobných systémov. Všetky informácie, ktoré vstupujú do predikčného modelu inteligentného systému údržby je potrebné zhromažďovať, analyzovať a vyhodnocovať v spojení s údržbou.

Na toto spojenie je nutné vytvoriť priamu komunikáciu predikčného modelu s výrobným informačným systémom (MES) alebo dispečerským riadením a zberom dát (SCADA), či už je výrobný informačný systém inteligentný alebo nie. Bez tohto prepojenia je predikčný model nevyužiteľný pre podporu podnikových procesov.



Obr. 15 MES/SCADA systémy v inteligentnom systéme údržby (vlastné spracovanie)

Vyhodnotenie možnosti vykonania preventívnej údržby v závislosti od predikčného modelu

Predikčný model s využitím všetkých modulov upozorní na abnormalitu v skúmaných parametroch. Na to, aby bolo možné stroj uvoľniť pre potreby činností údržby v konkrétnom zvolenom čase na základe predikcie, je nutné brať do úvahy kritéria v súvislosti s ostatnými procesmi v podniku. Týmito kritériami je myslené:

- kritérium náhradných dielov,
- kritérium pracovnej sily,
- kritérium výroby,
- kritérium kvality.

S týmito kritériami, spolu s kritériom predikcie, je možné určiť, kedy je optimálny čas na vykonanie činností údržby.

Kritérium, ktoré predstavuje hodnotu výsledkov predikčného modelu v závislosti od možnosti vykonania preventívnej údržby je **kritérium predikcie** K_{Pr} . Hodnota kritéria predikcie sa mení v závislosti od použitého modulu prediktívneho modelu na konkrétnom stroji.

Pri statickom module založenom na stave môže kritérium predikcie dosahovať nasledujúce hodnoty:

- 0 – pri žiadnom upozornení o prekročení intervalu hodnôt,
- 0,2 – pri prvom až treťom upozornení o prekročení intervalu hodnôt,
- 0,4 – pri štvrtom až šiestom upozornení o prekročení intervalu hodnôt,
- 0,6 – pri siedmom až deviatom upozornení o prekročení intervalu hodnôt,
- 0,8 – pri desiatom až pätnástom upozornení o prekročení intervalu hodnôt,
- 1 – pri dosiahnutí počtu viac ako 16 upozornení o presiahnutí intervalu hodnôt.

Pri matematickom vyhodnocovaní pravdepodobnosti vzniku poruchy kritérium predikcie dosahuje hodnoty od 0 po 1, ktoré je rovné vypočítanej pravdepodobnosti.

Pri nasadenom module priaznivého stavu dosahuje kritérium predikcie hodnoty podľa počtu zaznamenaných zmien štatistického trendu resp. závislosti sledovaného parametra v čase. Tieto hodnoty nadobúda nasledovne:

- 0 – pri nezaznamenaní zmeny štatistického trendu parametra,
- 0,5 – pri prvom upozornení o zmene štatistického trendu sledovaného parametra,
- 0,8 – pri druhom upozornení o zmene štatistického trendu,
- 1 – pri dosiahnutí počtu tri a viac upozornení o zmene štatistického trendu.

Z týchto parametrov je možné určiť výpočet možnosti vykonania činnosti údržby s využitím predikčného modelu ako:

$$MU(t) = K_{ND} * K_P * K_V * K_K * K_{Pr}, \quad (2)$$

kde MU predstavuje možnosť vykonania údržby a t predstavuje plánovaný čas vykonania údržby, K_{ND} predstavuje kritérium náhradných dielov, K_P predstavuje kritérium pracovníkov, K_V predstavuje kritérium výroby a K_K predstavuje kritérium kvality. Všetky kritéria musia byť počítané v plánovanom čase vykonania činností údržby.

Možnosť vykonania údržby môže dosahovať hodnoty od 0 po 1. Pri nasadení predikčného modelu je zo začiatku interval rozdelený do troch úrovní, podľa tretín dosahovania hodnoty možnosti vykonania údržby:

- Pokiaľ sa hodnota $MU(t)$ nachádza v intervale $(0;0,33>$, má iba informačný charakter a nie je možné vykonať v termíne t činnosti preventívnej údržby.
- Pokiaľ sa hodnota $MU(t)$ nachádza v intervale $(0,33;0,66>$, je nutné zabezpečiť všetky zdroje a expertný tím odkonzultuje zaplánovanie tohto termínu vykonania údržby v čase t do plánu údržby.

- Pokiaľ sa hodnota $MU(t)$ nachádza v intervale $(0,66;1>$, je nutné okamžite reagovať, vykonať opatrenia na dostupnosť zdrojov a neodkladne zaplánovať údržbu.

Tieto intervaly sú odporúčané a pri jednotlivých strojoch sa bude rozptyl intervalov možnosti vykonania údržby definovať z historických údajov a požiadaviek spoločnosti.

Kritérium náhradných dielov K_{ND} je určené zásobou náhradných dielov a náhradných konštrukčných celkov pre potrebu vykonania činností údržby na konkrétnom stroji. Kritérium môže nadobúdať hodnoty od 0 po 1. Hodnota kritéria na úrovni 0 znamená, že náhradné diely nie sú k dispozícii na sklade, nie sú na ceste a nie sú objednané. Hodnota kritéria na úrovni 1 znamená, že všetky potrebné náhradné diely pre potreby údržby sú na sklade. Pokiaľ je hodnota kritéria v plánovaný čas preventívnej údržby t menšia ako 1, môže to byť z dvoch dôvodov:

- náhradné diely nie sú na sklade a nie sú objednané,
- náhradné diely nie sú na sklade, ale sú objednané.

Pokiaľ kritérium predikcie, na základe konkrétneho predikčného modulu, nadobúda hodnotu vyššiu ako 0, v prípade matematického vyhodnocovania pravdepodobnosti vzniku poruchy vyššiu ako 0,4, je v týchto prípadoch nutné zabezpečiť objednanie náhradných dielov a stanoviť čas t_1 preventívnej údržby, ktorý predstavuje najbližší možný čas po t kedy sú na sklade dostupné všetky potrebné náhradné diely.

Kritérium pracovníkov K_p vychádza z kvalifikačnej matice pracovníkov a môže nadobúdať hodnoty od 0 do 1. Hodnota kritéria na úrovni 0 znamená, že v zadanom čase nie sú k dispozícii žiadni kvalifikovaní pracovníci na vykonanie činností údržby. Hodnota kritéria na úrovni 1 znamená, že máme plne naplnené a voľné kapacity pracovnej sily na vykonanie činnosti údržby a v potrebnej kvalifikácii. Pokiaľ je hodnota kritéria plánovaný čas preventívnej údržby t menšia ako 1, znamená to, že v čase t nie je voľný potrebný počet kvalifikovaných zamestnancov údržby a je nutné zmeniť plánovaný čas preventívnej údržby na čas t_2 , ktorý predstavuje najbližší možný čas po t , vykonania činností údržby s plnými pracovnými kapacitami podľa požiadaviek.

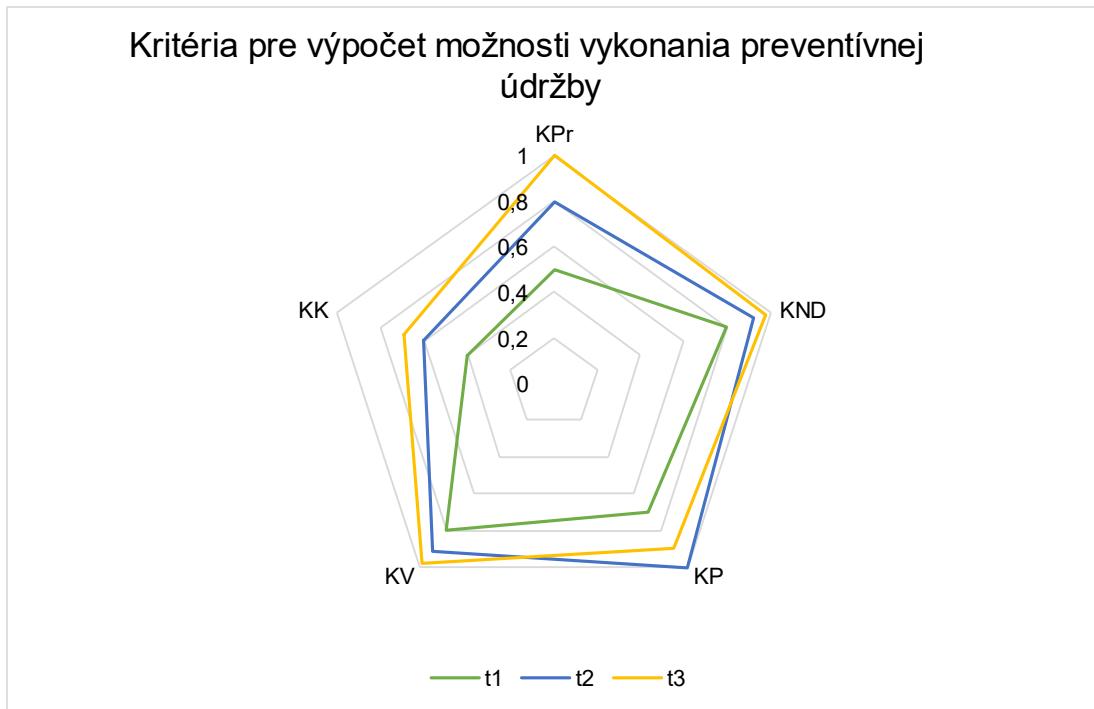
Kritérium výroby K_v predstavuje percentuálne naplnenie výrobného plánu. Môže nadobúdať hodnoty od 0 po 1. Čím väčší je tento parameter, tým viac je naplnený výrobný plán a je možné stroj uvoľniť z výroby na potreby údržby.

Kritérium kvality K_k je možné interpretovať cez celkovú efektívnosť zariadenia. Činnosti preventívnej údržby je vhodné robiť, pokiaľ klesá kvalita výroby. Kritérium môže nadobúdať hodnoty od 0 po 1. Vypočíta sa ako:

$$K_K = 1 - Q = 1 - \frac{\text{počet vyrobených kusov} - \text{počet nezhodných kusov}}{\text{počet vyrobených kusov}}, \quad (3)$$

kde K_K predstavuje kritérium kvality a Q predstavuje kvalitu výroby na konkrétnom stroji.

Následne na základe rozhodnutia o vykonaní preventívnej údržby založenom na výpočte možnosti vykonania údržby, plánuje údržby v dostatočnom predstihu naplánuje činnosti údržby v stanovenom čase, kedy sú splnené kritéria. V dôsledku splnenia jednotlivých kritérií je možné efektívne plánovať činnosti preventívnej údržby s minimálnym dopadom na plán výroby, s efektívnym využitím pracovníkov údržby a včasne reagovať na potreby náhradných dielov.



Obr. 16 Príklad vizualizácie kritérií pre možnosť vykonania údržby v troch plánovaných časoch pomocou pavučinového diagramu (vlastné spracovanie)

Predikčný model zabezpečuje kritérium optimálneho času preventívnej údržby a predchádza situáciám, ktoré sa môžu vyskytnúť pri plánovanej údržbe v dopredu stanovaných intervaloch, ktoré sú:

- preventívna údržba sa vykoná skôr ako je to potrebné, čo má negatívny dopad na efektivitu stroja,
- preventívna údržba sa vykoná neskoro a hrozí vysoké riziko vzniku poruchy, znehodnotenia polotovaru alebo nenávratné zničenie stroja. Takéto poruchy majú výrazný negatívny dopad na výrobu, kvalitu a ziskovosť podniku.

DOSIAHNUTÉ VÝSLEDKY

Metodika bola overovaná v podniku Johns Manville Slovakia, a. s. Pre potreby dizertačnej práce a overenia navrhnutého predikčného modelu v podniku bol vybraný jeden stroj, ktorý je zaradený do kategórie „A“, čo znamená, že stroj je pre podnik kritický. Na tomto stroji bola následne implementovaná časť predikčného modelu, nazvaná modul priaznivého stavu.

Vstupné dáta pre modul priaznivého stavu zo sekačky GFM-D

Pre potreby dizertačnej práce bolo vybrané nasadenie a overenie funkčnosti modulu priaznivého stavu. Tento modul je navrhnutý na stroj, ktorý patrí do kategórie „A“, teda je pre daný podnik kritický.

Po vykonaní analýzy kritických a konštrukčných celkov (ktorá je interný údaj spoločnosti a nebola sprístupnená pre potreby tejto práce) a osobnej komunikácií s expertným tímom údržby v podniku, boli stanovené dva kritické konštrukčné celky stroja a to:

- posúvacie zariadenie podporného valca z dôvodu konštrukčne daného obmedzenia pre hĺbku zaborenia noža,
- vreteno podporného valca z dôvodu vytvárania tlaku na valec pri činnosti stroja.

Po vyhodnotení kritických konštrukčných celkoch stroja boli definované dva kritické parametre, ktoré budú vstupovať ako vstupné dáta do modulu priaznivého stavu. Týmito parametrami boli definované:

- hĺbka zaborenia noža z [mm] ktorého maximálna hĺbka zaborenia stanovená výrobcom je 2,4 mm,
- tlak podporného valca p [Pa].

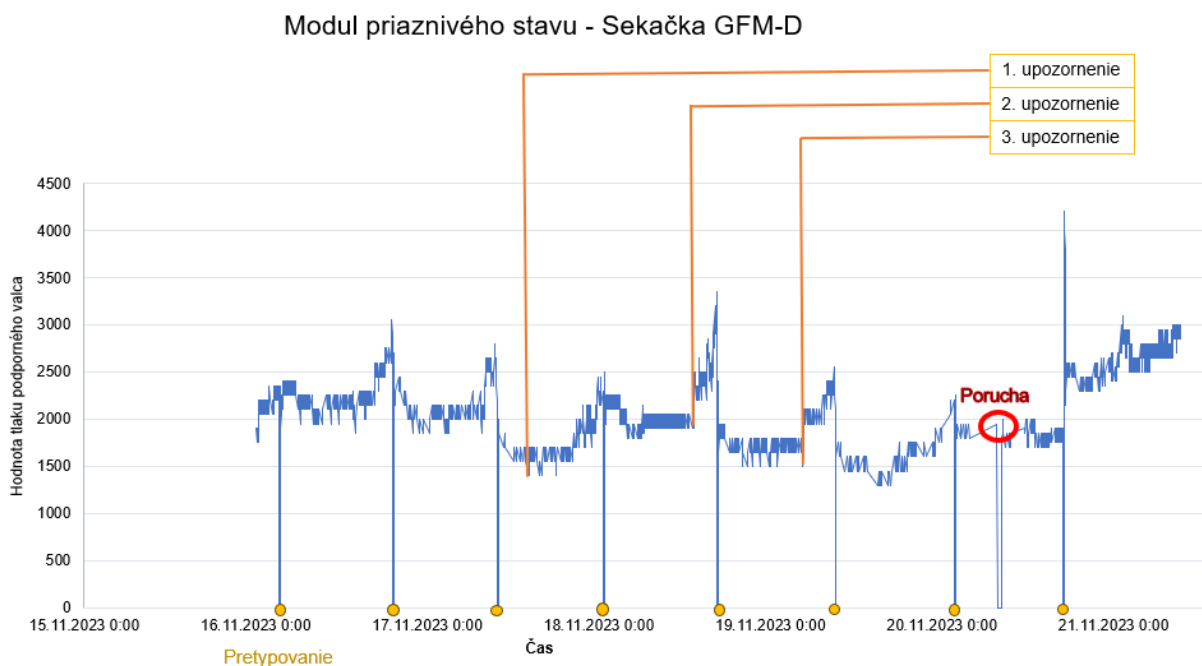
Nasadenie predikčného modelu na sekačku GFM-D

Nasadenie predikčného modelu na stroji - sekačka GFM-D za pomoci modulu priaznivého stavu.

V spolupráci so spoločnosťou, kde bola vykonávaná dizertačná stáž sa za pomoci špecialistov na programovanie analyzovali historické dáta vývinu kritického parametra v závislosti na vyskytnutých sa poruchách. Výsledky z analyzovania dát ukázali, že parameter môže meniť svoju:

- disperziu,
- koreláciu,
- trendovú zložku strednej hodnoty.

Po vyhodnotení tejto skutočnosti bol vytvorený inteligentný algoritmus a nasadený na historické dáta pre potreby overenia funkčnosti navrhovaného modulu priaznivého stavu. Pre potreby overenia modulu priaznivého stavu bolo vybrané obdobie pred poruchou. Toto obdobie zahŕňa interval od 16.11.2023 0:09 do 21.11. 2023 9:17. V tomto období, konkrétne v čase 20.11.2023 7:51 došlo ku poruche, kedy sa nevytváral tlak na valci. Odstránenie tejto poruchy trvalo do 20.11.2023 8:20. Modul priaznivého stavu v spracovaní algoritmu nasadeného na historické údaje vyhodnotil pred poruchou tri upozornenia. Prvé v čase 17.11.2023 14:11, druhé v čase 18.11.2023 13:21 a tretie v čase 19.11.2023 4:41. Toto overenie je vizuálne interpretované na obrázku (Obr. 17).



Obr. 17 Nasadenie modulu priaznivého stavu na sekačku GFM-D (vlastné spracovanie)

Z výsledkov modulu priaznivého stavu je možné definovať kritérium predikcie, ktoré vstupuje do predikčného modelu. V čase prvého upozornenia kritérium predikcie nadobúda hodnotu $K_{Pr}=0,5$, pri druhom upozornení nadobúda hodnotu $K_{Pr}=0,8$ a pri treťom upozornení nadobúda hodnotu $K_{Pr}=1$. Následne všetky tieto kritéria vstupujú ako vstupné parametre do výpočtu možnosti vykonania údržby.

Výpočet možnosti vykonania údržby

Predikčný model je schopný vyhodnotiť a navrhnúť čas vykonania preventívnej údržby. Pre potreby overenia funkčnosti výpočtu tohto času boli spätne vyhodnotenú dáta pred poruchou. Tieto dáta boli vyhodnotenú v termíne od 16.11.2023 0:09 do 21.11.2023 9:17, rovnako ako bol stanovený interval pre nasadenie modulu priaznivého stavu, z ktorého predikčný model definuje kritérium predikcie.

Pre každé upozornenie boli vypočítané dátumy možnej údržby s zohľadnením kritérií, ktoré sú uvedené v tabuľke (Tab. 1).

Tab 1. Vyhodnotenie možnosti vykonania údržby v konkrétnom termíne podľa kritérií (vlastné spracovanie)

Ozn.	Čas upozornenia	Navrhovaný termín údržby	K_{Pr}	K_{ND}	K_p	K_v	MU(t)
t_1	17.11.2023 14:11	18.11.2023 10:00	0,5	0,5	0,5	0,6	0,075
t_2	18.11.2023 13:21	19.11.2023 09:20	0,8	1	0,5	0,7	0,280
t_3	19.11.2023 4:41	20.11.2023 06:00	1	1	1	0,8	0,800

Predikčný model na základe kritérií z historických dát vyhodnotil dva možné dátumy vykonania preventívnej údržby a to v čase $t_2=19.11.2023$ 09:20 a $t_3=20.11.2023$ 06:00. Taktiež z historických dát vieme, že porucha nastala v čase 20.11.2023 8:20.

Modul priaznivého stavu poslal druhé upozornenie v čase 18.11.2023 13:21, teda 42,98 hod. skôr ako došlo k poruche a naplánoval možný termín činností preventívnej údržby na dátum $t_2=19.11.2023$ 09:20, teda 23 hod. skôr ako došlo k poruche. Následne poslal tretie upozornenie v čase 19.11.2023 4:41, teda 27,65 hod. skôr ako došlo k poruche a naplánoval možný termín činností preventívnej údržby na dátum $t_3=20.11.2023$ 06:00, teda 2,33 hod. skôr ako došlo k poruche.

Toto overenie bolo vypracované na jednom stroji s použitím modulu priaznivého stavu. Taktiež bol modul nasadení na historické dáta, aby bolo možné overiť predikciu a reakciu predikčného modelu na blížiaci sa nežiadúci stav (poruchu). Týmto spôsobom by bolo možné nasadiť modul priaznivého stavu na dáta v reálnom čase.

Podobným spôsobom by bolo možné nasadiť predikčný model na ďalšie stroje, počínajúc kategóriou strojov A s podporou dynamických modulov, kategóriou strojov B s podporou dynamických, alebo statických modulov a následne kategóriou C s podporou statických modulov. Pri vyhodnocovaní jednotlivých kritérií predikcie by predikčný model zbieral a vyhodnocoval dáta v reálnom čase na strojoch vo výrobe a počítal možnosti vykonania činností údržby. Tieto výpočty by smerovali do inteligentného systému údržby, ktorý by im následne pridelil priority a po schválení tímom údržby by operatívne zaplánoval činnosti do plánu údržby.

ZHODNOTENIE PRÍNOSOV NAVRHNUTÉHO RIEŠENIA

V dizertačnej práci bol popísaný návrh predikčného modelu pre inteligentný systém údržby, niekoľko možných modulov predikčného modelu, funkcionality predikovať nežiadúce stavy zariadenia a možnosť uskutočnenia činností údržby v navrhnutom čase.

Prínosy doktorskej dizertačnej práce v oblasti vedy a výskumu

- Rozšírenie poznatkovej základne v oblasti údržby, inteligentného systému údržby a využitia umelej inteligencie v údržbe.
- Návrh statických modulov pre predikčný model.
- Návrh dynamických modulov pre predikčný model.
- Návrh zaradenia predikčného modelu v rámci inteligentného systému údržby.
- Definovanie výpočtu možnosti vykonania údržbových činností na konkrétny čas.

Prínosy doktorskej dizertačnej práce v praktickej oblasti

- Vypracovanie metodického postupu zavádzania predikčného modelu na všetky kategórie strojov v podniku.
- Prehľad technológií využívajúcich umelú inteligenciu, ktoré môže spoločnosť využiť pre zlepšenie prediktívnej údržby.
- Zavedením predikčného modelu pre inteligentné systémy údržby sa implementuje prediktívna údržba a tým je možné operatívne zlepšovať činnosti preventívnej údržby.
- Predikčný model pomôže manažérom údržby včasne detekovať blížiac sa nežiadúce stavy na strojoch, akými sú poruchy, prerušenia a iné neplánované prestoje.
- Zvýšenie plynulosti výroby v podniku.

Ďalšie smerovanie výskumu v predmetnej oblasti

V doktorandskej dizertačnej práci je popísaný návrh predikčného modelu pre inteligentný systém údržby.

V priemyselných podnikoch je stále oblasť údržby a jej zlepšovanie značne zanedbaná. Údržba ako podporný proces priamo vplýva na hlavne podnikové procesy ako je výroba. V momentálnej koncepcii Industry 4.0 a nastupujúcej koncepcii Industry 5.0 už nemá korektívna údržba miesto. Údržba v dnešných podnikoch by mala byť postavená na prediktívnej údržbe, ktorá minimalizuje nežiaduce stavy a neplánované prestoje. Ďalšie smerovanie výskumu v oblasti predikčných modelov a inteligentných systémov údržby by sa malo orientovať na nasledujúce oblasti:

- návrh implementácie predikčných modelov v rôznych priemyselných odvetviach,
- návrh softvérových systémov, ktoré intuitívne prepájajú vstupné dáta s predikčnými modelmi, vyhodnocujú a navrhujú činnosti údržby s ohľadom na efektívnosť a plynulosť výroby,

- návrh udržateľnosti a optimalizácie predikčných modelov pre inteligentné systémy údržby,
- výskum v oblasti inteligentných systémov údržby,
- návrh softvérových systémov, ktoré predstavujú inteligentný systém údržby, ako podporný systém pre inteligentné systémy výroby,
- návrh databázy samo učiacich sa algoritmov pre potreby predikovania nežiadúcich stavov na rovinách strojov,
- návrh matematického modelu rozhodovania na základe výsledkov pre predikčné modely,
- výskum a návrh výrobných a podporných procesov v koncepcii samo opraviteľných strojov,
- návrh metodiky projektovania, plánovania a zlepšovania výrobných a podporných procesov v koncepte Industry 5.0.

RESUMÉ

Maintenance is a key aspect of the efficient operation of any industrial system. In today's era, where technology and automation play an increasingly significant role, it is essential to improve maintenance and implement intelligent maintenance systems. These systems leverage advanced technologies such as the Internet of Things (IoT), artificial intelligence (AI), and machine learning (ML) to monitor and predict the condition of equipment. Enhancing maintenance and utilizing predictive models bring numerous benefits, leading to more efficient and cost-effective operation of industrial enterprises. One of the main reasons for improving maintenance is to minimize downtime and increase the reliability of equipment. Traditional maintenance approaches, such as reactive or planned maintenance, often result in unplanned downtime and increased repair costs. In contrast, intelligent maintenance systems enable predictive maintenance, which uses real-time data to forecast failures before they occur. This allows maintenance to be performed precisely when needed, significantly reducing downtime and extending the lifespan of equipment. Predictive models play a crucial role in intelligent maintenance systems. These models analyze historical and real-time data using machine learning algorithms to identify patterns that indicate potential issues. For example, models can predict component wear, vibrations, temperature anomalies, and other factors that may lead to failure. By implementing predictive models, companies can proactively address problems, leading to reduced maintenance costs and increased overall efficiency. The importance of intelligent maintenance systems is also evident in the context of improving safety. Unplanned outages and failures can lead to dangerous situations and endanger workers' health. Predictive maintenance reduces the risk of such events by identifying and addressing issues before they arise. In conclusion, improving maintenance and integrating predictive models in intelligent maintenance systems bring numerous advantages, including reducing downtime, increasing equipment reliability and safety, and optimizing costs. These technologies represent the future of maintenance in the industry, and their implementation is crucial for maintaining competitiveness and efficiency in today's dynamic environment. The dissertation deals with a predictive model for an intelligent maintenance system. The introductory chapter describes the theoretical foundations in the field of maintenance. The second chapter outlines the current state of maintenance, intelligent maintenance systems, technical diagnostics, and also analyzes the current state of maintenance research within the Industry 4.0 concept, as well as the current state of maintenance and the use of intelligent maintenance systems in industrial practice. Subsequently, the conclusion from the analysis in the addressed area is described, from which the objectives of the dissertation are derived. The fifth chapter describes the design of the predictive model for the intelligent maintenance system. The conclusion of the dissertation discusses the verification of the proposed model in industrial practice and evaluates the benefits of the dissertation.

ZOZNAM POUŽITEJ LITERATÚRY

ABIDI, M.H., MOHAMMED, M. K., ALKHALEFAH, H. 2022. *Predictive Maintenance Planning for Industry 4.0 Using Machine Learning for Sustainable Manufacturing*. In: Sustainability 2022, 14, 3387. <https://doi.org/10.3390/su14063387>.

AHMAD, R., KAMARUDDIN, S. 2012. *An overview of time-based and condition-based maintenance in industrial application*. In: Computers & Industrial Engineering, Volume 63, Issue 1, Pages 135-149, ISSN 0360-8352, <https://doi.org/10.1016/j.cie.2012.02.002>.

AL-NAJJAR, B. 2012. *On establishing cost-effective condition-based maintenance: Exemplified for vibration-based maintenance in case companies*, Journal of Quality in Maintenance Engineering, Vol. 18 Iss: 4 pp. 401 - 416

ALSYOUF, I. 2004. *Cost effective maintenance for competitive advantages*. [PhD Thesis], Växjö University, Sweden, 2004, 98p.

ALZGHOUL, A., BACKE, B. LOFSTRAND, M., BYSTROM, A., LIJEDAHL, B. 2014. *Comparing a knowledge-based and a data-driven method in querying data streams for system fault detection: A hydraulic drive system application*. In: Computers in Industry, Volume 65, Issue 8, 2014, Pages 1126-1135, ISSN 0166-3615, <https://doi.org/10.1016/j.compind.2014.06.003>.

ARDENTE, F., MATHIEUX, F. 2012. *Environmental assessment of the durability of energy-using products: method and application*. J. Clean. Prod. 74, 62–73 p.

ARENA, S., MANCA, G., MURRU, S., ORRÚ, P. F., PERNA, R., REFORGIATO RECUPERO, D. 2022. *Data Science Application for Failure Data Management and Failure Prediction in the Oil and Gas Industry: A Case Study*. In: Applied Science 2022, 12, 10617. <https://doi.org/10.3390/app122010617>.

AUGUST, J. 2002. *Applied Reliability-Centered Maintenance*. Oklahoma USA: Penn Well, 2000, 500 p. ISBN 0-878 14-746-2.

BOLEDOVIČ, Ľ. 2017. *CEZ(OEE)*. IPA Slovakia, [online]. [cit. 2023-03-27]. Dostupné na internete: <https://www.ipaslovakia.sk/clanok/cez-oee>.

BONA, G. D., CESAROTTI, V., ARCESE, G., GALLO, T. 2021. *Implementation of Industry 4.0 technology: new opportunities and challenges for maintenance strategy*. In: Proceedings of the 2nd International Conference on Industry 4.0 and Smart Manufacturing (ISM 2020), Procedia Computer Science, 180 (2019) (2021), pp. 424-429, DOI 10.1016/j.procs.2021.01.258.

BOTELHO, S., RETTBERG, A., FILHO, N., HELLINGRATH, B., AMARAL, M., ESPÍNDOLA, D., PEREIRA, C., CORDES, A-K., VENTURA, R., FRAZZON, E. 2014. *Towards Intelligent Maintenance Systems: Rescuing Human Operator and Context Factors*. In IFAC Proceedings Volumes, 47(3), 7110-7115.

BUŠFYOVÁ, M., KASAJOVÁ, M. 2011. *Spôsobilosť výrobných zariadení. Produktivita a inovácie*. SLCP – Slovenské centrum produktivity, Žilina, 2011, ISSN 1335-5961, č.6, Žilina, 2012, s.15-16.

CARSODO, D., FERREIRA, L. 2021. *Application of Predictive Maintenance Concepts Using Artificial Intelligence Tools*. In: Applied Sciences, Vol. 11, no. 1: 18. <https://doi.org/10.3390/app11010018>

CARVALHO, T.P., SOARES, F.A.A.M.N., VITA, R., FRANCISCO, R.D.P., BASTO, J.P., ALCALÁ, S.G.S. 2019. *A systematic literature review of machine learning methods applied to predictive maintenance*. Comput. Ind. Eng. 2019, 137, 106024.

CONVERSO, G., GALLO, M., MURINO, T., VESPOLI, S. 2023. *Predicting Failure Probability in Industry 4.0 Production Systems: A Workload-Based Prognostic Model for Maintenance Planning*. In: Applied Sciences. 2023; 13(3):1938. <https://doi.org/10.3390/app13031938>.

CRONE, S. F., KOURENTZES, N. 2010. *Feature selection for time series prediction – A combined filter and wrapper approach for neural networks*. In: Neurocomputing, Volume 73, Issues 10–12, 2010, Pages 1923-1936, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2010.01.017>.

DAYA-BEN, M., DUFFUAA, S.O. 1995. *Maintenance and quality: the missing link*. Journal of Quality in Maintenance Engineering, Vol. 1 No. 1, pp. 20-26. <https://doi.org/10.1108/13552519510083110>

DEKKER, R., KOURENTZES, N. 1996. *Applications of maintenance optimization models: a review and analysis*. In Reliability Engineering & System Safety, Volume 51, Issue 3, 229-240 p., ISSN 0951-8320, [https://doi.org/10.1016/0951-8320\(95\)00076-3](https://doi.org/10.1016/0951-8320(95)00076-3).

DUFFUAA, S.O., HAROUN, A.E. 2009. *Maintenance Organization; Springer: Singapore*. 2009. pp. 3–15, DOI: 10.1007/978-1-84882-472-0_1.

EIFERT, T.; EISEN, K.; MAIWALD, M.; HERWIG, C. 2020. *Current and future requirements to industrial analytical infrastructure—Part 2: Smart sensors*. Anal. Bioanal. Chem. 2020, 412, 2037–2045.

FACCHINETTI, T., ARAZZI, M., NOCERA, A. 2022. *Time series forecasting for predictive maintenance of refrigeration systems*. In: 2022 IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress (DASC/PiCom/CBDCoM/CyberSciTech), Falerna, Italy, 2022, pp. 1-6, doi: 10.1109/DASC/PiCom/CBDCoM/Cy55231.2022.9927978.

FAMFULÍK, J., MÍKOVÁ, J., KZYŽANEK, R. 2007. *Teorie údržby* [online].

Ostrava: Ediční středisko VŠB - TUO, 2007 [cit. 2017-04-01]. ISBN 978-80-248-

1509-1. Dostupné z: <http://www.elearn.vsb.cz/archivcd/FS/TU/TU/>.

FIRDAUS, N., AB-SAMAT, H. and PRASETYO, B.T. 2023. *Maintenance strategies and energy efficiency: a review*. In: *Journal of Quality in Maintenance Engineering*, Vol. ahead-of-print No. ahead-of-print. <https://doi.org/10.1108/JQME-06-2021-0046>.

FORDAL, J.M., SCHJØLBERG, P., HELGETUN, H. et al. 2023. *Application of sensor data based predictive maintenance and artificial neural networks to enable Industry 4.0*. In: *Advanced Manufacturing* 11, 248–263 (2023). <https://doi.org/10.1007/s40436-022-00433-x>.

FORE. 2022. *An Introduction to Machine Learning, Its Importance, Types, and Applications*. FORE School of Management. [online]. 2022. [cit. 2023-03-06]. Dostupné na internete: <https://www.fsm.ac.in/blog/an-introduction-to-machine-learning-its-importance-types-and-applications/>.

FRAZZON, E., ISRAEL, E., ALBRECHT, A., PEREIRA, C., HELLINGRATH, B. 2014. *Spare parts supply chains operational planning using technical condition information from intelligent maintenance systems*. *Ann. Rev. Control* 38, 147–154 p.

FUSKO, M. 2016. *Towards a new systems of maintenance*. In: *Advanced industrial engineering : new tendencies in production designing : monograph*. – Bielsko-Biala: Wydawnictwo Fundacji Centrum Nowych Technologii, 2016. – ISBN 978-83-927531-8-6. – S. 183-210 [1,49 AH].

GONFALONIERI, A. 2016. *How to Implement Machine Learning For Predictive Maintenance*. In : *Towards Data Science* [online]. [cit. 2023-03-13]. Dostupné na: <https://towardsdatascience.com/how-to-implement-machine-learning-for-predictive-maintenance-4633cdbc4860>

GOTTWALDOVA, A., MANLING, F. 2013. *Sustainability improving in the manufacturing companies*. In: *Proceedings of International Conference on Innovative Technologies IN-TECH, Budapest, 2013*, p. 181-184, ISBN 978-953-6326-88-4.

GRENČÍK, J. a kol. 2013. *Manažérstvo údržby – synergia teórie a praxe*. Košice: Slovenská spoločnosť údržby - BEKI design, 2013, 630 strán, ISBN 978-80-89522-03-3.

HAARMAN, M., DELAHAY, G. 2003. *Value Driven Maintenance – new faith in maintenance*. Dordrecht, The Netherlands, 2003. ISBN 90-808270-2-9.

HAARMAN, M., DELAHAY, G. 2015. *VDM XL, Value Driven Maintenance & Asset Management*. Dordrecht, The Netherlands, 2015. ISBN 9789090292748.

HICHRI, B., DRIATE, A., BORGHESI, A., GIOVANNINI, F. 2022. *Predictive Maintenance Based on Machine Learning Model*. In: Maglogiannis, I., Iliadis, L., Macintyre, J., Cortez, P. (eds) *Artificial Intelligence Applications and Innovations. AIAI 2022. IFIP Advances in Information and Communication Technology*, vol 647. Springer, Cham. https://doi.org/10.1007/978-3-031-08337-2_21.

HIVAREKAR, N., JADAV, S., KUPPUSAMY, V., SINGH, P., GUPTA, C. 2020. *Preventive and Predictive Maintenance Modeling*. 2020 Annual Reliability and Maintainability Symposium (RAMS), Palm Springs, CA, USA, 2020, pp. 1-6, doi: 10.1109/RAMS48030.2020.9153636.

HOOGMARTENS, R., PASSEL, S., ACKER, K., DUBOIS, M. 2014. *Bridging the gap between LCA, LCC and CBA as sustainability assessment tools*. *Environ. Impact Assess. Rev.* 48, 27–33 p.

CHIEN, C.-F.; CHEN, C.-C. 2020. *Data-driven framework for tool health monitoring and maintenance strategy for smart manufacturing*. *IEEE Trans. Semicond. Manuf.* 2020, 33, 1.

CHIRIBĂU, O., FERENT, S., PETRUS, R., Ambrozie, P. U. R. A., CIUPAN, C. 2012. *Reliability and predictive maintenance of dynamic equipment*. ACTA TECHNICA NAPOCENSIS-Series: APPLIED MATHEMATICS, MECHANICS, and ENGINEERING, 55(1).

CHIRIBĂU, O., FERENT, S., PETRUS, R., Ambrozie, P. U. R. A., CIUPAN, C. 2012. *Reliability and predictive maintenance of dynamic equipment*. ACTA TECHNICA NAPOCENSIS-Series: APPLIED MATHEMATICS, MECHANICS, and ENGINEERING, 55(1)

JASIULEWICZ-KACMAREK, M., LEGUTKO, S., KLUK, P. 2020. *Maintenance 4.0 technologies - New Opportunities for Sustainability Driven Maintenance*. In : *Management and Production Engineering Review*. 2020. Vol. 11, No. 1, p. 74 – 87, DOI 10.24425/mper.2020.133730

JOHNS MANVILLE. 2024. *Who We Are*. [online]. [cit. 2024-01-25]. Dostupné na internete: <https://www.jm.com/en/our-company/>

KAHRAMAN, C., ÇEVİK ONAR, S. 2015. *Intelligent Techniques in Engineering Management*. Springer International Publishing Switzerland 2015. *Intelligent Systems Reference Library* 87, DOI 10.1007/978-3-319-17906-3_10.

KALINA, T., JURKOVIČ, M., SKRÚCANÝ, T. 2018. *Diagnostika a údržba lodných zariadení*. Žilina: Žilinská univerzita v Žiline, EDIS – vydavateľské centrum ŽU. 13 s. ISBN 978-80-5541-433-1 .

KARABEGOVIĆ, I.; MAHMIC, M.; HUSAK, E. 2019. *The role of smart sensors in production processes and the implementation of industry 4.0*. *J. Eng. Sci.* 2019, 6, b8–b13

KIJIMA, M. 1986. *Some Results for Repairable Systems with General Repair*; In : *Journal of Applied Probability* , Volume 26 , Issue 1 , March 1989 , pp. 89 – 102 DOI: <https://doi.org/10.2307/3214319>

KLEIN, D. 2020. *Pokročilé štatistické metódy*. Univerzita Pavla Jozefa Šafárika v Košiciach v ŠafárikPress. 2020. 136 s. ISBN 978-80-8152-915-3.

KOBBACY, K., A H. 2012. *Application of Artificial Intelligence in Maintenance Modelling and Management*. In ScienceDirect, IFAC Proceedings Volumes, Volume 45, Issue 31, 2012, Pages 54-59, <https://www.sciencedirect.com/science/article/pii/S1474667015338957>

KOOPMANS, M., JONGE, B. de. 2023. *Condition-based maintenance and production speed optimization under limited maintenance capacity*. In: Computers & Industrial Engineering, Volume 179, 2023, 109155, ISSN 0360-8352, <https://doi.org/10.1016/j.cie.2023.109155>.

LASI, H., FETTKE, P., KEMPER, HG., Feld, T., Hoffmann, M. 2014. *Industry 4.0*. In : Bus Inf Syst Eng 2014;6:239–42. <https://doi.org/10.1007/S12599-014-0334-4/FIGURES/1>.

LEE J, QIU H, NI J. 2004. *Infotronics technologies and predictive tools for next-generation maintenance systems*. In: Proceedings of the 11th IFAC symposium on information control problems in manufacturing, Salvador, Brazil, 5–7 April 2004, pp.291–302. New York: Elsevier.

LEE, J., SINGH, J. 2020. *Intelligent Maintenance Systems and Predictive Manufacturing*. In: Conference: 48th SME North American Manufacturing Research Conference, NAMRC 48At: Cincinnati, OH

LEGÁT, V., POŠTA, J., JURČA, V., HRNČÍŘ, P. 2007. *Systémy managementu jakosti a spolehlivosti v údržbě*. Praha: Česká společnost pro jakost, 2007. 192s. ISBN 978-80-02-01949-7.

LENORT, R. a kol. 2017. *Sustainable solutions for supply chain management*. In: Waldkirchen, Bayern : rw&w Science & New Media Passau-Berlin-Prague, 2017, 184 p., ISBN 978-3-946915-17-1.

LETOT, CH., EQUETER, L., DUTOIT, C., DEHOMBREUX, P. 2017. *Updated Operational Reliability from Degradation Indicators and Adaptive Maintenance Strategy*. [online]. 2020, [cit. 2023-02-17]. Dostupné z: [https://www.intechopen.com/books/system\[1\]reliability/updated-operational-reliability-from-degradation-indicators-and-adaptive-maintenance-strategy](https://www.intechopen.com/books/system[1]reliability/updated-operational-reliability-from-degradation-indicators-and-adaptive-maintenance-strategy).

LU, Y., ZHENG, H., CHAND, S., XIA, W., LIU, Z., XU, X. 2022. *Outlook on human-centric manufacturing towards Industry 5.0*. In: J Manuf Syst 2022;62:612–27. <https://doi.org/10.1016/J.JMSY.2022.02.001>.

LYUBCHYK, L., AKHIEZER, O., GRINBERG, G., YAMKOVYI, K. 2022. *Machine Learning-Based Failure Rate Identification for Predictive Maintenance in Industry 4.0*. In: 12th International Conference on Dependable Systems, Services and Technologies (DESSERT), Athens, Greece, 2022, pp. 1-5, doi: 10.1109/DESSERT58054.2022.10018614.

MARKECHOVÁ, D., STEHLÍKOVÁ, B., TIRPÁKOVÁ, A. 2011. *Štatistické metódy a ich aplikácie*. 2011. Univerzita Konštantína Filozofa v Nitre. ISBN 978-80-80948-07-8.

MEZZEY, P. 2012. *Systém kódovania porúch zariadení s cieľom efektívne využiť metodiku MTBF.* [online]. [cit. 2023-03-27]. atp journal. Dostupné na internete: https://www.atpjournal.sk/rubriky/prehladove-clanky/system-kodovania-poruch-zariadeni-scielom-efektivne-vyuzit-metodiku-mtbf.html?page_id=15532.

MOHAN, T., ROSELYN, J.P., UTHRA, R.A., DEVARAJ D., UMACHANDRAN, K. 2021. *Intelligent machine learning based total productive maintenance approach for achieving zero downtime in industrial machinery.* PERGAMON-ELSEVIER SCIENCE LTD 2021, 157, DOI 10.1016/j.cie.2021.107267.

MOORE, W. J.; STARR, A. G. 2006. *An intelligent maintenance system for continuous cost-based prioritisation of maintenance activities.* Computers in Industry. 57 (6): 596. doi:10.1016/j.compind.2006.02.008. hdl:2299/2247.

MOUBRAY, J. 1997. *Reliability-centered Maintenance.* Industrial Press, New York, 1997, 448 p., ISBN 978-08-31131-46-3

MUSHAVHANAMADI, K., SELOWA, T. 2018. *The impact of plant maintenance on quality productivity in Gauteng breweries.* [online]. 2021, [cit. 2023-02-15]. Dostupné z: <http://ieomsociety.org/dc2018/papers/456.pdf>.

PAČAIOVÁ, H. 2002. *Aplikácia nástrojov pre stanovanie bezpečnej úrovne strojných zariadení.* In Acta Mechanica. ISSS 1335-2393, 2/2002.

PAČAIOVÁ, H. 2009. *Riadenie údržby ako nástroj na zvyšovanie pohotovosti a bezpečnosti prevádzky.* In AT&P Journal [online]. 1/2009. Dostupné online: http://www.atpjournal.sk/buxus/docs/casopisy/atp_2009/pdf/atp-2009-01-22.pdf ISSN 1335-2237.

PAČAIOVÁ, H., SINAY, J., GLATZ, J. 2009. *Bezpečnosť a riziká technických systémov.* Košice : Technická univerzita v Košiciach, Strojnícka fakulta, Katedra bezpečnosti a kvality produkcie. 246 strán. ISBN 978-80-553-0180-8.

PANGBURN, M., STAVRULAKI, E. 2014. *Take back costs and product durability,* European Journal of Operational Research, Volume 238, Issue 1, Pages 175-184, ISSN 0377-2217, <https://doi.org/10.1016/j.ejor.2014.03.008>.

PECH, M., VRCHOTA, J., BEDNAR, J. 2021. *Predictive Maintenance and Intelligent Sensors in Smart Factory: Review.* Sensors. 2021; 21(4):1470. <https://doi.org/10.3390/s21041470>

Peysson F. 2008. *New Approach to Prognostic System Failures.* IFAC Proceedings Volumes, Volume 41, Issue 2, 2008, Pages 12861-12866, ISSN 1474-6670, ISBN 9783902661005, <https://doi.org/10.3182/20080706-5-KR-1001.02175>.

PINCIROLI, L., BARALDI, P., ZIO, E. 2023. *Maintenance optimization in industry 4.0*. In: Reliability Engineering & System Safety, Volume 234, 2023, 109204, ISSN 0951-8320, <https://doi.org/10.1016/j.ress.2023.109204>.

PSAROMMATIS, F., GÖKAN, M., AZAMFIREI, V. 2023. *Envisioning maintenance 5.0: Insights from a systematic literature review of Industry 4.0 and a proposed framework*. In: Journal of Manufacturing Systems, Volume 68, 2023, Pages 376-399, ISSN 0278-6125, <https://doi.org/10.1016/j.jmsy.2023.04.009>.

PSAROMMATIS, F., SOUSA, J., MEDONCA, J.P., KIRITSIS, D. 2022. *Zero-defect manufacturing the approach for higher manufacturing sustainability in the era of industry 4.0: a position paper*. 2022;60: 73–91. <https://doi.org/10.1080/00207543.2021.1987551>.

RAJA, H. A., KUDELINA, K., ASAD, B., VAIMANN, T., KALLASTE, A., RASSÖLKIN, A., KHANG, H.V. 2022. *Signal Spectrum-Based Machine Learning Approach for Fault Prediction and Maintenance of Electrical Machines*. In : Energies 2022, 15, 9507. <https://doi.org/10.3390/en15249507>.

RAKYTA, M. 2002. *Údržba ako zdroj produktivity*. GEORG, Žilina 2002, ISBN 80-968324-3-3.

RAKYTA, M. 2005. *Koncepcia údržby TPM*. Žilina: Žilinská univerzita, 2005. 43 s. ISBN 80-8070-364-7.

RAKYTA, M. 2012. *Koncepcia údržby TPM*. EDIS Žilina 2012, ISBN 80-8070-364-7.

RAKYTA, M., BEZDĚK, J. 2017. *Inovatívne využitie umelej inteligencie v údržbe = Innovative application of artificial intelligence in maintenance*. In: Národné fórum údržby 2017 : 17. ročník medzinárodnej konferencie : 30.- 31. máj 2017, Vysoké Tatry, Štrbské Pleso : zborník prednášok. - Žilina: Žilinská univerzita, 2017. - ISBN 978-80-554-1335-8. - S. 74-81.

RAKYTA, M., BIŇASOVÁ, V. 2016. *Totálne produktívna údržba TPM Total Productive Maintenance*. 1. vyd. - V Žiline : Žilinská univerzita, 2016. - 159 s., ilustr. - ISBN 978-80-554-1210-8.

ROUBAL, J. 2010. *Klasifikace ABC významnosti strojů ve společnosti Automotive Lighting, a.s.* Jihlava. In ÚDRŽBA 2010: sborník přednášek ze 7. mezinárodní konference. Praha: Česká společnost pro údržbu, s 57-61.

SAP Insights. 2023. *Čo je to strojové učenie?* [online]. [cit. 2023-03-27]. Dostupné na internete: <https://www.sap.com/sk/insights/what-is-machine-learning.html>.

SAYED-MOUCHAWEH, M., RAJAOARISOA, L. 2022. *Explainable Decision Support Tool for IoT Predictive Maintenance within the context of Industry 4.0*. In: 21st IEEE International Conference on Machine Learning and Applications (ICMLA), Nassau, Bahamas, 2022, pp. 1492-1497, doi: 10.1109/ICMLA55696.2022.00234.

SHOORKAND, H. D., NOURELFATH, M., HAJJI, A. 2023. *A deep learning approach for integrated production planning and predictive maintenance*, In: International Journal of Production Research, DOI: 10.1080/00207543.2022.2162618.

SCHMITT, R.H.; VOIGTMANN, C. 2018. *Sensor information as a service–component of networked production*. J. Sens. Sens. Syst. 2018, 7, 389–402.

SILVESTRI, L., FORCINA, A., INTRONA, V., SANTOLAMAZZA, A., CESAROTTI, V. 2020. *Maintenance transformation through Industry 4.0 technologies: A systematic literature review*. Computers in Industry, Volume 123, 2020, 103335, ISSN 0166-3615, <https://doi.org/10.1016/j.compind.2020.103335>.

SIRVIO, K., M. 2015. *Intelligent Systems in Maintenance Planning and Management*. In: Kahraman C., Çevik Onar S. (eds) Intelligent Techniques in Engineering Management. Intelligent Systems Reference Library, vol 87.

SKF. 2023. *Microlog analyzer series*. SKF, [online]. [cit. 2023-09-19]. Dostupné na internete: <https://www.skf.com/ph/products/condition-monitoring-systems/portable-systems/cmxa-ax>.

STAVROPOULOS, G., VIOLOS, J., TSANAKAS, S., LEIVADEAS, A. 2023. *Enabling Artificial Intelligent Virtual Sensors in an IoT Environment*. In: Sensors. 2023; 23(3):1328. <https://doi.org/10.3390/s23031328>

STEHLÍKOVÁ, B. 2004. *Nový Metodologický prístup k prognózovaniu demografických časových radov = a new methodological approach to the demographic time series projection*. In Acta Economica et Informatica, roč. 7, 2004, č. 2, s. 49-52, ISSN 1335-2571.

STUHLÝ, V., POPROCKÝ, R. 2010. *Apriórna spoľahlivosť a RCM, tutoriál 9 pre celoživotné vzdelávanie MANAŽÉR ÚDRŽBY*. EDIS vydavateľstvo ŽU Žilina, 2010, ISBN 976-80-554-0158-4.

STUHLÝ, V., POPROCKÝ, R. 2014. *Údržba strojov a zariadení*. 1. vyd. - Žilina : Žilinská univerzita, 2014. - 359 s. ISBN 978-80-554-0845-3.

STUHLÝ, V., POPROCKÝ, R., RAKYTA, M., GREŇČÍK, J. 2017. *Navrhovanie procesov údržby*. Žilina: Žilinská univerzita v Žiline, EDIS – vydavateľské centrum ŽU. 542 s. ISBN 978-80-554-1315-0.

TALAMI, F., DE BARROS, A. C., SILVA, P. T., VASCONCELOS, A., SANTOS, G. 2023. *AR in remote maintenance: Empirical user research with dyads*. 2023 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW), Shanghai, China, 2023, pp. 425-431, doi: 10.1109/VRW58643.2023.00092.

TEOH, Y. K., GILL S. S., PARLIKAD, A. K. 2023. *IoT and Fog-Computing-Based Predictive Maintenance Model for Effective Asset Management in Industry 4.0 Using Machine Learning*. In: IEEE Internet of Things Journal, vol. 10, no. 3, pp. 2087-2094, 1 Feb.1, 2023, doi: 10.1109/JIOT.2021.3050441.

TESSONI, V., AMORETTI, M. 2022 *Advanced statistical and machine learning methods for multi-step multivariate time series forecasting in predictive maintenance*. In: Procedia Computer Science, Volume 200, 2022, Pages 748-757, ISSN 1877-0509, <https://doi.org/10.1016/j.procs.2022.01.273>.

TITKO, M., NOVÁK, L., JÁNOŠÍKOVÁ, M. 2021. *PRAKTICKÁ ŠTATISTIKA*. Žilinská univerzita v Žiline v EDIS-vydavateľstve UNIZA, ISBN 978-80-554-1814-8.

TORTORA, A.M.R.; DI PASQUALE, V.; FRANCIOSI, C.; MIRANDA, S.; IANNONE, R. 2021. *The Role of Maintenance Operator in Industrial Manufacturing Systems: Research Topics and Trends*. Appl. Sci. 2021, 11, 3193, DOI 10.3390/app11073193

VALENČÍK, Š., STEJSKAL, T. 2015. *Údržba, diagnostika a opravy strojov*. Košice: Technická univerzita v Košiciach. 2015. 230 s. ISBN 978-80-5532-249-0.

WAKEFIELD, R., WATSON, T. 2014. *A reappraisal of Delphi 2.0 for public relations research*. In : Public Relations Review, ISSN-e 0363-8111, Vol. 40, Nº. 3, 2014, 577-584 p. <http://dx.doi.org/10.1016/j.pubrev.2013.12.004> 578

WAN, J., LI, X., DAI, HN., KUSIAK, A., MARTINEZ-GARCIA, M., LI, D. 2021. *Artificial-intelligence driven customized manufacturing factory: key technologies, applications, and challenges*. In: Proc IEEE 2021;109:377–98. <https://doi.org/10.1109/JPROC.2020.3034808>.

YOU, M., LI, L., MENG, G., NI, J. 2010. *Cost-Effective Updated Sequential Predictive Maintenance Policy for Continuously Monitored Degrading Systems*. In IEEE Transactions on Automation Science and Engineering. pp.257-265.

ZHONGHUI, S., YANYING, G., ZHONGHONG, S., SHOUCHEN, Y., BAOYU, H. 2023. *Maintenance cost prediction for the vehicle based on maintenance data*. In: Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering. 2023;0(0). doi:10.1177/09544070221147080.

ZONTA, T., DA COSTA, C.A., RIGHI, R.D.R., DE LIMA, M.J., DA RINDADE, E.S., LI, G.P. 2020. *Predictive maintenance in the Industry 4.0: A systematic literature review*. Comput. Ind. Eng. 2020, 150, 106889.

ZOZNAM PUBLIKAČNEJ ČINNOSTI

BIŇASOVÁ, V., BUBENÍK, P., RAKYTA, M., KASAJOVÁ, M., ŠTAFFENOVÁ, K. 2023. *Industry 4.0 in manufacturing enterprises*. In: In: Technológ [print]. - ISSN 1337-8996. - Roč. 15, č. 2 (2023), s. 83-86 [print].

BIŇASOVÁ, V., BUBENÍK, P., RAKYTA, M., KASAJOVÁ, M., ŠTAFFENOVÁ, K. 2023. *Programmable model of an automated warehouse*. In: Technológ [print]. - ISSN 1337-8996. - Roč. 15, č. 2 (2023), s. 110-113 [print].

BIŇASOVÁ, V., BUBENÍK, P., RAKYTA, M., KASAJOVÁ, M., ŠTAFFENOVÁ, K. 2023. *Evaluation of the possibilities of use of interactive technology in the laboratory*. In: Technológ [print]. - ISSN 1337-8996. - Roč. 15, č. 3 (2023), s. 43-46 [print].

BIŇASOVÁ, V., BUBENÍK, P., RAKYTA, M., KASAJOVÁ, M., ŠTAFFENOVÁ, K. 2023. *Evaluation of new trends and reasons for attendance artificial intelligence at the operational level*. In: Technológ [print]. - ISSN 1337-8996. - Roč. 15, č. 3 (2023), s. 53-56 [print].

BIŇASOVÁ, V., MIČIETA, B., KRAJČOVIČ, M., KASAJOVÁ, M., GABAJOVÁ, G., ŠTAFFENOVÁ, K. 2023. *Possibilities of using 3D printing for the sustainable development of Industry 4.0*. In: Globalization and its socio-economic consequences [electronic] : 22th international scientific conference. - 1. vyd. - Žilina: Žilinská univerzita v Žiline, 2022. - ISBN 978-80-8154-332-6 (online). - s. 63-70 [online].

BODINGEROVÁ, M., DULINA, Ľ., ŠTAFFENOVÁ, K. 2023. *The benefits of digital technology for logistics workers*. In: In: InvEnt 2023: Industrial Engineering - Invention for Enterprise [electronic]. - 1. vyd. - Žilina: Žilinská univerzita v Žiline, 2023. - ISBN 978-83-947909-4-3. - s. 11-15 [online].

BUBENIK, P.; CAPEK, J.; RAKYTA, M.; BINASOVA, V.; STAFFENOVA, K. 2022. *Impact of Strategy Change on Business Process Management*. In: Sustainability 2022, 14, 11112. <https://doi.org/10.3390/su141711112>. CC, V3.

BUČKOVÁ, M., FUSKO, M., RAKYTA, M., ŠTAFFENOVÁ, K. 2021. *Creating an inovated changes with digitization as a marketing tool in production company*. In: International Scientific Conference „Marketing Identity 2021: New changes, new challenges“, 9th November 2021, Trnava, Slovak Republic. ISBN 978-80-572-0220-2. p. 69-79.

BUČKOVÁ, M., RAKYTA, M., ŠTAFFENOVÁ, K. 2022. *The utilisation of 3D printing possibilities in technical service*. In: InvEnt 2022. Invention for Enterprise [electronic]. - 1. vyd. - Žilina: Žilinská univerzita v Žiline, 2022. - ISBN 978-80-970974-4-8. - p. 20-25 [online]. V2.

FUSKO, M., GAŠO, M., BUČKOVÁ, M., ŠTAFENOVÁ, K. 2021. *Digitisation in manufacturing processes in SMES [print, electronic]*. In: Trends and Innovative Approaches in Business Processes 2021 [electronic] = Trendy a inovatívne prístupy v podnikových procesoch 2021 : 24th International Scientific Conference. - 1. vyd. - Košice: Technical University of Košice, 2021. - ISBN 978-80-553-3835-4. - p. 155-160 [CD-ROM].

FUSKO, M., ŠTAFENOVÁ, K., GAŠO, M., KLIMENT, M. 2021. *The system of maintenance kpis for small and medium-sized enterprises*. In: InvEnt 2021: Industrial engineering – Invention for enterprise [electronic, print] : proceedings. - 1. vyd. - Bielsko-Biała: Wydawnictwo Akademii Techniczno-Humanistycznej, 2021. - ISBN 978-83-66249-77-6 (online). - p. 56-59 [online, print].

KASAJOVÁ, M., BUBENÍK, P., RAKYTA, M., BIŇASOVÁ, V., ŠTAFENOVÁ, K. 2022. *Technical preparation of production*. In: Technológ - Ročník 14.; Číslo 3/2022. [electronic, print]. Žilina: Žilinská univerzita v Žiline, 2022. p. 48 – 51. [online, print]. DOI : <https://doi.org/10.26552/tech.J.2022.3>

KASAJOVÁ, M., BUBENÍK, P., RAKYTA, M., BIŇASOVÁ, V., ŠTAFENOVÁ, K. 2022. *The use of 3D printing for the sustainable development of Industry 4.0*. In: Technológ [print]. - ISSN 1337-8996. - Roč. 14, č. 4 (2022), s. 57-61 [print].

RAKYTA, M., BUBENÍK, P., BIŇASOVÁ, V., ŠTAFENOVÁ, K. 2023. *Stratégia údržby a jej vplyv na efektivitu výrobného systému*. In: Vše o průmyslu [electronic] : portál pro moderní výrobu. - č. 27. november (2023), s. [1-5] [online].

RAKYTA, M.; BUBENIK, P.; BINASOVA, V.; MICIETA, B.; STAFFENOVA, K. 2022. *Advanced Logistics Strategy of a Company to Create Sustainable Development in the Industrial Area*. In: Sustainability 2022, 14, 12659. <https://doi.org/10.3390/su141912659>. CC, V3.

ŠTAFENOVÁ, K., RAKYTA, M., KRAJČOVIČ, M., BASTIUCHENKO, V. 2023. *Reducing internal logistics costs by implementing AGVs*. In: InvEnt 2023: Industrial Engineering - Invention for Enterprise [electronic]. - 1. vyd. - Žilina: Žilinská univerzita v Žiline, 2023. - ISBN 978-83-947909-4-3. - s. 73-77 [online].

ŠTAFENOVÁ, K., BIŇASOVÁ, V. 2023. *Intelligent maintenance system*. In: Národné fórum údržby 2023 : 22. ročník medzinárodnej vedecko technickej konferencie : zborník prednášok. - 1. vyd. - Žilina: Vydavateľstvo EDIS, 2023. - ISBN 978-80-554-1972-5. - s. 167-171.

ŠTAFENOVÁ, K., RAKYTA, M. 2021. *Skanowanie laserowe 3D jako narzędzie inżynierii odwrotnej [electronic] = 3D laser scanning as toll of reverse engineering*. In: Technologie, procesy i systemy produkcyjne [electronic, print] = Technologies, processes and systems of manufacturing. - 1. vyd. - Bielsko Biała: Wydawnictwo naukowe Akademii techniczno-humanistycznej w Bielsku-Białej, 2021. - ISBN 978-83-66249-84-4. - p. 172-178.

ŠTAFFENOVÁ, K., RAKYTA, M., BIŇASOVÁ, V. 2022. *Reverse engineering with 3D laser scanning technology support [electronic]. In: Trends and Innovative Approaches in Business Processes 2022 [electronic] = Trendy a inovatívne prístupy v podnikových procesoch 2022 : Proceedings of the 25. International Scientific Conference. - 1. vyd. - Košice: Technická univerzita v Košiciach, 2022. - ISBN 978-80-553-4177-4. - s. 201-206 [online].*

ŠTAFFENOVÁ, K., RAKYTA, M., BIŇASOVÁ, V. 2023. *The use of automated guided vehicles in the internal logistics of the production company. In: TRANSCOM 2023 [electronic] : 15th International scientific conference of young scientists on sustainable, modern and safe transport. - 1 vyd. - Amsterdam: Elsevier, 2023. - s. [1-6] [online].*

ŠTAFFENOVÁ, K., RAKYTA, M., BUBENÍK, P., BIŇASOVÁ, V., KASAJOVÁ, M. 2022. *Proces reverzného inžinierstva s využitím 3D laserového skenovania. Technológ - Ročník 14.; Číslo 3/2022. [electronic, print]. Žilina: Žilinská univerzita v Žiline, 2022. p. 25 – 30. [online, print]. DOI : <https://doi.org/10.26552/tech.J.2022.3>*

ŠTAFFENOVÁ, K., RAKYTA, M., BUČKOVÁ, M. 2022. *3D modelling as a tool to support marketing. In: InvEnt 2022. Invention for Enterprise [electronic]. - 1. vyd. - Žilina: Žilinská univerzita v Žiline, 2022. - ISBN 978-80-970974-4-8. - p. 102-107 [online]. V2.*

ŠTAFFENOVÁ, K., RAKYTA, M., FUSKO, M., ŠTEPO, M. 2021. *New trends and concepts of maintenance management in technical service. In: PRŮMYSLOVÉ INŽENÝRSTVÍ 2021 [electronic] : Mezinárodní studentská vědecká konference : Sborník příspěvků. - 1. vyd. - Plzeň: Západočeská univerzita v Plzni, 2021. - ISBN 978-80-261-0792-7. - p. 220-228 [online].*

VÁVRIK, V., FUSKO, M., BUČKOVÁ, M., GAŠO, M., FURMANNOVÁ, B., ŠTAFFENOVÁ, K. 2022. *Designing of machine backups in reconfigurable manufacturing systems. In: Applied sciences [electronic]. - ISSN 2076-3417 (online). - Roč. 12, č. 5 (2022), p. [1-27] [online]. CC, V3.*