



Česká společnost pro jakost, Novotného lávka 5, 116 68 Praha 1
ÚLOHA PREDIKTIVNÍ ÚDRŽBY VE SPOLEHLIVOSTI, 6. 12. 2022



Úloha prediktivní údržby ve spolehlivosti

Materiály z 83. semináře Odborného centra Spolehlivost,
konaného dne 6. 12. 2022 v Praze

Česká společnost pro jakost, Novotného lávka 5, 110 00 Praha 1, www.csq.cz
© ČSJ 2022



Obsah

| | |
|---|-----------|
| <i>Ing. Jakub Čedík, Ph.D., prof. Ing. Martin Pexa, Ph.D.</i> FUNDAMENTÁLNÍ ZÁKLADY PREDIKTIVNÍ ÚDRŽBY | 3 |
| <i>Ing. Bohuslav Peterka, Ph.D., prof. Ing. Josef Pošta, CSc.</i> PŘEDEPÍANÉ ŠROUBOVÉ SPOJE A MOŽNOST JEJICH PREDIKTIVNÍ ÚDRŽBY | 17 |
| <i>Ing. Jan Novák</i> PREDIKTIVNÍ ÚDRŽBA S VYUŽITÍM TRIBODIAGNOSTIKY | 24 |
| <i>Ing. Jan Hroch, Václav Šimek, prof. Ing. Martin Pexa, Ph.D.</i> PREDIKTIVNÍ ÚDRŽBA – ZKUŠENOSTI Z POHLEDU AUDITŮ ÚDRŽBY | 41 |

Fundamentální základy prediktivní údržby

Ing. Jakub Čedík, Ph.D.

prof. Ing. Martin Pexa, Ph.D.

1. Úvod

Údržba je jednou z kritických činností většiny organizací, prakticky v jakémkoli odvětví ve veřejném i soukromém sektoru. Současný vývoj údržby směřuje od systému údržby po poruše, přes preventivní údržbu k údržbě prediktivní, či přímo proaktivní (preskriptivní) údržbě. Tento příspěvek si dává za cíl vytvořit literární rešerši, zaměřenou na základy prediktivní údržby a jejího využití, především s důrazem na samotnou predikci vývoje technického stavu objektu.

Prediktivní údržba, nebo také předpovídaná údržba, je údržba podle stavu prováděná na základě předpovědi odvozené z analýzy a vyhodnocení významných parametrů degradace objektu [1]. Prediktivní údržba využívá časově závislých dat a znalostí ke stanovení okamžiku poruchy za účelem vyvarování se následkům poruchy a předpovědi zbývajících užitečného života objektu [2]. Koncept prediktivní údržby je znám již řadu let, avšak rozvoj moderních technologií, jako internet věcí, cloudové systémy, možnosti pro zpracování enormního množství dat (Big Data), strojové učení, neuronové sítě, obecně vyšší výpočetní kapacita a další technologie, spojované především s Průmyslem 4.0, umožnily její mohutný výzkum a vývoj v posledních letech [2–5].

Koncept prediktivní údržby je spojován s tzv. Prognostics and Systems Health Management (PHM), což je kompletní cyklus průmyslového řízení. Tento cyklus má 3 hlavní osy – pozorování, analýza a akce [2,6,7]. Někteří autoři spojují PdÚ pouze s osou pozorování a použití inteligentních metod predikce závady [2,8], jiní ji považují za součást všech komponent PHM [9]. Podle Kwon et al. [6] má PHM čtyři dimenze, jsou to *snímání, diagnóza, prognóza a management*. Snímáním vhodně zvolených veličin pomocí vhodně umístěných snímačů umožňuje detekovat anomálie shromažďovat časově závislá data o degradaci objektu. Pomocí diagnostiky lze následně extrahovat informace spojené s poruchami, vyvolaných anomáliemi. Anomálie mohou být způsobeny degradací objektu nebo změnou provozních podmínek. Diagnostika spojuje detekované anomálie s mechanismy poruch a identifikuje rozsah poškození. Prognóza využívá algoritmů k predikci vývoje konkrétního mechanismu poruchy od jeho počátku až po selhání objektu v rámci příslušné hladiny spolehlivosti. Tato dimenze také často vyžaduje dodatečné informace, které senzory neposkytují, jako např. historie údržby a oprav, historické a budoucí provozní podmínky, faktory okolního prostředí apod. [10] Poslední dimenzí je management, který na základě poskytnutých informací činí vhodná rozhodnutí, pomocí nichž lze zabránit katastrofickým selháním, zvýšit pohotovost objektu snížením prostojů a kontrol, prodloužit cykly údržby, provést včasné opravy, snížit náklady životního cyklu díky snížení nákladů na kontrolu, opravy a inventarizaci. [6]

Implementace PHM je možná, podle Climente-Alarcon et al. [7], ve čtyřech krocích: 1) Analýza kritických komponent, 2) výběr vhodných senzorů pro monitoring tech. stavu (CM), 3) vyhodnocení funkcí prognostiky v rámci analýzy dat, 4) matice pro vyhodnocení metodologie nástrojů prognostiky.

Prediktivní údržba je obvykle implementována skrze specializované systémy pro sběr dat nebo informací za účelem diagnostiky nebo predikce. Open System Architecture for Condition Based Monitoring (OSA-CBM) [11], definována v normě ISO 13374, nabízí seznam tradičních funkčních bloků systému prediktivní údržby pro stanovení zbývajících technického života (RUL – remaining useful life) jedné komponenty podléhající jednomu mechanismu poruchy. [12]

F1 – sběr dat; F2 – předzpracování dat; F3 – detekce a identifikace poruch (detekce stavu); F4 – posouzení degradace (stavu); F5 – výpočet RUL (prognostické posouzení); F6 – tvorba hlášení a doporučení [4,12]

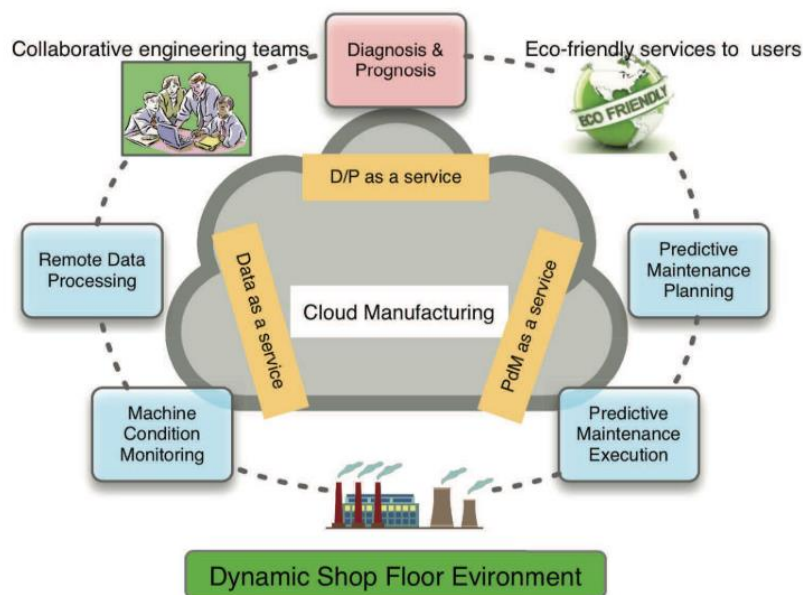
Tyto funkční bloky mohou, ale také nemusí, být přítomny v systému prediktivní údržby, mohou být také duplikovány nebo upraveny v závislosti na použité systémové architektuře a komplexitě technického systému, dostupných datech apod. [13]

Prediktivní údržbu lze rozdělit několika způsoby. Ran et al. [4] rozděluje prediktivní údržbu podle systémové architektury, podle jejího účelu a podle přístupu k predikci. Účelem prediktivní údržby může být minimalizace nákladů na údržbu, maximalizace pohotovosti/spolehlivosti, případně kombinace obou výše zmíněných cílů.

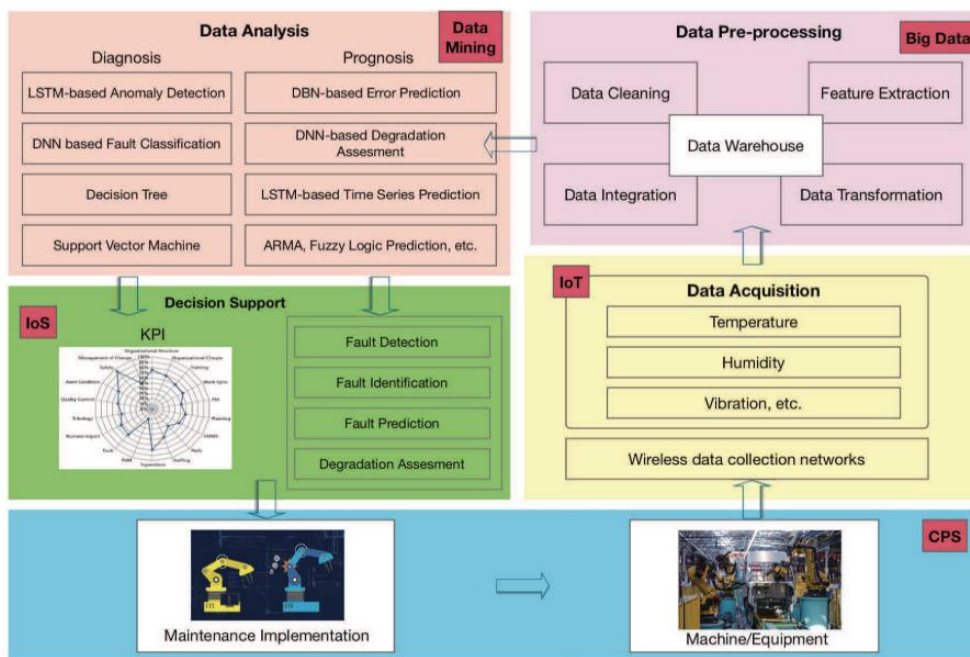
2. Systémové architektury PdÚ

Ran et al [4] rozeznává tři základní modely systémové architektury pro prediktivní údržbu.

- 1) *OSA-CBM* – architektura definovaná ve výše zmiňované normě ISO 13374.
- 2) *Cloud-enhanced* – založená na cloudových technologiích (obrázek 1). Využívá se cloudových výpočetních aplikací, dálkového sběru dat nebo internetu věcí [14,15]. Této architektury se také často využívá při poskytování PdÚ jako služby, díky možnostem dálkového přístupu. Díky cloudovým technologiím lze za využití inženýrských týmů vytvořit expertní znalostní báze v cloudu, ke kterým následně mohou mít přístup uživatelé. [4]
- 3) *Údržba 4.0* – založená na principech průmyslu 4.0 [16–18] (obrázek 2). Systémová architektura pro údržbu 4.0 je navržena v publikacích [16,19].



Obrázek 1 Systémová architektura pro systémovou architekturu PdÚ, založenou na cloudových systémech [4]



Obrázek 2 Systémová architektura pro údržbu 4.0 [4]

3. Přístup k predikci vývoje technického stavu

Publikace rozeznávají v základním pojetí tři až čtyři základní typy přístupů, rozdělení na této základní úrovni je prezentováno v podobném vyznění ve více publikacích [2,4,6,7,12], avšak v případě detailnější klasifikace či rozdělení se již publikace rozcházejí, jelikož na detailnější členění je možno nahlížet z více úhlů pohledu.

1) Přístup na základě fyzikálního modelu

Tento přístup využívá fyzikálních zákonů ve spojení s matematickým modelováním pro předpověď vývoje technického stavu komponent. Tyto modely jsou v řadě odvětví stále předmětem výzkumu, avšak přesný popis fyzikálního chování systému poskytuje také přesné simulace degradačního chování systému nebo komponent [2,6,12,20,21].

Podle Kwon et al. [6] lze postup prognózy podle modelů tohoto typu shrnout do 5-ti bodů: 1) Identifikace mechanismů poruch a jejich rozmístění (například s použitím FMMEA); 2) Monitoring zatížení, které může znamenat opotřebení v průběhu života zařízení a jeho reakcí; 3) Extrakce funkcí z proměnných, měnících se v reakci na zhoršování spojené s mechanismy poruch, identifikovanými v bodě 1; 4) Posouzení poškození a výpočet zbývajících tech. života na základě fyzikálního modelu mechanismů poruch; 5) Posouzení nejistoty a vyjádření TTR jako pravděpodobnostní rozdělení.

Příklady případových studií, využívajících přístup na základě fyzikálního modelu jsou uvedeny v tabulce 1.

Tab. 1 Příklady studií, využívající pro predikci budoucího vývoje technického stavu fyzikální model

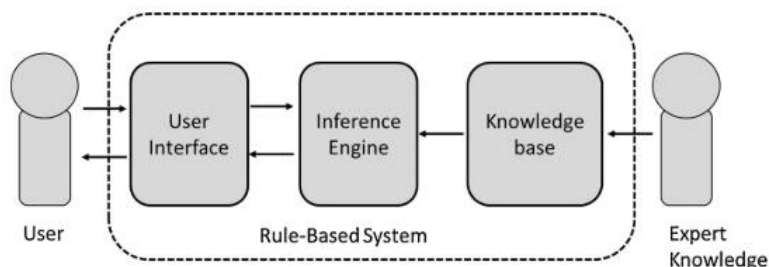
| Zdroj | Popis | Rok |
|-------|--|------|
| [22] | Únavové opotřebení měděných vodičů u offshore větrných turbín – metoda konečných prvků (FEM) | 2012 |

| | | |
|------|--|------|
| [23] | Model, simulující tepelné a mechanické namáhání a poruchy rotorového hřídele během transienčních operací elektrického indukčního motoru. | 2017 |
| [24] | Predikce selhání solenoidových ventilů, založená na FEM | 2015 |
| [25] | Predikce koroze trubek výměníku kotle, podle známého fyzikálního modelu. | 2019 |
| [26] | Predikce zanášení filtru s použitím fyzikálního modelu na základě běžně snímaných veličin. | 2016 |
| [27] | Dynamický model čelního převodu průmyslové převodovky, včetně tření a šíření trhlin | 2001 |

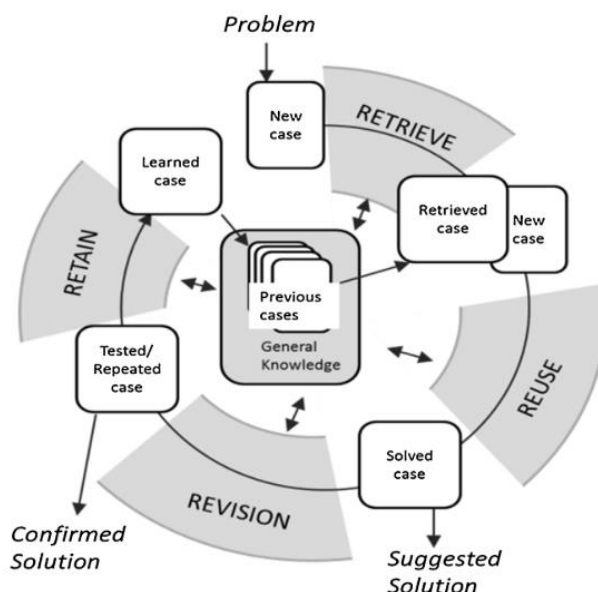
2) Přístup na základě znalostního modelu

Znalostní modely využívají zkušeností, zkušenosti mohou být reprezentovány pravidly, fakty nebo případy, získanými léty provozu a údržbou technických systémů [12]. Tyto modely také snižují komplexitu fyzikálních modelů, proto využívají například expertních systémů nebo fuzzy logiku [2,28]. V literatuře se rozdělení tohoto typu modelu liší. Montero et al. [12] rozlišuje 3 typy znalostních modelů:

- 1) *Založený na pravidlech (rule-based)* – Založené na logice „IF...THEN“. Jsou vytvořena pravidla (znalostní báze), která jsou do určité míry schopna simulovat rozhodování lidského experta [29]. Základní schéma znalostního modelu, založeného na pravidlech je na obrázku 3.
- 2) *Založený na případech (case-based)* – Znalostní báze se v tomto případě skládá z množiny případů a řešení. V případě konfrontace s problémem systém hledá podobnosti s již známými případy. Základní schéma znalostního modelu, založeného na případech je znázorněno na obrázku 4.
- 3) *Založené na fuzzy logice* – V zásadě jsou podobné modelům, založeným na pravidlech s tím rozdílem, že v případě fuzzy logiky existuje na otázku či podmínku, více odpovědí, než pouze pravda a nepravda.[12]



Obrázek 3 Základní schéma znalostního modelu, založeného na pravidlech [12]



Obrázek 4 Základní schéma znalostního modelu, založeného na případech [12]

Slabinou těchto systémů je skutečnost, že bývá obtížné vytvořit dostatečnou znalostní bázi pro přesnou predikci. Při použití pro predikci mají své limity, proto se pro predikci používá často v kombinaci s jinými metodami [12,30–32].

V současné době je báze znalostí často vytvářena pomocí tzv. aplikované ontologie, či jiných data-mining nebo rule-mining technik [4,33–38], kdy je možné vytvořit znalostní bázi na základě rozsáhlých databází. V této oblasti definujeme ontologii jako způsob, jak určit specifický obsah, sdílení a opětovné použití znalostí o pojmenování definic a reprezentaci entit, jejich vlastností a vztahy [39]. Příklady případových studií, využívajících přístup na základě znalostního modelu jsou uvedeny v tabulce 2.

Tab. 2 Příklady studií, využívající pro predikci budoucího vývoje technického stavu znalostní model

| Zdroj | Popis | Rok |
|-------|---|------|
| [40] | Odhad vývoje stavu CNC obráběcího stroje za použití belief-rule-base modelu | 2018 |
| [33] | Model pro diagnostiku nakladačů založený na ontologii | 2018 |
| [30] | Diagnóza a predikce poruch na palubním systému železničního vozidla, založené na textovém case-based rozhodování | 2018 |
| [41] | Expertní systém pro diagnostiku a predikci poruch důlních rypadel | 2012 |
| [42] | OntoProg: Model, pro implementaci PHM pro mechanické stroje, založený na ontologii | 2018 |
| [43] | Fuzzy rule-based přístup pro hodnocení rizik podle Fine-Kinneyho v železniční dopravě | 2018 |
| [44] | Aplikace prediktivní asociativní rule-based politiky údržby pro minimalizaci poruch v ropné rafinerii | 2019 |
| [45] | Sématicky vylepšená rule-based diagnostika pro průmyslový IoT, aplikovaný na vlacích a větrných turbínách Siemens | 2019 |

3) Přístup založený na datovém modelu (data-driven)

Tyto modely, spoléhající se na mnohdy velmi pokročilou datovou analýzu, získávají na významu teprve v posledních letech s rozvojem možností zpracování Big Data a obecně s nárůstem výpočetní kapacity, možností cloudového zpracování dat apod. [4,6,12].

Patří sem modely založené na statistice, stochastice, umělé inteligenci, strojovém učení, rozpoznávání vzorců a anomálií a různé empirické modely, založené na datové analýze a regresi [4,6,12,21,46–48].

Statistické modely cílí na analýzu chování určité proměnné/proměnných v závislosti na zaznamenaných datech. Pro účely prediktivní údržby jsou používány pro stanovení stavu degradace a očekávaného zbývajících života technických systémů. [12] Jedná se především o různé korelační, regresní, autoregresní analýzy autoregresní pohyblivý průměr nebo např. Bayesův model. [7,49–51]

Stochastické modely jsou pravděpodobnostní modely, snažící se odhadnout vývoj určité proměnné v čase, jejichž základními kameny jsou stochastické procesy [12,52]. Lze rozlišit tři stochastické procesy, používané pro prognózu při údržbě:

- 1) *Gaussovské procesy* – je soubor náhodných proměnných nebo libovolný konečný počet, které mají společné Gaussovo rozdělení. Gaussovy procesy lze použít pro nelineární regresi [53]. Tato vlastnost motivovala použití Gaussových procesů pro diagnostiku a prognostiku v oblasti údržby. Podle [54] jsou Gaussovy procesy flexibilní modely pro práci s malými nebo velkými soubory dat pro prognostické účely. K provádění prediktivních úloh však vyžaduje vysoký výpočetní výkon.
- 2) *Markovovy řetězy (Markov chains)* - jsou součástí větší rodiny stochastických nástrojů nazývaných Markovovy procesy. Markovovy řetězce předpokládají, že u daného procesu v jeho současném stavu závisí budoucnost pouze na současném stavu nezávisle na minulosti procesu [12]. Podle [55] jsou hlavní nedostatky Markovových modelů pro prediktivní údržbu: 1) potřeba velkého objemu dat pro trénování, 2) nemožnost modelovat různé stupně degradace a 3) nemožnost modelovat neočekávané poruchy. Protože tyto modely nelze použít k modelování různých stupňů degradace, nejsou vhodné pro opravitelné součásti, které byly částečně restaurovány. Je třeba poznamenat, že složitost modelu se zvyšuje, když degradace nesleduje exponenciální trend [56].
- 3) *Lévyho procesy* – jsou stochastické procesy v rámci rodiny Markovových procesů. Tyto procesy představují pohyb náhodných veličin, jejichž posuny jsou nezávislé a stacionární ve stejně dlouhých časových intervalech. Weinerovy procesy, Gamma procesy a Poissonovy procesy patří do kategorie Lévyho procesů používaných pro prediktivní údržbu [12]. Rozsáhlé přehledy Lévyho procesů pro prediktivní údržbu lze nalézt v [57,58]. Lévy sdílí obecná omezení Markovových procesů. Lévyho procesy jsou v prognostice vázány na monotónní degradační procesy [55,56].

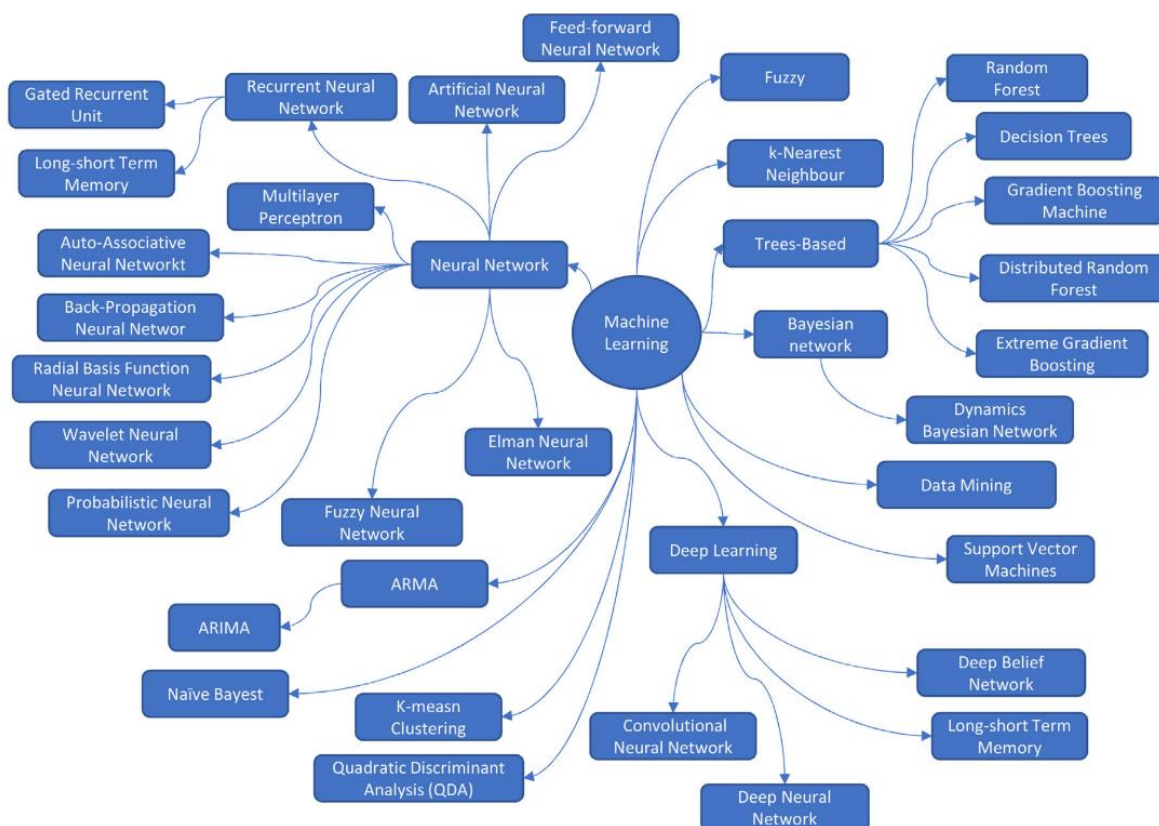
Strojové učení je odvětví umělé inteligence, která využívá speciálních učících se algoritmů pro sestavení modelů z dat nebo databází. Tyto algoritmy jsou schopny zachytit a poradit si s komplexními vztahy v datech, které by jinak bylo obtížné definovat pomocí fyzikálních, statistických nebo stochastických modelů [12].

Podle [8,59] koncept využití strojového učení pro PdÚ zahrnuje několik kroků: 1) *výběr historických dat nebo sběr dat*, - výběr relevantních dat o systémovém zdraví systému [20].; 2) *předzpracování dat* – zpracování a transformace dat pro efektivní zpracování ML modelem - zahrnuje transformaci dat, čištění dat a redukce dat; 3) *výběr modelu, trénink (učení) modelu a jeho validace* – v PdÚ je tento krok také nazýván „maintenance decision-making step“ - a cílí k výběru nejvhodnějšího algoritmu pro konkrétní aplikaci; 4) *Údržba modelu* – cílí na udržení výkonnosti modelu v čase, jelikož průmyslové aplikace se mohou v čase měnit.

Jedním z klíčových znaků modelů strojového učení je právě jejich proces učení a závislost na a použití, cíli a dostupných datech. Montero et al. [12] rozlišuje tři základní typy procesu učení:

- 1) *Učení pod dohledem (Supervised learning)* – používá se když je znám předpokládaný výstup modelu. Učení je iterativní proces, který posuzuje dosaženou chybu oproti předpokládané a proces učení končí v případě, kdy je dosaženo požadované úrovně chyby;
- 2) *Učení bez dohledu (Unsupervised learning)* – používá se v případě, kdy nejsou známy žádné předpokládané výstupy modelu. Pro ukončení procesu učení se používá jiných kritérií, jako například počet iterací nebo průběh konvergenčního indikátoru v čase [60].;
- 3) *Posílené učení (Reinforcement learning)* – zaměřuje se na naučení se modelu ze zkušeností místo z příkladů [61]. Model „interaguje“ s prostředím a v závislosti na interakcích a indikátoru výkonnosti, který se model snaží optimalizovat, obdrží „odměny“. Finální výstupy modelu nejsou známy.

Na obrázku 5 je znázorněna taxonomie technik strojového učení, používaných pro prediktivní údržbu.



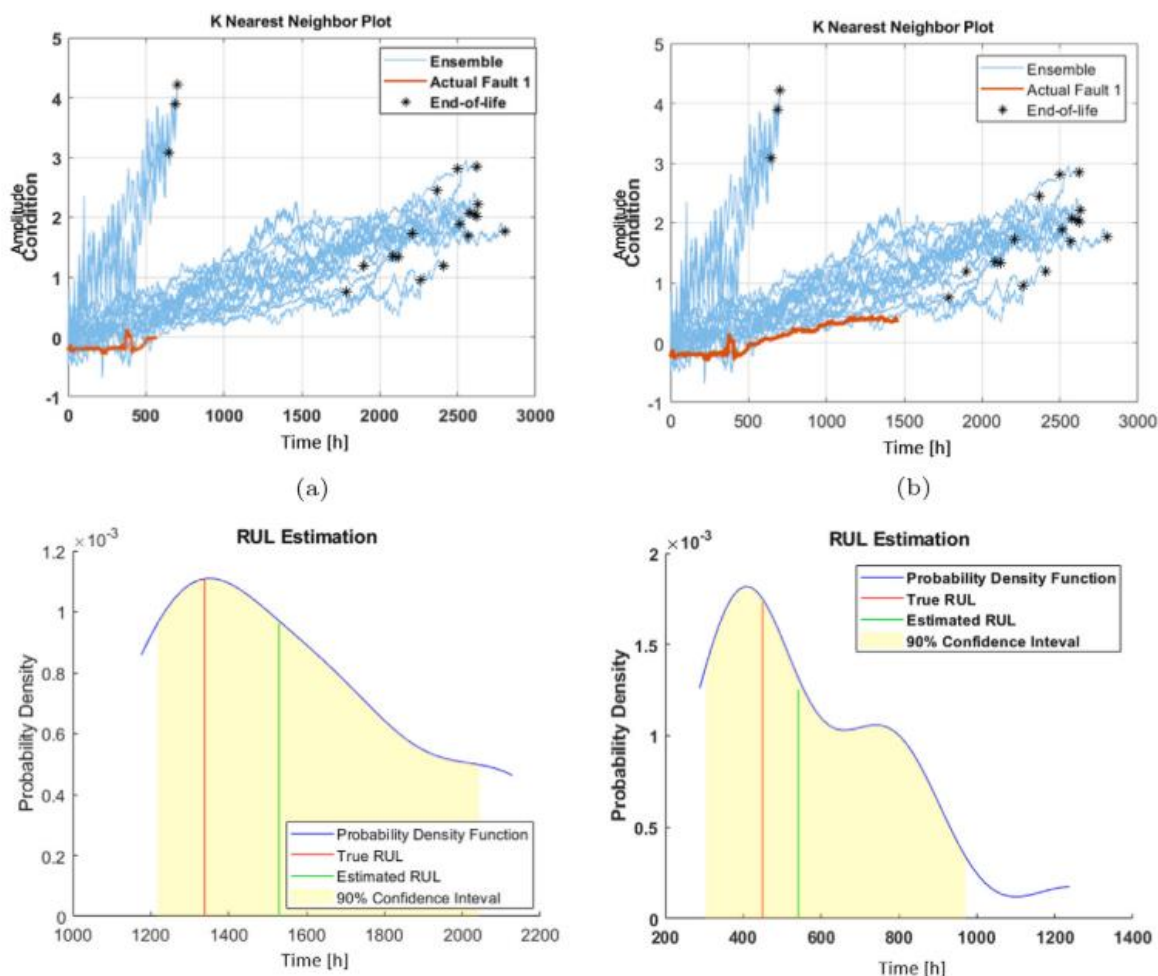
Obrázek 5 Taxonomie používaných technik strojového učení [5]

V rámci identifikovaných modelů strojového učení pro aplikace prediktivní údržby jsou umělé neuronové sítě výpočetními modely inspirovanými biologickými neuronovými sítěmi ve snaze napodobit jejich jedinečné schopnosti zpracování [4,12]. Tyto sítě se skládají z neuronů, každý neuron obdrží více vstupů a produkuje jeden nebo více výstupů, které mohou být zároveň vstupy dalších neuronů. Výstup neuronu se rovná váženému součtu jeho vstupních hodnot pomocí aktivační funkce. Proces učení neurální sítě má za cíl vybrat a upravit váhy vstupů neuronů. Neuronové sítě jsou organizovány do vrstev, tyto vrstvy pak mohou být organizovány v různých konfiguracích (architekturách). V případě použití několika vrstev neuronů lze hovořit o tzv. hlubokém učení (deep learning). V takovém případě lze získat požadovaný výstup (ať už diagnostický nebo prognostický) přímo ze surových dat. Nicméně, i v případě dosažení velmi dobrých výsledků je velmi obtížné detailně porozumět naučenému algoritmu, jeho logice atd. Tento problém se stává závažnějším v případě použití takových algoritmů pro kritické bezpečnostní aplikace, jako například v letectví nebo jaderných elektrárnách [12]. Detailní vysvětlení a popis funkce neurálních sítí a jejich typů lze najít v publikacích [4,5,8,56,62]. Příklady případových studií, využívajících přístup na základě znalostního modelu jsou uvedeny v tabulce 2. Na obrázku 6 je znázorněn výsledek stanovení zbývající délky technického života vodního čerpadla v Dánské elektrárně Studstrupværket při použití podobnostního modelu „k-nearest neighbour“, včetně vyjádření hustoty pravděpodobnosti pro dvě různé doby provozu a stádia degradace.

Tab. 3 Příklady studií, využívající pro predikci budoucího vývoje technického stavu datový model

| Zdroj | Popis | Metoda | Rok |
|---------|---|--|------|
| [63] | Optimalizace údržby geometrie kolejí pomocí data-driven modelu | Markovovy řetězce - Monte Carlo | 2018 |
| [64] | Analýza principiálních komponent a index kvality tratě – porovnání SVM a Linear Discriminant Analysis (LDA) pro detekci geometrických defektů na kolejových tratích a Track Quality Index | LDA, SVM a RF (random forest) | 2018 |
| [65] | Detekce degradace převodovek pomocí autoregresivního modelování a Kolmogorov–Smirnov statistického testu – aplikace v laboratorních podmínkách | Autoregresivní pohyblivý průměr | 2007 |
| [66] | Použití SVM metody pro předpověď blížícího se selhání a alarmu pro kritické komponenty kolejových vozidel | Support vector machines (SVM) - ML | 2014 |
| [67,68] | Detekce anomálií a predikce závažnosti úniků vzduchu z brzdových systémů vlaků na základě dat o chování kompresoru | Regresní analýza + Density-Based Clustering | 2017 |
| [60] | Data-driven detekce, izolace a předpověď poruchy aktuátorů a senzorů leteckých turbínových motorů | Self-organizing map | 2017 |
| [69] | Predikce poruchy ložiska s využitím hluboké konvoluční neuronové sítě | Konvoluční neuronová síť a hluboká neuronová síť | 2018 |

| | | | |
|------|---|---------------------|------|
| [70] | Predikce zbývajícího technického života čerpadla v elektrárně a teplárně s využitím virtuálně generovaných dat. | k-nearest neighbour | 2021 |
|------|---|---------------------|------|



Obrázek 6 Příklad použití metody „k-nearest neighbour“ pro stanovení zbývající délky technického života včetně vyjádření hustoty pravděpodobnosti pro různé doby provozu [70]

4. Závěr

Příspěvek je zaměřen na oblast prediktivní údržby, která v současné době nachází stále více uplatnění v průmyslových aplikacích prakticky ve všech odvětvích. Velký boom zažívají zejména různé datové modely, což si lze vysvětlit především rozvojem dostupné výpočetní kapacity a snímačů.

Trendem se v poslední době stává také využití různých hybridních přístupů k predikci. Ať už se jedná o využití více různých typů neuronových sítí v jedné aplikaci [4,69] nebo o kombinaci základních přístupů fyzikálního, znalostního a/nebo datového modelu [12]. Takovýto hybridní přístup může při správném použití umožnit přesnější a spolehlivější predikci vývoje technického stavu.

Prediktivní údržba je velice perspektivní odvětví údržby, v budoucnu lze očekávat její nasazení u stále většího počtu objektů, ať už ve formě vlastního útvaru údržby nebo poskytnutou jako službu např. od výrobce zařízení.

Použitá literatura

1. ČSN EN 13306 (010660): 2018 Údržba - Terminologie údržby.
2. Zonta, T.; da Costa, C.A.; da Rosa Righi, R.; de Lima, M.J.; da Trindade, E.S.; Li, G.P. Predictive maintenance in the Industry 4.0: A systematic literature review. *Comput Ind Eng* **2020**, *150*, 106889, DOI: 10.1016/j.cie.2020.106889.
3. Silvestri, L.; Forcina, A.; Introna, V.; Santolamazza, A.; Cesarotti, V. Maintenance transformation through Industry 4.0 technologies: A systematic literature review. *Comput Ind* **2020**, *123*, 103335, DOI: 10.1016/j.compind.2020.103335.
4. Ran, Y.; Zhou, X.; Lin, P.; Wen, Y.; Deng, R. A Survey of Predictive Maintenance: Systems, Purposes and Approaches. *IEEE COMMUNICATIONS SURVEYS & TUTORIALS* **2019**, *XX*.
5. Dalzochio, J.; Kunst, R.; Pignaton, E.; Binotto, A.; Sanyal, S.; Favilla, J.; Barbosa, J. Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. *Comput Ind* **2020**, *123*, 103298, DOI: 10.1016/j.compind.2020.103298.
6. Kwon, D.; Hodkiewicz, M.R.; Fan, J.; Shibutani, T.; Pecht, M.G. IoT-Based Prognostics and Systems Health Management for Industrial Applications. *IEEE Access* **2016**, *4*, 3659–3670, DOI: 10.1109/ACCESS.2016.2587754.
7. Atamuradov, V.; Medjaher, K.; Dersin, P.; Lamoureux, B.; Zerhouni, N. Prognostics and Health Management for Maintenance Practitioners - Review, Implementation and Tools Evaluation. *Int J Progn Health Manag* **2017**, *8*, 1–31.
8. Carvalho, T.P.; Soares, F.A.A.M.N.; Vita, R.; Francisco, R. da P.; Basto, J.P.; Alcalá, S.G.S. A systematic literature review of machine learning methods applied to predictive maintenance. *Comput Ind Eng* **2019**, *137*, 106024, DOI: 10.1016/j.cie.2019.106024.
9. Iskandar, J.; Moyne, J.; Subrahmanyam, K.; Hawkins, P.; Armacost, M. Predictive Maintenance in semiconductor manufacturing. In Proceedings of the 2015 26th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC); IEEE, 2015; pp. 384–389.
10. Montgomery, N.; Banjevic, D.; Jardine, A.K.S. Minor maintenance actions and their impact on diagnostic and prognostic CBM models. *J Intell Manuf* **2012**, *23*, 303–311, DOI: 10.1007/s10845-009-0352-0.
11. Lebold, M.; Reichard, K.; Byington, C.S.; Orsagh, R. OSA-CBM Architecture Development with Emphasis on XML Implementations. In Proceedings of the MAINTENANCE AND RELIABILITY CONFERENCE; 2002.
12. Montero Jimenez, J.J.; Schwartz, S.; Vingerhoeds, R.; Grabot, B.; Salaün, M. Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics. *J Manuf Syst* **2020**, *56*, 539–557, DOI: 10.1016/j.jmsy.2020.07.008.
13. Montero Jimenez, J.J.; Vingerhoeds, R. A System Engineering Approach to Predictive Maintenance Systems: from needs and desires to logical architecture. In Proceedings of the 2019 International Symposium on Systems Engineering (ISSE); IEEE, 2019; pp. 1–8.
14. Wang, J.; Zhang, L.; Duan, L.; Gao, R.X. A new paradigm of cloud-based predictive maintenance for intelligent manufacturing. *J Intell Manuf* **2017**, *28*, 1125–1137, DOI: 10.1007/s10845-015-1066-0.
15. Mourtzis, D.; Vlachou, E. A cloud-based cyber-physical system for adaptive shop-floor scheduling and condition-based maintenance. *J Manuf Syst* **2018**, *47*, 179–198, DOI: 10.1016/j.jmsy.2018.05.008.

16. Cachada, A.; Moreira, P.M.; Romero, L.; Barbosa, J.; Leitno, P.; Geraldcs, C.A.S.; Deusdado, L.; Costa, J.; Teixeira, C.; Teixeira, J.; et al. Maintenance 4.0: Intelligent and Predictive Maintenance System Architecture. In Proceedings of the 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA); IEEE, 2018; pp. 139–146.
17. Li, Z.; Wang, K.; He, Y. Industry 4.0 - Potentials for Predictive Maintenance. In Proceedings of the International Workshop of Advanced Manufacturing and Automation (IWAMA 2016); Atlantis Press, 2016; pp. 42–46.
18. Chukwueke, D.O.; Schjølberg, P.; Rødseth, H.; Stuber, A. Reliable, Robust and Resilient Systems: Towards Development of a Predictive Maintenance Concept within the Industry 4.0 Environment. In Proceedings of the EFNMS Euro Maintenance Conference; 2016.
19. Wang, K. Intelligent Predictive Maintenance (IPdM) System – Industry 4.0 Scenario. *WIT transactions on engineering sciences* **2016**, *113*, 259–268, DOI: 10.2495/IWAMA150301.
20. Jardine, A.K.S.; Lin, D.; Banjevic, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mech Syst Signal Process* **2006**, *20*, 1483–1510, DOI: 10.1016/j.ymsp.2005.09.012.
21. Coble, J.; Ramuhalli, P.; Bond, L.J.; Hines, J.W.; Ipadhyaya, B.; Bond, L.; Upadhyaya, B. A Review of Prognostics and Health Management Applications in Nuclear Power Plants. *Int J Progn Health Manag* **2015**, *6*, 1–22.
22. Nasution, F.P.; Sævik, S.; Gjøsteen, Janne.K.Ø. Fatigue Analysis of Copper Conductor for Offshore Wind Turbines by Experimental and FE Method. *Energy Procedia* **2012**, *24*, 271–280, DOI: 10.1016/j.egypro.2012.06.109.
23. Climente-Alarcon, V.; Nair, D.; Sundaria, R.; Antonino-Daviu, J.A.; Arkkio, A. Combined Model for Simulating the Effect of Transients on a Damaged Rotor Cage. *IEEE Trans Ind Appl* **2017**, *53*, 3528–3537, DOI: 10.1109/TIA.2017.2691001.
24. Li, J.; Xiao, M.; Liang, Y.; Tang, X.; Li, C. Three-dimensional Simulation and Prediction of Solenoid Valve Failure Mechanism Based on Finite Element Model. *IOP Conf Ser Earth Environ Sci* **2018**, *108*, art. no 022035, DOI: 10.1088/1755-1315/108/2/022035.
25. Cholette, M.E.; Yu, H.; Borghesani, P.; Ma, L.; Kent, G. Degradation modeling and condition-based maintenance of boiler heat exchangers using gamma processes. **2018**, DOI: 10.1016/j.res.2018.11.023.
26. Eker, O.F.; Camci, F.; Jennions, I.K. Physics-based prognostic modelling of filter clogging phenomena. **2015**, DOI: 10.1016/j.ymsp.2015.12.011.
27. Howardr, I.; Shengxiang, J.; And, J.; Wang, A. THE DYNAMIC MODELLING OF A SPUR GEAR IN MESH INCLUDING FRICTION AND A CRACK. *Mech Syst Signal Process* **2001**, 831–853, DOI: 10.1006/mssp.2001.1414.
28. Ayad, S.; Terrissa, L.S.; Zerhouni, N. An IoT approach for a smart maintenance. *2018 International Conference on Advanced Systems and Electric Technologies, IC_ASET 2018* **2018**, 210–214, DOI: 10.1109/ASET.2018.8379861.
29. Tang, X.; Xiao, M.; Liang, Y.; Zhu, H.; Li, J. Online updating belief-rule-base using Bayesian estimation. *Knowl Based Syst* **2019**, *171*, 93–105, DOI: 10.1016/j.knosys.2019.02.007.
30. Zhong, Z.; Xu, T.; Wang, F.; Tang, T. Text Case-Based Reasoning Framework for Fault Diagnosis and Predication by Cloud Computing. *Math Probl Eng* **2018**, *2018*, DOI: 10.1155/2018/9464971.
31. Zhou, A.; Yu, D.; Zhang, W. A research on intelligent fault diagnosis of wind turbines based on ontology and FMECA. *Advanced Engineering Informatics* **2015**, *29*, 115–125, DOI: 10.1016/j.aei.2014.10.001.

32. Cao, Q.; Samet, A.; Zanni-Merk, C.; de Beuvron, F. de B.; Reich, C. An Ontology-based Approach for Failure Classification in Predictive Maintenance Using Fuzzy C-means and SWRL Rules. *Procedia Comput Sci* **2019**, *159*, 630–639, DOI: 10.1016/j.procs.2019.09.218.
33. Xu, F.; Liu, X.; Chen, W.; Zhou, C.; Cao, B. Ontology-Based Method for Fault Diagnosis of Loaders. *Sensors* **2018**, *18*, 729, DOI: 10.3390/s18030729.
34. Konys, A. An Ontology-Based Knowledge Modelling for a Sustainability Assessment Domain. *Sustainability* **2018**, *10*, 300, DOI: 10.3390/su10020300.
35. Ruiz, P.P.; Foguem, B.K.; Grabot, B. Generating knowledge in maintenance from Experience Feedback. **2014**, DOI: 10.1016/j.knosys.2014.02.002.
36. Grabot, B. Rule mining in maintenance: Analysing large knowledge bases. *Comput Ind Eng* **2020**, *139*, 105501, DOI: 10.1016/j.cie.2018.11.011.
37. Nuñez, D.L.; Borsato, M. An ontology-based model for prognostics and health management of machines. *J Ind Inf Integr* **2017**, *6*, 33–46, DOI: 10.1016/j.jii.2017.02.006.
38. Medina-Oliva, G.; Voisin, A.; Monnin, M.; Leger, J.-B. Predictive diagnosis based on a fleet-wide ontology approach. *Knowl Based Syst* **2014**, *68*, 40–57, DOI: 10.1016/j.knosys.2013.12.020.
39. Adamcová, M. Hodnocení spolehlivosti metodou FMEA s využitím ontologického inženýrství, ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE: Praha, 2020.
40. Yin, X.; Zhang, B.; Zhou, Z.; Han, X.; Wang, Z.; Hu, G. A new health estimation model for CNC machine tool based on infinite irrelevance and belief rule base. *Microelectronics Reliability* **2018**, *84*, 187–196, DOI: 10.1016/j.microrel.2018.03.031.
41. Kumar, P.; Srivastava, R.K. An expert system for predictive maintenance of mining excavators and its various forms in open cast mining. In Proceedings of the 2012 1st International Conference on Recent Advances in Information Technology (RAIT); IEEE, 2012; pp. 658–661.
42. Nuñez, D.L.; Borsato, M. OntoProg: An ontology-based model for implementing Prognostics Health Management in mechanical machines. *Advanced Engineering Informatics* **2018**, *38*, 746–759, DOI: 10.1016/j.aei.2018.10.006.
43. Gul, M.; Celik, E. Fuzzy rule-based Fine–Kinney risk assessment approach for rail transportation systems. *Human and Ecological Risk Assessment: An International Journal* **2018**, *24*, 1786–1812, DOI: 10.1080/10807039.2017.1422975.
44. Antomarioni, S.; Pisacane, O.; Potena, D.; Bevilacqua, M.; Ciarapica, F.E.; Diamantini, C. A predictive association rule-based maintenance policy to minimize the probability of breakages: application to an oil refinery. *The International Journal of Advanced Manufacturing Technology* **2019**, *105*, 3661–3675, DOI: 10.1007/s00170-019-03822-y.
45. Kharlamov, E.; Mehdi, G.; Savković, O.; Xiao, G.; Kalaycı, E.G.; Roshchin, M. Semantically-enhanced rule-based diagnostics for industrial Internet of Things: The SDRL language and case study for Siemens trains and turbines. *Journal of Web Semantics* **2019**, *56*, 11–29, DOI: 10.1016/j.websem.2018.10.004.
46. Paolanti, M.; Romeo, L.; Felicetti, A.; Mancini, A.; Frontoni, E.; Loncarski, J. Machine Learning approach for Predictive Maintenance in Industry 4.0. In Proceedings of the 2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA); IEEE, 2018; pp. 1–6.
47. Galar, D.; Villarejo, R.; Johansson, C.-A.; Kumar, U. Hybrid models for PHM deployment techniques in railway. In Proceedings of the The Tenth International Conference on Condition Monitoring and Machinery Failure Prevention Technologies; Krakow, 2013.

48. Hines, J.W.; Garvey, J.; Preston, J.; Usynin, A. Empirical Methods for Process and Equipment Prognostics. In Proceedings of the 53rd Annual Reliability and Maintainability Symposium (RAMS); Las Vegas, Nevada, 2008.
49. Zhan, Y.; Mechefske, C.K. Robust detection of gearbox deterioration using compromised autoregressive modeling and Kolmogorov–Smirnov test statistic—Part I: Compromised autoregressive modeling with the aid of hypothesis tests and simulation analysis. *Mech Syst Signal Process* **2007**, *21*, 1953–1982, DOI: 10.1016/j.ymssp.2006.11.005.
50. Haque, M.S.; Shaheed, M.N. Bin; Choi, S. RUL Estimation of Power Semiconductor Switch using Evolutionary Time series Prediction. In Proceedings of the 2018 IEEE Transportation Electrification Conference and Expo (ITEC); IEEE, 2018; pp. 564–569.
51. Cheng, C.; Yu, L.; Chen, L.J. Structural Nonlinear Damage Detection Based on ARMA-GARCH Model. *Applied Mechanics and Materials* **2012**, *204–208*, 2891–2896, DOI: 10.4028/www.scientific.net/AMM.204-208.2891.
52. Ghahramani, S. *Fundamentals of Probability*; Chapman and Hall/CRC, 2015; ISBN 9781498755023.
53. Rasmussen, C.E. Gaussian Processes in Machine Learning. In *Advanced Lectures on Machine Learning*; Bousquet, O., von Luxburg, U., Rätsch, G., Eds.; Springer: Berlin, 2004; Vol. 3176, pp. 63–71.
54. Kan, M.S.; Tan, A.C.C.; Mathew, J. A review on prognostic techniques for non-stationary and non-linear rotating systems. *Mech Syst Signal Process* **2015**, *62–63*, 1–20, DOI: 10.1016/j.ymssp.2015.02.016.
55. Sikorska, J.Z.; Hodkiewicz, M.; Ma, L. Prognostic modelling options for remaining useful life estimation by industry. *Mech Syst Signal Process* **2011**, *25*, 1803–1836, DOI: 10.1016/j.ymssp.2010.11.018.
56. Lei, Y.; Li, N.; Guo, L.; Li, N.; Yan, T.; Lin, J. Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mech Syst Signal Process* **2018**, *104*, 799–834, DOI: 10.1016/j.ymssp.2017.11.016.
57. Zhang, Z.; Si, X.; Hu, C.; Lei, Y. Degradation data analysis and remaining useful life estimation: A review on Wiener-process-based methods. *Eur J Oper Res* **2018**, *271*, 775–796, DOI: 10.1016/j.ejor.2018.02.033.
58. Vališ, D.; Mazurkiewicz, D. Application of selected Levy processes for degradation modelling of long range mine belt using real-time data. *Archives of Civil and Mechanical Engineering* **2018**, *18*, 1430–1440, DOI: 10.1016/j.acme.2018.05.006.
59. Soares, S.G. Ensemble Learning Methodologies for Soft Sensor Development in Industrial Processes, Ph.D. Thesis, University of Coimbra, Faculty of Sciences and Technology: Coimbra, Portugal, 2015.
60. Naderi, E.; Khorasani, K. Data-driven fault detection, isolation and estimation of aircraft gas turbine engine actuator and sensors. In Proceedings of the 2017 IEEE 30th Canadian Conference on Electrical and Computer Engineering (CCECE); IEEE, 2017; Vol. 32, pp. 1–6.
61. Koprinkova-Hristova, P. Reinforcement Learning for Predictive Maintenance of Industrial Plants. *Information Technologies and Control* **2013**, *11*, 21–28, DOI: 10.2478/itc-2013-0004.
62. Zhang, W.; Yang, D.; Wang, H. Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE Syst J* **2019**, *13*, 2213–2227, DOI: 10.1109/JSYST.2019.2905565.
63. Sharma, S.; Cui, Y.; He, Q.; Mohammadi, R.; Li, Z. Data-driven optimization of railway maintenance for track geometry. *Transp Res Part C Emerg Technol* **2018**, *90*, 34–58, DOI: 10.1016/j.trc.2018.02.019.



64. Lasisi, A.; Attoh-Okine, N. Principal components analysis and track quality index: A machine learning approach. *Transp Res Part C Emerg Technol* **2018**, *91*, 230–248, DOI: 10.1016/j.trc.2018.04.001.
65. Zhan, Y.; Mechefske, C.K. Robust detection of gearbox deterioration using compromised autoregressive modeling and Kolmogorov–Smirnov test statistic. Part II: Experiment and application. *Mech Syst Signal Process* **2007**, *21*, 1983–2011, DOI: 10.1016/j.ymssp.2006.11.006.
66. Li, H.; Parikh, D.; He, Q.; Qian, B.; Li, Z.; Fang, D.; Hampapur, A. Improving rail network velocity: A machine learning approach to predictive maintenance. *Transp Res Part C Emerg Technol* **2014**, *45*, 17–26, DOI: 10.1016/j.trc.2014.04.013.
67. Lee, W.-J. Contextual Air Leakage Detection in Train Braking Pipes. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*; Springer, Cham, 2017; Vol. 10351 LNCS, pp. 191–200.
68. Lee, W.-J. Anomaly Detection and Severity Prediction of Air Leakage in Train Braking Pipes. *Int J Progn Health Manag* **2017**, *8*, DOI: 10.36001/IJPHM.2017.V8I3.2662.
69. Ren, L.; Sun, Y.; Wang, H.; Zhang, L. Prediction of Bearing Remaining Useful Life With Deep Convolution Neural Network. *IEEE Access* **2018**, *6*, 13041–13049, DOI: 10.1109/ACCESS.2018.2804930.
70. Olesen, J.F.; Shaker, H.R. Predictive maintenance within combined heat and power plants based on a novel virtual sample generation method. *Energy Convers Manag* **2021**, *227*, 113621, DOI: 10.1016/j.enconman.2020.113621.

Kontakt

Ing. Jakub Čedík, Ph.D.

prof. Ing. Martin Pexa, Ph.D.

Česká zemědělská univerzita v Praze, Technická fakulta, katedra jakosti a spolehlivosti strojů,
Kamýcká 129, 165 21 Praha – Suchbátka

E-mail: cedikj@tf.czu.cz, pexa@tf.czu.cz

Předepínané šroubové spoje a možnost jejich prediktivní údržby

Ing. Bohuslav Peterka, Ph.D.

prof. Ing. Josef Pošta, CSc.

1. Úvod

Šroubové spoje jsou nejrozšířenější a univerzální provedení rozebíratelného spojení konstrukcí, jejich částí, dílů a strojních součástí. Na šroubových spojích závisí bezpečnost i spolehlivost zařízení, která je obsahují. Jsou na ně kladeny vysoké požadavky, bývají velmi namáhány nejen mechanicky, ale často také tepelně, korozně, chemicky. Pro jejich dlouhodobě spolehlivou a bezpečnou funkci je důležitý nejen jejich správný konstrukční návrh a výrobní provedení všech jejich částí, ale také správná montáž a zajištění.

Typickým příkladem spojení s předpjatými šrouby jsou spoje různých stavebních, nosných, mostních, podpůrných aj. konstrukcí, kde je primárním požadavkem mechanická pevnost a únosnost spojů po celou dobu jejich technického života.

Dalším typickým příkladem důležitých a náročných předepjatých šroubových spojů jsou spoje přírubového typu, tj. vícešroubové spoje s předpětím. Pro tento typ spojení je typické, že primárním požadavkem je těsnost spoje za všech projektových provozních podmínek.

Tento příspěvek se zaměřuje na popis dnes dostupných metod zjišťování osového napětí ve šroubu během montáže, které lze použít také během provozu šroubového spoje. Metody, které přímo umožňují měření během provozu jsou vhodné pro monitoring v údržbě a jsou základem pro sběr informací pro analýzu současného technického stavu a predikci vývoje technického stavu takto sledovaného šroubového spoje.

2. Montáž a demontáž předepjatých šroubových spojů

Spojovací šrouby jsou vždy předepjaté, tj. musí být utaženy tak, aby v nich vznikla osová tahová síla. Tato osová síla způsobí prodloužení šroubu a stlačení spojovaných součástí. Mezi šroubem a maticí tedy vznikne silový styk, rovněž mezi spojovanými částmi je silový styk (podle provedení spojovaných částí to však může být i tvarový styk).

Osová síla musí být tak velká, aby vyvolala mezi spojovanými částmi tlak tak velký, že

- tření mezi spojovanými částmi přenesou všechny výsledné příčné síly, a
- při nejvyšším možném vnitřním tlaku bude tlak mezi spojovanými částmi ještě tak velký, že nedojde k jejich oddálení, případně že jimi sevřené těsnění nebude vnitřním přetlakem roztrženo

Při konstrukčním návrhu daného šroubového spoje je, s přihlédnutím k provozním podmínkám a dalším okolnostem, stanovena hodnota potřebného statického předpětí šroubů. Tato hodnota je vyjádřena jako statická osová síla ve šroubu. Při montáži je pak nezbytně nutné tuto předepsanou, tj. požadovanou, hodnotu osově síly skutečně dosáhnout. Velikost osově síly (tj. předpětí šroubu) je tedy při montáži nutno kontrolovat.

Kontrolu (vytvoření) osově síly ve šroubu lze principiálně provést některým z dále uvedených způsobů:

- kontrola osově síly měřením utahovacího momentu,
- kontrola osově síly měřením úhlu pootočení matice nebo šroubu,
- předepínání šroubů na mez kluzu,

- předepínání s přímým měřením prodloužení šroubu,
- předepínání s ultrazvukovou kontrolou prodloužení šroubu,
- předepínání s použitím speciálních indikačních přípravků.

Při praktické montáži lze některé způsoby kontroly osově síly kombinovat.


3. Selhání šroubových spojů v provozu

Selhání předepjatého šroubového spoje znamená, že z nějakého důvodu dojde k jeho uvolnění, tj. ke ztrátě jeho předpětí. Příčinou selhání může být nesprávný konstrukční návrh spoje, nevhodné vlastnosti materiálů tvořících součásti spoje, nesprávná montáž, nevhodný způsob zajištění, dlouhodobě působící nepříznivé provozní vlivy.

K uvolnění (povolení) spoje může dojít v důsledku sesedání spoje, nebo pohybu, mikropohybu či pružení součástí spoje.

Uvolnění spojů sesedáním součástí

Sesedá spoj, který je zatížen ve směru osy šroubu. Utažením předepjatého šroubového spoje dojde ke stlačení dosedacích ploch součástí, dosedacích ploch pod hlavou šroubu a pod maticí, dotykových ploch v závitech. Mikrone rovnosti povrchů kontaktních ploch se plasticky deformují a zarovnávají. To působí pokles předpětí, viz Obr. 1. Tento děj trvá řádově hodiny až dny po utažení. Na sesedání má vliv drsnost povrchů, geometrické nerovnosti, počet stlačovaných ploch a velikost tlaku na stlačovaných plochách. Na velikost tlaku mají vliv také geometrické poměry ve spoji - např. zkosení hran měrný tlak zvyšuje, přírubové provedení hlav šroubů a matic měrný tlak snižuje. Sesedání může být také významně ovlivněno vlastnostmi těsnění, sevřeného ve spoji.




Obr. 1 Uvolnění předepjatého šroubového spoje sesednutím (Zdroj:[2])

- P_o statická síla předpětí vzniklá utažením
 P_{os} statická síla předpětí po sesednutí = skutečná síla předpětí
 P_{o1} pokles statické síly předpětí v důsledku sesednutí
 δ_s celková velikost sesednutí
 δ_{s1} zkrácení předepjaté délky šroubu v důsledku sesednutí

δ_{S2} zkrácení předepjaté sevřené součásti v důsledku sesednutí

Uvolnění spojů pohybem součástí

Vlivem dynamických sil, působících na předepjatý spoj v jiném než osovém směru, může docházet k mikroposuvům mezi součástmi spoje. Vlivem těchto posuvů může dojít k rotaci šroubu a matice, tím k následnému poklesu předpětí až k úplnému povolení šroubu, případně až k jeho vypadnutí. Situace je znázorněna na obr. 2.



Obr. 2 Uvolnění pohybem součástí (Zdroj:[2])

P_0 statická síla předpětí vzniklá utažením

F_v vnější proměnlivá příčná síla

e excentricita (mikroposuv) vyvolaná vnějšími příčnými silami

Uvolnění spojů relaxací napětí a tečením materiálu

Zatímco sesedání deformacemi povrchových mikrone rovností probíhá řádově hodiny až dny, relaxace probíhá dlouhodobě.

Při relaxaci dochází ke zhutňování materiálu, které rovněž snižuje předpětí. Relaxace se významněji projevuje u měkkých kovů, polymerů a kompozitních materiálů.

Tečení materiálu je velmi pomalý pohyb spojený se vznikem trvalých mikrodeformací vlivem dlouhodobě působícího napětí, které se však nachází pod mezí kluzu materiálu. Tečení je výraznější u materiálů, které jsou vystaveny dlouhodobému působení tepla a teplotám blízkým se bodu rekrytalizace. Míra tečení se zvyšuje také s rostoucí teplotou okolního prostředí.


4. Metody zjišťování osově síly vhodné pro provozní monitoring a predikci vývoje

Především důvody selhání šroubových spojů spojené s relaxací napětí a tečením, a to jak šroubu, ale také dalších komponent spoje (příruby, těsnění atp.) mají společný projev spočívající ve změně délky šroubu.

Pokud předpokládáme, že šroubový spoj bude v některých případech vhodné podrobit provozní kontrole stanovené osové síly, nabízí se využití metod měření, které jsou s úspěchem využívány při vlastní montáži šroubového spoje a jsou založeny na měření změny délky šroubu.

Šrouby s kalibrovaným nosníkem

Šroub Rotabolt, obr. 3, má vývrt, ve kterém je vložen kalibrovaný svorník 3, který přesně vymezuje mezeru 2 mezi hlavou svorníku a vsazeným volně otočným prvkem 1. Velikost mezery odpovídá potřebnému prodloužení šroubu pro dosažení požadované osové síly, viz vztah **Chyba! Nenalezen zdroj odkazů..** Jakmile je při utahování šroub natažen o velikost mezery, je znemožněno volné otáčení prvku 1, což hmatově signalizuje montérovi, že požadované předpětí bylo dosaženo.



Obr. 3 Princip šroubu RotaBolt (Zdroj:[2])

Na podobném principu pracují dnes dostupné šrouby SmartBolt a MaxBolt, kde je změna délky šroubu indikována v průhledítku resp. je zobrazována barevným indikátorem, nebo zpracována elektronickým snímačem. Variantní provedení MaxBolt SPC4 používá elektronický snímač, který měří posun (změnu polohy) čela svorníku, tuto změnu ukazuje či indikuje přímo na šroubu a může tuto informaci také předávat do nadřazeného systému.



*Obr. 4 Ukázka systému SPC4 s převodníky a ústřednou pro bezdrátovým přenos dat
(Zdroj:[3])*

Měřicí podložky

Další možností provozního měření osově síly je využití tzv. měřících podložek. Podložka je obvykle tvořena siloměrným prvkem, který převádí působící tlakové napětí na elektrický signál dále zpracovávaný nadřazeným systémem (Obr. 5).



Obr. 5 Měřicí podložka s převodníkem na proudovou smyčku 4÷20 mA (Zdroj:[4])

Měření ultrazvukem

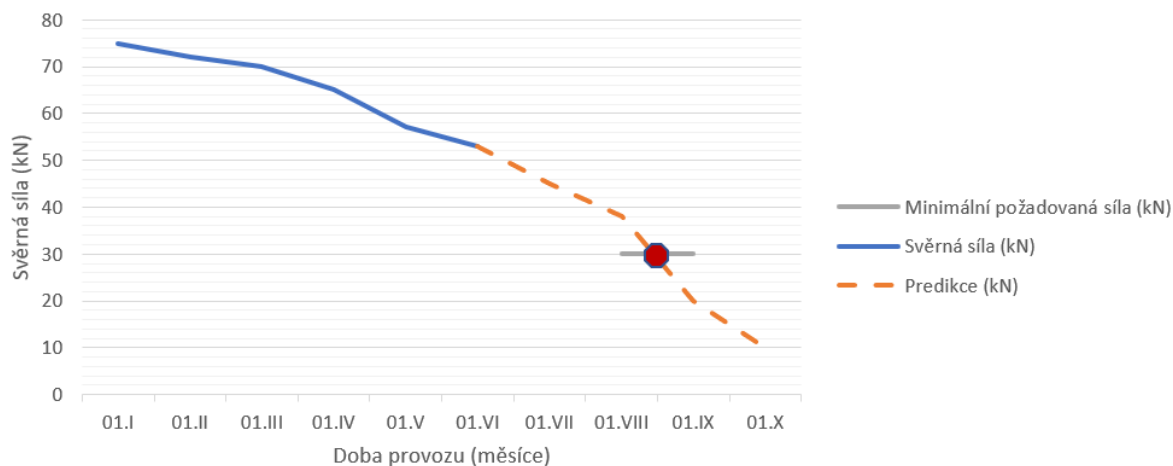
Prodloužení šroubu také nepřímo, pomocí ultrazvuku. Ultrazvuková sonda vysílá do šroubu ultrazvuk, který se jako vlna šíří materiálem šroubu, odrazí se od čela šroubu a postupuje zpět. Sonda zaznamená dobu průchodu vlny tam a zpět, z této doby se vypočítá délka šroubu. Přístroj pro toto měření, obr. 6, může zobrazit výsledek v délkových jednotkách, nebo v jednotkách síly, nebo v jednotkách napětí, nebo v procentech přednastavené hodnoty síly či napětí. Takto lze tedy poměrně velmi přesně nastavit požadovanou hodnotu při montáži spoje. Lze však také kdykoliv později tuto hodnotu zkontrolovat, a tak se přesvědčit, zda nedochází k uvolňování spoje. Výhodou tohoto způsobu je, kromě přesnosti a opakovatelnosti měření, také široký rozsah použití. Např. přístroj na obr. 6 je schopen měřit šrouby v délkách od 12 mm do 24000 mm, umožňuje také ukládání a následné zpracovávání a porovnávání naměřených hodnot. Nevýhodou tohoto způsobu je vysoká pořizovací cena, pomalá práce při přesném utahování, nutná vysoká kvalifikace pracovníka. V případě požadavku na možnost kontinuálního sledování utahení je nutno každý šroub trvale opatřit ultrazvukovou sondou a tu propojit s nadřazeným systémem.



Obr. 6 Přístroje pro ultrazvukové měření prodloužení šroubů (Zdroj: [6],[7])

Optické měření senzorem FBG

Další možností měření prodloužení šroubu, resp. osového napětí, které skýtá potenciál pro využití v rámci provozního monitoringu je měření ve šroubu zabudovaným senzorem na principu optické tenzometrie Fiber Bragg Grating (FBG). Jedná se v podstatě o optické vlákno s vícenásobnou Braggovou mřížkou vpleené polymerem vhodných vlastností do vývrtu v tělese šroubu. Jak je vlákno spolu se šroubem natahováno nebo zkracováno mění se optické vlastnosti a tím i měřené spektrum záření. Změna spektra je pak převáděna na změnu délky vlákna. Pro tento způsob měření nejsou v současnosti dostupné komerční produkty pro oblast šroubových spojů resp. jejich údržby, měření je omezeno na laboratorní a vývojové zkoušky [6].



Obr. 7 Princip predikce na základě měření osově síly ve šroubu (Zdroj: autoři)

5. Závěr

Technická diagnostika v mnoha oblastech údržby již dlouho a s dobrými výsledky poskytuje data o provozu strojů, která je možno dále zpracovat a užitím vhodného algoritmu prognózovat vývoj technického stavu. Problematika šroubových spojů, jejich montáže, údržby a demontáže je velice aktuální a přímo vybízí k využití moderních měřících a diagnostických metod. V odůvodněných

provozních případech je pak vhodné sledovat osově napětí ve šroubovém spoji trvale, nebo pochůzkovým systémem a získaná data trendovat. Získaný trend pak ukazuje na provozní chování spoje. Spolu s informací o provozních podmínkách a zatížení může být trend cenným podkladem například pro hodnocení provozního chování těsniv, zajišťovacích prvků a spojem svíraných částí, typicky přírub. Odhadem budoucího vývoje z historických dat získáváme zároveň představu o zbytkové životnosti do okamžiku poklesu svorné síly pod požadovanou minimální mez (Obr. 7). Získaný časový interval je pak vstupní informací pro optimalizaci a plánování údržby a rovněž předcházení nenadálých havarijních stavů.

6. Použitá literatura

- [1] LEGÁT, V. a kol.: Management a inženýrství údržby. Professional Publishing, Praha 2016, ISBN978-80-7431-119-2.
- [2] POŠTA, J. a kol.: Technologie údržby strojů – Šroubové spoje, 1. vyd., Praha, 2019. 86 s. ISBN 978-80-213-2947-8
- [3] [online]. Dostupné z: Valley Forge and Bolt Mfg. Co. (2022, July 19). SPC4 Load Indicating System | Load Indicating Bolt | VF Bolts. Valley Forge & Bolt. <https://www.vfbolts.com/product/spc4-load-indicating-system-2/>
- [4] Messende Unterlegscheibe, Messunterlegscheibe, Vorspannkraft, Schraubmontage. *Wägezellen, Messunterlegscheibe, Schneelastsensor, Messverstärker, Vorspannkraft* [online]. Dostupné z: <https://www.bds-solutions.de/BoltValid.html>
- [5] Khomenko, A., Koricho, E. G., Haq, M., & Cloud, G. L. (2016). In-service preload monitoring of bolted joints subjected to fatigue loading using a novel ‘monitorque’ bolt. *Fracture, Fatigue, Failure and Damage Evolution, Volume 8*, 261–267. https://doi.org/10.1007/978-3-319-21611-9_32
- [6] Ultrasonic Bolt Measuring Services | Ultrasonic Bolt Measuring Tools. [online] [cit. 31.10.2022]. Dostupné z: <https://milltorc.com/ultrasonic-bolt-measuring-services/>
- [7] Load monitor - BoltScope Ultra - Hydratight. DirectIndustry - The B2B marketplace for industrial equipment: sensors, automation, motors, pumps, handling materials, packaging, etc. [online]. Dostupné z: <https://www.directindustry.com/prod/hydratight/product-53249-2050149.html>

Kontakt

Ing. Bohuslav Peterka, Ph.D.

prof. Ing. Josef Pošta, CSc.

Česká zemědělská univerzita v Praze, Technická fakulta, katedra jakosti a spolehlivosti strojů,
Kamýcká 129, 165 21 Praha – Suchbátka

Tel.: +420 224 383 254, +420 224 384334, E-mail: peterka@tf.czu.cz, posta@tf.czu.cz

Prediktivní údržba s využitím tribodiagnostiky

Ing. Jan Novák

1. Úvod

Točivé stroje, hydraulické systémy, převodovky, motory, ložiska – stroje a zařízení díky nimž dnešní moderní industriální společnost zažívá vrcholu mají jednu společnou a velmi podstatnou součást. Je jím mazivo. Maziva jsou neoddělitelnou a základní konstrukční součástí většiny současných strojních technologií. Bez maziv bychom se potýkali s vysokými ztrátami energií díky třením a opotřebením strojních součástí. Pokud chceme zajistit vysokou spolehlivost, efektivitu a dlouhou životnost strojů a zařízení, je vyžadována také pravidelná údržba/péče o mazání.

Tribodiagnostika, jakožto diagnostický obor v oblasti mazání a maziv, poskytuje klíčové informace pro moderní řízení údržby strojů a zařízení. Prediktivní údržba strojů je vedle dalších diagnostických postupů jako je vibrodiagnostika nebo termodiagnostika s tribodiagnostikou velice úzce spjata.

2. Obecné informace o mazivech

Obecně platí, že maziva jsou určena ke snížení tření a opotřebením, poskytují chlazení, odnáší znečištění, přenášejí práci atp.

V drtivé většině nejfrekventovanější formou maziv, jsou maziva kapalná a plastická. Z pohledu konstrukce, se jedná o základový olej, který je případně zušlechťen vybranými přísadami a popř. zpevňovačem. Různé stroje mají různé požadavky na mazivo a podle toho se volí příslušné složení přísad.

Řádné mazání minimalizuje, nebo vylučuje kontakt mezi kovovými povrchy a snižuje opotřebením součástí. Opotřebením a poruchy strojů z valné většiny souvisí se stavem oleje – zejména s kontaminací oleje nečistotami či vodou. Protože maziva jsou tepelně a oxidačně namáhány, degraduje základový olej a vyčerpávají se přísady.

3. Tribodiagnostika

Vhodnými diagnostickými postupy je možné sledovat úbytek přísad a fyzikálně chemických vlastností oleje, tak aby bylo možné maximálně využít vlastnosti maziva do konce jeho životnosti bez vlivu na snížení spolehlivosti a provozuschopnosti zařízení. Zároveň je mazivo nosičem informací o kondici klíčových strojních součástí. Zde je zcela adekvátní přirovnání, že olej je krví stroje. V lékařství analýzou krve lékař diagnostikuje disfunkci konkrétních orgánů, v technické diagnostice analýzou a klasifikací částic opotřebením jsme schopni identifikovat, která konkrétní strojní součást podléhá opotřebením a blíží se porucha.


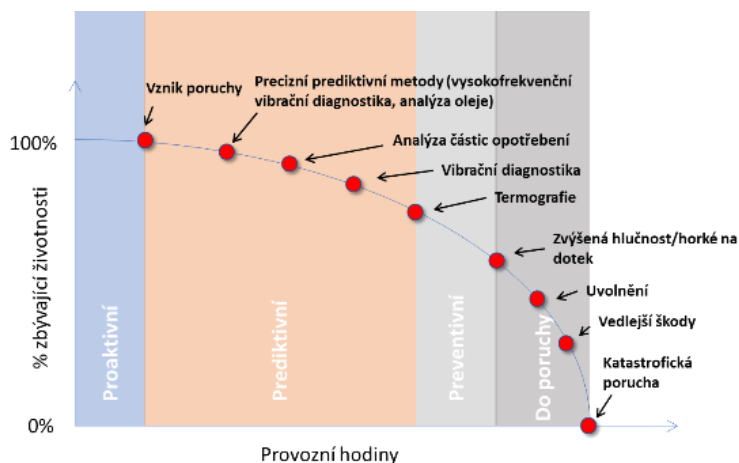
Použití vysoce kvalitního maziva je zárukou potenciálně bezvadné funkce a dlouhé životnosti. Požadavky na nové oleje jsou uvedeny většinou standardizovanou výkonnostní třídou – např. API, ISO, DIN atd. Pokud výrobce stroje má vlastní firemní výkonnostní specifikaci, musí nové mazivo splňovat i tyto požadavky.

4. Tribodiagnostika v konkurenci jiných diagnostických postupů

Zatímco ostatní diagnostické obory dlouhé roky těžily z rostoucích schopností výpočetní techniky a možností automatického sběru a zpracování dat pomocí i relativně jednoduchých a levných snímačů, současná tribodiagnostika stále spočívá primárně na odběru vzorku maziva ze stroje a jeho následném

zpracování ve specializované laboratoři. V posledních letech zažívají snímače tribodiagnostických dat rozkvět, ale stále jsou možnosti oproti ostatním oborům omezené.

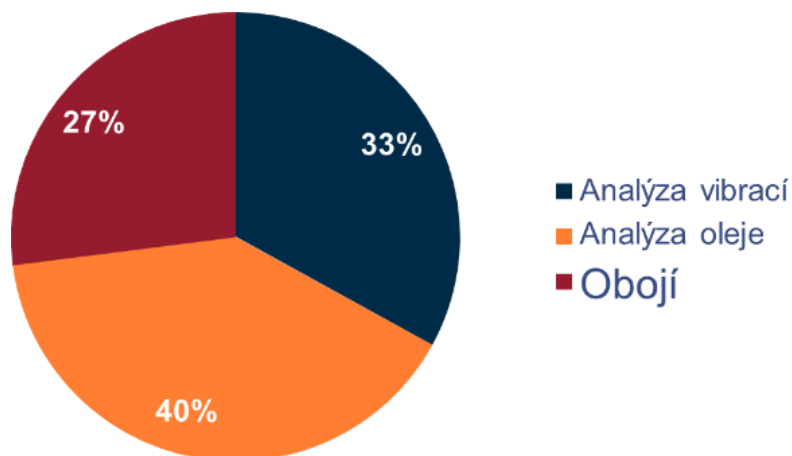
Mezi odbornou veřejností tak panují neshody v tom, který diagnostický postup je z pohledu prediktivní údržby lepší. Jedni upřednostňují ultrazvukovou či vibrační diagnostiku jako hlavní zdroj informací pro odhad budoucího chování strojů, jiní zase díky vysoké citlivosti analytických metod vyzdvihují tribodiagnostiku jako klíčový nástroj pro včasné odhalení blížící se poruchy. Pokud se podíváme do různých odborných publikací, najdeme pak tribodiagnostiku na různých místech PF křivky.



Obrázek 7 – Porovnání různých PF křivek

V tomto ohledu doporučuji diskutujícím detailně prostudovat články a studie (např. v časopise Machinery Lubrication [2]) věnované oceňovanému diagnostickému programu atomové elektrárny Palo Verde/Arizona. Za citaci rozhodně stojí věta „Za každý 1\$ vynaložený na prediktivní údržbu,

eliminujeme náklady na opravy ve výši 6,50 \$“, která přesně dokazuje, jak prediktivní údržba je účinný nástroj.



Graf 1 - Podíl včasné detekce vybranou diagnostickou metodou

Ve jedné z publikovaných studií z Palo Verde [3] byly analyzovány závady ložisek ze 750 strojů, které byly rozděleny do kategorií podle toho, zda se nejprve objevily při analýze oleje, při analýze vibrací nebo při shodně v obou analýzách. Na základě těchto údajů by se mohlo zdát, že při 40 % má mírně navrch analýza oleje. Ve skutečnosti tato studie ukazuje, že vynechání jedné nebo druhé technologie by vedlo k tomu, že by zhruba třetina všech závad zůstala neodhalena. Dokonce i 27 % závad, které se projeví u obou technik, je poučných, protože potvrzující důkazy ze dvou rozdílných zdrojů poskytují větší míru jistoty, že lze učinit správné rozhodnutí o údržbě.

Z toho plyne poučení, že je vhodné kombinovat více diagnostických technik je pro zajištění maximální spolehlivosti strojů a zařízení.

5. Základní konsensus tribodiagnostiky a předpoklady

Testování výkonnosti konkrétního maziva pro vhodné aplikace je velice náročný a nákladný proces. Vývoj nové formulace aditiv nebo maziv vyžaduje celou řadu zkoušek a měření, kdy je mazivo podrobeno zkoumání celého komplexu vlastností a charakteristik, které zaručí, že mazivo poskytne dlouhodobou bezvadnou výkonnost po celou životnost v celé šíři různých provozních podmínek. Zkoumá se výkon, tj. oxidační stabilita, mazivost, povrchové vlastnosti, provádí se motorové nebo strojní zkoušky atd.


Pokud sledujeme kondici maziv ve strojích, nesledujeme a neověřujeme výkonnost maziva (až na výjimky), protože by to bylo příliš složité, nákladné a časově náročné. Sledujeme jen základní fyzikálně chemické vlastnosti oleje a vycházíme z předpokladu, že pokud těchto několik parametrů se shoduje nebo jen mírně liší vůči hodnotám nového maziva, můžeme předpokládat podobnou nebo stejnou výkonnost maziva.

Častý předpoklad je, že odebraný vzorek oleje je reprezentativní a stav maziva je v rámci určitých mezí stejný v celém stroji. Tento předpoklad je platný pro fyzikálně chemické vlastnosti – viskozitu, číslo kyselosti, chemického složení, koncentrace rozpustných přísad apod. Pro kontaminaci nečistotami, vodou, otěrové prvky to často neplatí. Např. voda má obvykle vyšší hustotu než minerální olej, popř. nižší v případě vybraných syntetických olejů. Pokud má olej dobrou deemulgační charakteristiku, tak v minerálních olejích se odděluje a klesá ke dnu, resp. stoupá na hladinu v případě vybraných syntetických olejů.

Podmínkou úspěšného programu tribodiagnostiky je množství dat. Čím širší rozsah analýz a čím vyšší frekvence analýz, čím více informací o dané aplikaci máme, tím přesnější závěry a doporučení získáme. Proti tomu stojí náklady, protože každá laboratorní analýza nebo čidlo představuje nějaké finanční prostředky, které je potřeba vydat. Manažer údržby tak často musí volit jaké náklady na tribodiagnostiku jsou adekvátní vůči očekávaným přínosům. On-line snímače, představují vyšší prvotní náklad / investici, ale pak přináší nepřetržitý proud informací. Oproti tomu laboratorní analýza vzorku je o dva řády nižší náklad, ale zachytím pouze jeden diskrétní okamžik života stroje.

| Laboratorní analýzy vzorků oleje | On-line snímač |
|---|---|
| <ul style="list-style-type: none"> + vysoká přesnost – vždy stejné podmínky měření + standardizované zkoušky + pravidelná kalibrace a validace + široká škála fyzikálně chemických vlastností | <ul style="list-style-type: none"> + vysoká rychlost + on-line přenos dat + real-time data pro rychlou reakci |
| <ul style="list-style-type: none"> - rychlost - manipulace a doprava vzorků - možnost chyby odběru vzorku - cena | <ul style="list-style-type: none"> - omezené množství měřených vlastností - nutnost pravidelné kalibrace/čištění - vyšší vstupní investice |

Další předpoklad tribodiagnostiky je, že parametry maziva se mění jen pozvolně. Tomu potom odpovídají následně i intervaly odběru vzorků. Pokud je životnost náplně měřena na roky, tak se provádí odběry vzorků obvykle kvartálně a intervaly se zkracují v případě náznaku problému. Pokud je životnost oleje v motoru maximálně desítky stovek provozních hodin, odebírají se vzorky v rozmezí jednotek stovek provozních hodin. Opět tento předpoklad neplatí pro kontaminaci. Někdy může být koncentrace nečistot velice dynamický proces – viz následující příklad měření počtu on-line čítačem částic, který vyhodnocuje koncentraci a velikost částic každé 2 minuty. Pokud se mění provozní podmínky maziva – např. v hydraulickém systému, kde se střídají fáze klidu a pohybu výkonných prvků v různých hydraulických okruzích, mění se koncentrace nečistot velmi dynamicky.



Obrázek 8 - průběžně měnící se počty částic v oleji při provozu stroje

Pro vyhodnocení stavu maziva v provozu ve většině případů využíváme konfrontaci vůči parametrům nového oleje. Ty buď nacházíme v dokumentaci od výrobce, nebo častěji provádíme analýzu nového maziva. Jelikož se výrobní postupy maziv mohou průběžně měnit, je vhodné údaje od dodavatele případně analýzu oleje aktualizovat s každou dodávkou.

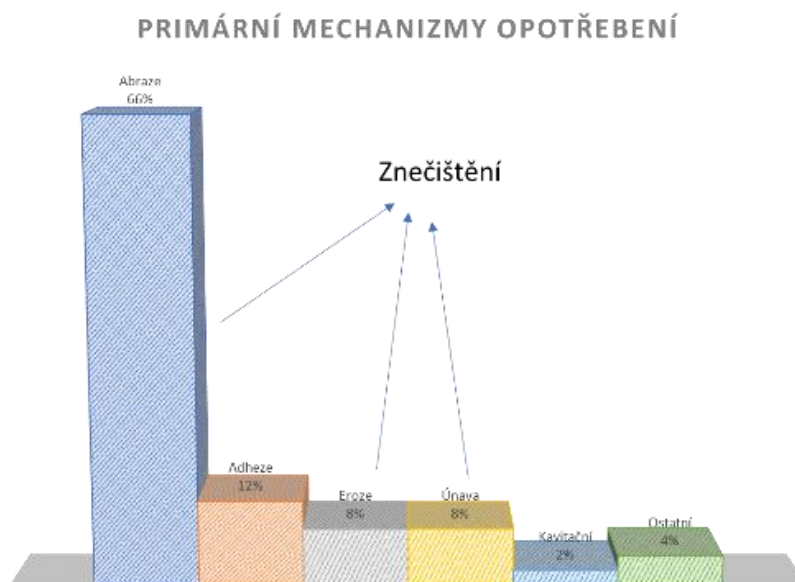
6. Provozní podmínky systému

Nejdůležitějšími faktory ovlivňujícími předpokládanou životnost daného maziva v daném systému jsou provozní podmínky v systému. Vzduch (kyslík), zvýšené provozní teploty, kovy a voda (vlhkost) jsou v mazacích systémech vždy v určité míře přítomny. Tyto vlivy podporují degradaci oleje, a proto musí být sledovány. Posouzení vnějších vlivů má významný vliv na přesnost diagnostického závěru a lépe se následně směřují další kroky údržby.

7. Kontaminace

Kontaminace je často nejvýznamnějším faktorem ovlivňujícím životnost maziva a stroje. Ke kontaminaci dochází jak z vnějšku, tak zevnitř systému. Vnější znečištění může do systému za provozu proniknout přes těsnění ložisek, odvětráním, netěsnostmi vík, nesprávným doplňováním novým olejem atp. Důsledné zatěsnění a kvalitní zavzdušňovací filtry významně redukuje vnik vnější kontaminace. Vnitřní kontaminace vzniká ve stroji vždy. Patří mezi ně kondenzovaná vlhkost, částice opotřebení, produkty degradace oleje a vyčerpaných přísad, popř. ve speciálních případech např. médium, spaliny či mikrobiální růst.

Dostupné publikace a studie se zcela jednoznačně shodují, že kontaminace maziv je dominantní faktor, který ovlivňuje opotřebení (a v důsledku spolehlivost a životnost strojů). Jednotlivé publikace se liší v tom, jakou závažnost kontaminaci přisuzují. V průměru se hodnoty pohybují okolo 80% a tyto hodnoty se už liší podle toho, jaké konkrétní technologie se studie týká. Hydraulické systémy jsou citlivější na přítomnost kontaminace na rozdíl od některých točivých strojů nebo převodovek.



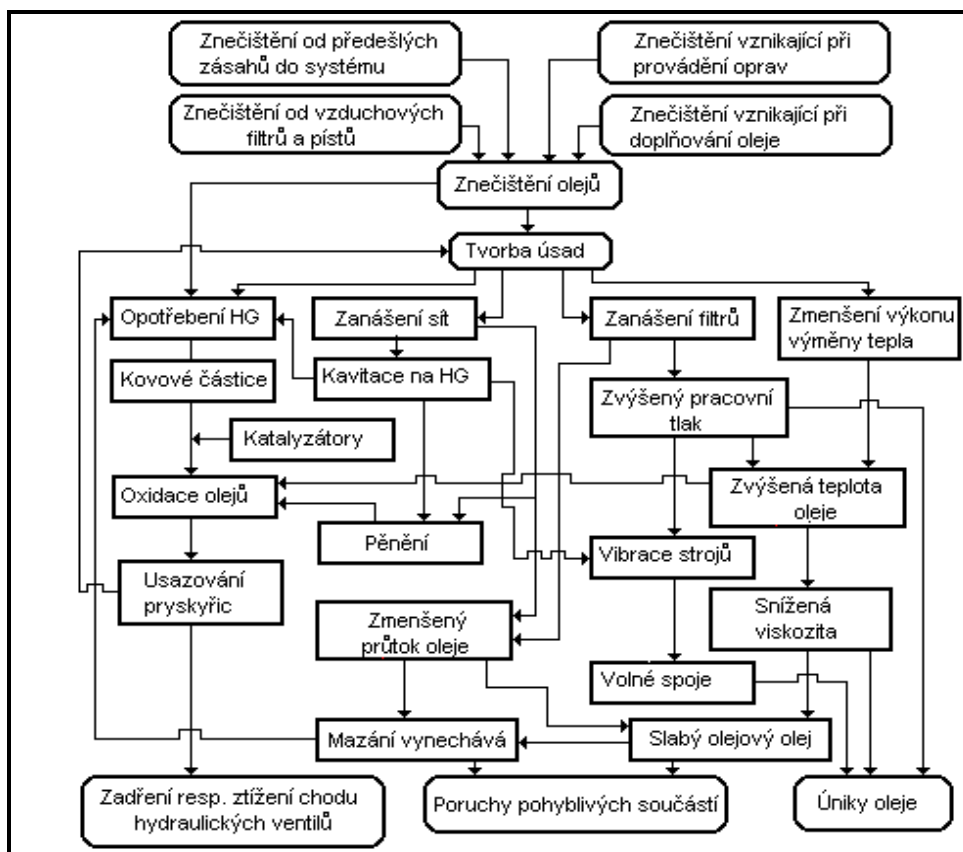
Graf 2 - Primární mechanismy opotřebení

Bez ohledu na počáteční kvalitu maziva, dochází během používání k tepelnému a oxidačnímu namáhání, ztrátě kontroly pěnovosti, zhoršování schopnosti deemulgace a ztrátě ochrany proti opotřebení, což vede k degradaci chemického složení oleje. Aby se předešlo problémům s degradací, jsou vyvíjeny oleje se

schopností odolávat oxidačním procesům, degradaci opotřebením a další degradační mechanismy, a to pomocí kombinace kvalitního základového oleje spolu se směsí aditiv. Oxidační degradace probíhá v důsledku chemických změn způsobených kyslíkem v atmosféře, podporována teplem a následnou řetězovou reakcí.

Voda je velmi nebezpečný kontaminant, který podporuje degradaci oleje, vyčerpání aditiv, korozi, snížení tloušťky mazacího filmu a růst mikroorganismů.

Kauzalitu mezi kontaminací a problémy strojů je možné znázornit následovně:



Graf 3 - Kauzalita mezi nečistotami a příčinami poruch

V následujícím, textu se omezím na oleje. Plastická maziva z pohledu tribodiagnostiky jsou okrajovou skupinou, které by bylo vhodné věnovat samostatný text.

8. Strategie údržby

Tribodiagnostika využívá celou řadu laboratorních analýz pro sledování kondice maziv v průběhu provozu stroje. Nicméně ne všechny metody lze označit za nástroje prediktivní nebo proaktivní údržby. Některé běžně sledované parametry konstatují stav oleje a vyjadřují co se stalo v minulosti a ani na základě analýzy trendu se velmi špatně dá odhadnout budoucí chování systému. Jiné parametry jsou ideální pro využití v prediktivní údržbě.

Zvolená strategie údržby určuje rozsah použitých parametrů, frekvenci, a především způsob práce s tribodiagnostickými daty.

| STRATEGIE | METODA | FREKVENCE | TRIBODIAGNOSTIKA |
|-------------|--|-----------|--|
| REAKTIVNÍ | Výměna maziva po poruše | - | Žádná |
| PREVENTIVNÍ | Výměna maziva obvykle na základě plánu nebo nevyhovujícího stavu | Nízká | Minimální rozsah Vyhodnocení nevyhovujícího stavu maziva na základě statických limitů |
| PREDIKTIVNÍ | Sledování a vyhodnocování stavu maziva | Vysoká | Identifikace vzniku poruch na základě analýzy trendů, statistické vyhodnocení dat |
| PROAKTIVNÍ | Sledování a vyhodnocování stavu maziva v širších souvislostech | Vysoká | Analýza kořenových příčin poruch Předchází vzniku a eliminuje příčiny poruch |

9. Vybrané sledované parametry olejů

Konkrétní program sledování kondice oleje, by měl reflektovat o jakou aplikaci se jedná, předpoklad životnosti a s jakými riziky se předpokládá. Tomu se posléze nastaví odpovídající metriky a frekvence kontrol.

Barva

Nová maziva mají obvykle světlou barvu. V průběhu použití z pravidla maziva tmavnou (někdy i při vystavení slunečnímu světlu nebo U/V) a změna je obvykle pomalá v průběhu let provozu. Časté kontroly barvy jsou proto užitečné jako rychlý test na místě. Výrazná změna barvy by naznačovala, že neobvyklé a rychlé ztmavnutí může být přímým důsledkem kontaminace nebo nadměrné degradace.

Viskozita

Viskozita je nejdůležitější charakteristikou maziva, protože tloušťka olejového filmu při mazání je kriticky závislá na viskozitních vlastnostech oleje. Viskozita většiny komerčních olejů je klasifikována podle systému klasifikace viskozity ISO 3448. Hlavním účelem kontroly viskozity použitého oleje je zjistit, zda se používá správný olej a odhalit znečištění. Současné průmyslové oleje zřídka vykazují významné změny viskozity v důsledku degradace. Příležitostně se viskozita mění v důsledku tvorby emulze při kontaminaci vodou. Výjimkou jsou oleje, které používají přísadu „modifikátor viskozity“, která je citlivá na stříhové napětí a v důsledku vyčerpání této přísady viskozita oleje klesá na viskozitu základového oleje, která bývá obvykle o třídu nižší.

Viskozitní index

Viskozita oleje se mění exponenciálně v závislosti na teplotě. Viskozitní index, je způsob stanovení směrnice této závislosti. Obvykle se stanovuje z kinematické viskozity stanovené při 40 a 100°C. Změna

viskozitního indexu může být signálem vyčerpání modifikátoru viskozity nebo poškozování základového oleje.

Množství nečistot v olejích

Stanovení množství nečistot v definovaném objemu oleje je jednou z klíčových technik, jak hodnotit kvalitu oleje a zabránit opotřebení stroje. Čistotu oleje v systému lze stanovit:

- gravimetricky – stanoví se hmotnost zachycených nečistot na filtru po přefiltrování definovaného množství oleje
- počítáním částic – počty částic vybraných velikostí se zařazují do tříd čistoty dle klasifikačního systému – nejčastěji ISO 4406:1999. Stanovení počtu částic je možné jak ze vzorku oleje, tak i kontinuálně on-line pomocí snímače zařazeného do systému. On-line sledování počtu částic je důležité pro zachycení dynamiky vývoje znečištění.
- MPC – metoda MPC je jeden ze způsobů hodnocení znečištění oleje, a především hodnotí potenciál oleje k tvorbě úsad v olejových systémech, protože je schopen hodnotit také množství produktů degradace v oleji. Kolorimetrem se vyhodnocuje zbarvení membrány způsobené zachycenými nerozpustnými nečistotami a produkty degradace.
- CPA – další kolorimetrická metoda, která hodnotí množství produktů degradace v oleji bez nutnosti čekat na aglomeraci částic

Produkty degradace tvoří velmi malé částice a jedná se o jeden z nejvíce nebezpečných kontaminantů v mazacích systémech turbín a hydraulických systémech. Produkty degradace mají za následek vznik úsad v olejovém systému. Moderní maziva tvoří úsady častěji, než tomu bylo v historii. Jedním z důvodů je používání základových olejů s nižší rozpustností či nové formulace přísad. Při pracovní teplotě je část produktů degradace v oleji rozpuštěných anebo tvoří malé částice, které je problematické standardními testy účinně kvantifikovat.

Množství vody

Jak už bylo uvedeno, voda je nebezpečný kontaminant. Pro rutinní kontrolu postačuje sledovat přítomnost, v komplexním rozboru se většinou aplikuje coulometrická titrace.

- Přítomnost – vzorek oleje se v tenké vrstvě nalije na zkoušečku rozpálenou na cca 170 °C – což je teplota pod bodem varu oleje, ale nad bodem varu vody. Pokud se ve vzorku tvoří bublinky páry, je v oleji voda přítomna v nebezpečném množství.
- Destilačně – touto metodou lze stanovit koncentraci vody v oleji s přesností v jednotkách procent.
- Coulometricky – Karl Fischerovou titrací lze přesně stanovit obsahy vody od jednotek ppm.

Inhibitor oxidace

Sledování koncentrace antioxidantů je důležité pro kontrolu oxidace maziv a jejich zbývající životnosti. Pro přesné sledování zbývající koncentrace primárních (nejčastěji fenoly, amíny) a sekundárních (např. ZnDTP) antioxidantů se využívá např. voltametrické metody (RULER). Pro měření koncentrace primárních antioxidantů fenolického typu a případně sekundárních antioxidantů je možné použít infračervenou spektrometrii. Aminické antioxidanty touto metodou sledovat prakticky nejde. Při nastavování reference se doporučuje konzultovat s dodavatelem maziva informace o antioxidantech použitých ve složení oleje.

RULER

Voltmetrie je elektrochemická zkušební technika, kterou lze použít pro měření primárních a sekundárních antioxidačních přísad. Tato technika aplikuje napěťovou rampu přes tříelektroodový snímací systém a měří proudový tok, který vzniká, když se napětí rovná oxidačnímu potenciálu antioxidantu. Potenciál vzniklého voltametričského píku pomáhá při identifikaci antioxidantu a plocha vzniklého píku je úměrná koncentraci antioxidantu. Lze měřit antioxidanty, jako jsou fenoly, aminy a ZnDTP (podle zkušební metody ASTM D6810 a D6971). Pro sledování změny koncentrace musí být k dispozici referenční voltamogram nového oleje.

FTIR

Infračervená spektroskopie s Fourierovou transformací (FTIR) je zdokonalená metoda infračervené spektroskopie, kterou lze použít ke sledování koncentrace některých druhů přísad – antioxidantů, AW přísad atp. Lze ji také použít ke sledování vzniku oxidačních produktů při degradaci oleje. Pro každý olej je jedinečné spektrum a pro přesné vyhodnocení je nutné mít spektrum nového oleje pro porovnání. Každá přísada či kontaminace je specifická chemická látka a absorbuje infračervené světlo při určité vlnové délce.

Oxidační stabilita

Jednou z klíčových vlastností nového oleje je jeho oxidační stabilita. Ta se tradičně měří zkušební metodou TOST, popř. Dry TOST, přičemž zkušební metoda RPVOT (dříve RBOT) se používá jako pomocná (rychlá) metoda pro sledování změn stavu oleje v provozu. Oxidační stabilita oleje v provozu se postupně snižuje, přičemž zhoršování je podporováno katalytickými účinky kovů v systému (železo a měď) a také vyčerpáním antioxidantu. Se snižováním zásoby oxidační stability vznikají kyselé sloučeniny, které následně podléhají dalším reakcím za vzniku složitějších sloučenin. Konečnými produkty těchto procesů jsou nerozpustné kaly a úsady.

Oddělitelnost vody

Voda se může dostat do systémů v důsledku netěsnosti chladiče oleje, běžného dýchání nebo z vnějšího prostředí (nedostatečná ochrana proti dešti atp.). Voda nepříznivě ovlivňuje olej tím, že působí s kovy a katalyzuje oxidaci. Rovněž vyčerpává aditiva citlivá na vodu, jako jsou některé typy inhibitorů koroze olejů, a může způsobovat rezavění a korozi, popř. může podporovat růst mikroorganismů. Kromě chemických účinků na olej a přísady mohou být nepříznivě ovlivněny mazací vlastnosti oleje; olej, který obsahuje značné množství vody, nemůže udržet odpovídající mazání.

Pěnovost

Pěnovost se měří zkušební metodou, která udává, jak tendenci oleje pěnit, tak stabilitu pěny po jejím vytvoření. Tato zkouška může být užitečná při řešení problémů s pěněním oleje v zařízení. K určitému zvýšení pěnovosti v průběhu času dojde v důsledku změn povrchového napětí oleje, které jsou důsledkem normální degradace oleje, stopového znečištění a toto zvýšení pěnovosti je často pozorováno a nemusí být znepokojivé.

Analýza prvků

K analýze prvků obsažených v použitém mazacím oleji lze použít atomovou absorpční spektroskopii nebo emisní spektrometrii s indukčně vázaným plazmatem. Alternativně také XRF spektroskopii. OES-ICP je obecně omezena na rozpuštěné materiály nebo částice menší než přibližně 8 μm . Nalezené prvky pocházejí ze zbytků opotřebení, přísad a kontaminace.

Určité opotřebenění kovových částí lze považovat za normální (i když není žádoucí). Velké množství kovových nečistot obvykle signalizuje vážný problém se strojem. Vzhledem k tomu, že různé části stroje jsou vyrobeny z různých kovů, přítomnost určitých kovů naznačuje, které součásti se opotřebovávají. Vzorky ze zařízení, u nichž se koncentrace kovů zvyšují neobvykle rychle nebo jsou mimo normální rozsah, naznačují, že zařízení může mít problém. Analýza by měla být provedena u nepoužitého oleje, aby se stanovila základní hodnota pro budoucí srovnání.

Bod vzplanutí

Většina olejů, musí mít bod vzplanutí výrazně vyšší než minimální platné bezpečnostní požadavky. Bod vzplanutí má však malý význam pro určení stupně degradace použitých olejů, protože běžná degradace má na bod vzplanutí malý vliv.

10. Statické limity

Nejčastější technikou, jak vyhodnotit tribodiagnostická data je jejich porovnání se statickými limity. Statické limity se obvykle dělí na různé úrovně závažnosti a značí barvami jako semafor.

| Metoda | Zkušební předpis | norma, | Nový olej požadované parametry | Provozní Výstraha | výsledky | Provozní Vážný stav | výsledky |
|---------------------------------|---|--------|--|---|----------|--|----------|
| Výkonová klasifikace | | | ISO 6743/5 TS, TSA TG, TGA DIN 51 502 TD ISO 6743/4 HL DIN 51 515 - 1 L-TD DIN 51 517 - 2 CL | | | | |
| FZG | ČSN 65 6280 | | min nevyhov. stupeň 6 | | | | |
| Hustota | ČSN EN ISO 12185 | | 850 -875 kg/m ³ | 850–875 kg/m ³ | | 840–900 kg/m ³ | |
| Barva | D1500 | | | | | Neobvykle rychlé ztmavnutí | |
| Bod tekutosti | ČSN EN ISO 3016 | | -12°C nebo lepší | -12°C nebo lepší | | -12°C nebo lepší | |
| Kinematická viskozita při 40°C | ČSN EN ISO 3104 | | ± 10% dané viskozitní třídy | ± 5% rozdíl oproti viskozitě nového oleje | | ± 10% rozdíl oproti viskozitě nového oleje | |
| Kinematická viskozita při 100°C | ČSN EN ISO 3104 | | ± 10% dané viskozitní třídy | ± 5% rozdíl oproti viskozitě nového oleje | | ± 10% rozdíl oproti viskozitě nového oleje | |
| TAN (Total Acid Number) | ČSN EN 12 634 ČSN ISO 6619 ČSN ISO 6618 | | 0.05 – 0,2 mgKOH/g (max.) Deklaruje dodavatel | Max + 0,1 mgKOH/g /rok | | Max + 0,2 mgKOH/g /rok | |
| Obsah vody | ČSN ISO 760 | | max. 80 mg/kg | 100 mg/kg | | 500 mg/kg | |
| Deemulgační číslo | ČSN 656230 | | max. 150 s | 300 s | | 700 s | |
| Deemulgační charakteristika | ČSN ISO 6614 ČSN 65 6229 | | 40-37-3 při 54°C, max. za 20 minut | 40-37-3 při 54°C, za 35 minut a více | | 40-37-3 při 54°C, za 50 minut a více | |
| Obsah nerozpustných nečistot | ČSN 65 6219 | | Max. 50 mg/kg | 50 mg/kg | | 100 mg/kg | |



| MPC | | ΔE max. 10 | ΔE 15 až 30 | ΔE 30 až 40 abnormální > ΔE 40 kritický stav |
|--|------------------|--------------------|----------------------------------|---|
| Kód čistoty | ISO 4406:99 | Max 16/14/11 | 18/16/13 | 19/17/16 |
| Bod vzplanutí (°C) OK | ČSN EN ISO 2592 | Min. 246°C | 230 °C | 200°C |
| Obsah aditiv v % (např RULLER, nebo IČ spektrum) | ASTM D6810/D6971 | 100% | 50 % | 25% |
| Odolnost proti stárnutí (TOST) | ASTM 943 | Min.10 000 hod | - | - |
| Oxidační stabilita (RBOT) | ASTM 92272 | Min. 800 min. | 250 h | 100 h |
| Odlučivost vzduchu | ČSN ISO 9120 | Max. 7 min | 10 min | 12 min |
| Pěnivost | ČSN ISO 6247 | max. 25/0 | 450/10 | 600/15 |
| Kvantitativní stanovené otěrových kovů, aditivních prvků a ostatních prvků | | | Nárůst > 10 mg/kg | Nárůst > 20 mg/kg |
| Stanovení IČ spektra | | | Drobné změny oproti novému oleji | Významné změny oproti novému oleji |

V porovnání se statickým limitem se srovnají výsledky měření a pokud jeden nebo více parametrů neodpovídá je označen výsledek jako nevyhovující. Na základě nevyhovujícího výsledku údržba provede nápravné opatření, které odpovídá zjištěnému nálezu – výměnu oleje, doplnění aditiv, filtraci atp.

| Stroj | 1. | 2. | 5. | 6.1 | 6.2 | 7.1 | 7.2 | 6/7 |
|-------------------------------------|----------|----------|----------|-----------|-----------|-----------|----------|----------|
| Kinematická viskozita při 40°C | 45 | 46 | 46 | 33 | 25 | 32 | 25 | 45 |
| TAN - číslo kyselosti | 0,17 | 0,16 | 0,18 | 0,14 | 0,12 | 0,11 | 0,19 | 0,18 |
| Množství vody - coulometricky | 15 | <10 | 23 | 16 | 583 | 18 | 567 | 36 |
| Celkové nečistoty na filtru 0,45um | 63 | 39 | 27 | 47 | 30 | 33 | 45 | 12 |
| MPC | 10 | 8 | 26 | 36 | 3 | 3 | 3 | 2 |
| Kód čistoty čítačem částic NAS 1638 | 8 | 9 | 10 | 10 | 7 | 8 | 9 | 10 |
| 5-15 µm | 36189 | 101766 | 208940 | 195758 | 30551 | 48755 | 72981 | 216400 |
| 15-25 µm | 500 | 1000 | 1001 | 1125 | 500 | 625 | 1000 | 2625 |
| 25-50 µm | <1 | 250 | <1 | <1 | 125 | 125 | 125 | 1625 |
| 50-100 µm | <1 | <1 | <1 | <1 | <1 | 125 | <1 | <1 |
| >100 µm | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Kód čistoty čítačem částic ISO 4406 | 17/14/10 | 19/16/11 | 20/17/11 | 20/17/11 | 16/14/10 | 17/15/11 | 18/16/11 | 19/17/13 |
| > 4µm | 916 | 2592 | 5039 | 5193 | 633 | 1010 | 1413 | 4460 |
| > 6µm | 133 | 371 | 815 | 669 | 154 | 238 | 379 | 1100 |
| > 14µm | 5 | 13 | 14 | 18 | 8 | 10 | 15 | 49 |
| FTIR - oxidace | <1,0 | <1,0 | <1,0 | <1,0 | 5,6 | <1,0 | 5,1 | 2,7 |
| Železo (Fe) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Draslík (K) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Sodík (Na) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Vápník (Ca) | <1 | <1 | 10 | <1 | <1 | <1 | <1 | <1 |
| Hořčík (Mg) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Bor (B) | <5 | <5 | <5 | <5 | <5 | <5 | <5 | <5 |
| Zinek (Zn) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | 2 |
| Fosfor (P) | 2 | 2 | <1 | <1 | 2492 | 1 | 2575 | 475 |
| Síra (S) | 162 | 231 | 159 | 299 | <10 | 1051 | <10 | 8184 |
| Chrom (Cr) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Cín (Sn) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Hliník (Al) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Níkl (Ni) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Měď (Cu) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Olovo (Pb) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Molybden (Mo) | <1 | <1 | <1 | <1 | <1 | <1 | <1 | <1 |
| Křemík (Si) | 1 | 1 | 2 | <1 | 1 | 6 | <1 | 2 |
| Bod vzplanutí v otevřeném kelímku | 232 | 232 | 228 | 227 | 257 | 231 | 266 | 235 |
| RULER - ZDDP | -- | -- | -- | -- | -- | -- | -- | -- |
| RULER - fenolický antioxidant | 49 | 55 | 37 | 15 | 87 | <10 | 94 | |
| RULER - aminický antioxidant | -- | -- | -- | 55 | 82 | 76 | 90 | |
| IČ spektrum v květě | OK | OK | OK | OK | OK | OK | OK | |
| pěnívost - sekv. 1 (24°C) | | | | 320/0/4,0 | 10/0/0,5 | 480/0/8,5 | 10/0/0,5 | |
| pěnívost - sekv.2 (93.5°C) | | | | 30/0/0,5 | 20/0/0,5 | 80/0/0,5 | 20/0/0,5 | |
| pěnívost - sekv.3 (24°C po 93.5°C) | | | | 350/0/3,5 | 190/0/1,5 | 450/0/8,0 | 40/0/0,5 | |
| Odlučivost vzduchu | | | | 3 | 1 | 5 | 1 | |
| Deemulgační číslo | | | | 467 | 342 | 181 | 394 | |

Tabulka 1 - příklad vyhodnocení kondice několika strojů v rámci jedné lokality na základě statických limitů.

Výhodou takového srovnání je, že není potřeba hlubších znalostí problematiky a souvislostí. Z pravidla je takové vyhodnocení k dispozici z laboratoře a vyhodnocení nereflektuje provozní podmínky stroje a informace o provozu/spolehlivosti stroje. Nevýhodou pak je, že v některých případech:

- Provedeme nápravné opatření zbytečně např. výměnu oleje, protože byť hodnota je třeba těsně nadlimitní, vliv vybraného parametru na celkovou funkci maziva je minimální a stroji to vůbec nevadí
- Neprovedeme opatření, protože je hodnota podlimitní, ale přesto došlo k dramatickému zhoršení kondice maziva a technického stavu stroje

11. Vyhodnocování trendu a hledání souvislostí

Vyhodnocování trendu, je jednou z klíčových technik, jak vytěžit z naměřených dat maximum. Podstatou sledování trendu tribodiagnostických dat, je vyhodnocení změny měřených parametrů v časových řadách. Absolutní hodnoty jednoho měření tak mají malou váhu oproti odchylce oproti dlouhodobě měřeným hodnotám. V tomto ohledu je velice praktickou pomůckou zobrazení grafu naměřených hodnot.

Další důležitý faktor při hodnocení, je stanovit si priority a rozumět tomu, jaký parametr je skutečně důležitý. Jak už bylo zmíněno v předchozím textu, hodnocení znečištění by mělo mít vysokou váhu.

Nedílnou součástí vyhodnocení trendu je také porovnání s informacemi z provozu – množstvím a druhem poruch, provozními teplotami, vibracemi, způsobem provozu, prováděné údržbě a opravách atp. Je nutné vycházet z předpokladu, že každý stroj je individuem, které může mít o trochu jiné požadavky

než typově stejný stroj. Pro každý stroj je tak možné poznat individuální limity, kdy máme jistotu, že tato kondice oleje reprezentuje vysokou spolehlivost, minimální opotřebení, vysokou jakost výroby s minimem zmetků.


Analýza prvků obsažených ve vzorku a znalost materiálového složení jednotlivých komponent nám může být velice užitečná při hledání konkrétního mazacího uzlu, kde dochází k poruše.

| Prvek/symbol | Opotřebení | Aditivum | Kontaminant | Primární zdroje | Sekundární zdroje |
|--------------|------------|----------|-------------|---|---|
| Hliník/Al | X | | X | písty, ložiska, dmychadla, turbodmychadla, měniče točivého momentu, lopatky čerpadel | nečistoty, slitina s mědí, v klecích valivých ložisek, pouzdrech a skříních |
| Antimon/Sb | X | X | X | Ložiska | Plastické mazivo, přísada proti otlakům |
| Baryum/Ba | | X | | aditivum* | Plastické mazivo |
| Bór/B | | X | X | aditivum*, upravená chladicí voda | |
| Kadmium/Cd | X | | | Ložiska | pokovování |
| Vápník/Ca | | X | X | aditivum** | voda, plastické mazivo |
| Chrom/Cr | X | | | Pístní kroužky, chromované válce | Ve slitině železem ve valivých ložiskách, hřídele z tvrdých ocelí. |
| Měď/Cu | X | X | | ložiska, klece, pouzdra, přítlačné kroužky, vodítka, chladiče oleje, ložiskové klece, čerpadla... | aditiva do automobilových maziv* |
| Železo/Fe | X | | X | válce, hřídele, převody, valivá ložiska, skříně, pouzdra... | korozí, únavové opotřebení |
| Olovo/Pb | X | | X | čepová ložiska, hlavní ložiska, obložení, čerpadla | barva, pájka, těsnění |
| Hořík/Mg | | X | | aditivum* | mořská voda |
| Mangan/Mn | X | | | hřídele, ventily, dmychadla | několik |
| Molybden/Mo | X | X | | aditivum* | Pístní kroužky |
| Nikl/Ni | X | | | s železem v ocelích, hřídele, valivá ložiska | |
| Fosfor/P | X | X | | aditivum, opotřebení | povrchová úprava ozubených kol |
| Draslík/K | | | X | přísada do chladicí kapaliny | |
| Křemík/Si | X | X | X | písek, nečistoty, prach, protipěnovací přísada, některé filtry pro odstraňování kyselin | Litina (slitina se železem) |
| Stříbro/Ag | X | | | čepy (EMD) | pájka |
| Sodík/Na | | X | X | obsažená v některých nových olejích, chladicí kapalina | plastické mazivo |
| Cín/Sn | X | | | ložiska, s mědí v klecích valivých těles, blikavá | pájka |
| Titan/Ti | X | | | lopatky turbíny | barva, katalyzátor esterifikace v olejích na bázi esterů** |
| Vanad/V | X | | | lopatky turbíny | ventily |
| Zinek/Zn | | X | X | aditivum** | pozinkovaná ocel, pokovení, plastické mazivo |

12. Případová studie – kondice olejů na hydraulických vstřikolisech


Příklad 1.

Na trendu hodnot je patrné zvýšené hodnoty MPC a celkových nečistot v průběhu roku 2015. Příčinou zvýšené oxidační zátěže a množství částic opotřebení bylo enormní zvýšení provozní zátěže stroje. Vliv na spolehlivost stroje to nemělo, situaci se podařilo následně stabilizovat. Je pravděpodobné, že to bude do budoucna mít vliv na životnost stroje.




Příklad 2.

Nový stroj vykazoval zvýšené znečištění oleje. Vhodnou péčí o olej se podařilo parametry oleje stabilizovat a kontaminace oleje je dlouhodobě na nízké úrovni. Lis nevykazuje jakékoliv problémy.



Příklad 3


Po úvodním stabilizování znečištění oleje, lis dlouhodobě pracoval bezporuchově. Trend znečištění vykazuje v posledních měsících nárůst a v posledním rozboru se objevuje železo 5,2 mg/kg a měď 7 mg/kg. Ačkoliv se jedná o podlimitní hodnoty otěrových kovů, jedná se první signály zvýšeného opotřebení a pokud se neprovede adekvátní opatření, lze s vysokou pravděpodobností očekávat neplánovanou poruchu a zhoršení jakosti výroby. Vzhledem k přítomnosti železa i mědi se pravděpodobně bude jednat o opotřebení hydraulického čerpadla.



13. Predikce budoucího chování

Některé parametry oleje jsou ideální pro predikci. Naopak, chování některých parametrů je ryze ovlivněno vnějšími vlivy a údržba na ně musí reagovat pouze preventivně.


Na příkladě si ukážeme, že pokud známe vnitřní mechanismus chemických procesů degradace oleje, můžeme velice efektivně využít celkové životnosti maziva, aniž bychom jakkoliv riskovali spolehlivost stroje. Většina současných olejů je vybavena přídatnou látkou – antioxidantem, který významně ovlivňuje dlouhodobou oxidační stabilitu oleje a zabraňuje jeho degradaci. Antioxidant se přirozeně vyčerpává a ve chvíli, kdy jeho koncentrace klesne na nízkou úroveň, olej ztratí „obranyschopnost“ a může nastat jeho prudká degradace a v konečném důsledku i selhání funkce. Docela dobře to ilustruje následující graf.



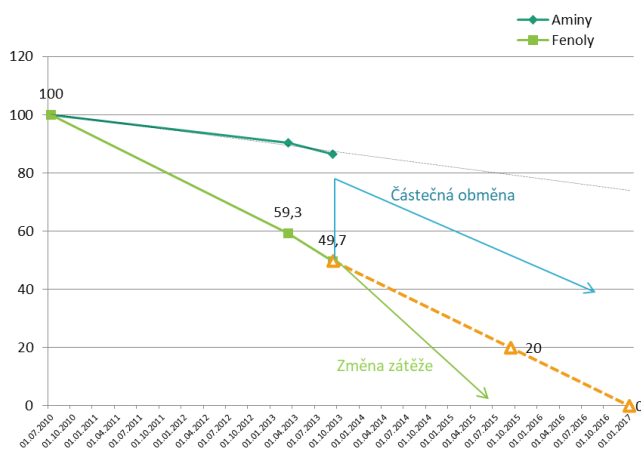
Cílem tribodiagnostika je tak najít „bod zlomu“. Na základě empirických poznatků byla stanovena 25% zbývající koncentrace antioxidantů, která pro uživatele představuje hranici, kdy by měl zvážit výměnu olejové náplně nebo doplnění antioxidantu, protože za touto hranicí se dramaticky zvyšuje pravděpodobnost rozvoje řetězové chemické reakce s důsledky na spolehlivost a životnost stroje.

Nový olej reprezentuje 100% koncentraci antioxidantů. Pokud máme několik dostatečně od sebe vzdálených měření, můžeme s využitím lineární regrese (s výpočtem metodou nejmenších čtverců) stanovit poměrně přesný termín konce životnosti olejové náplně.


Estimace konce životnosti olejové náplně s využitím lineární regrese



Odhad je vhodné korigovat na základě vstupů údržby. Pokud údržba provede doplnění oleje, termín výměny se s vysokou pravděpodobností posune. Pokud se zvýší výroba/oxidační zátěž oleje, nastane konec životnosti olejové náplně pravděpodobně o něco dřív.



Realita – odhad životnosti olejové náplně se od skutečnosti lišil jen o několik týdnů.



14. Závěr

Tribodiagnostika, resp. sledování kondice maziv je jednou z klíčových součástí prediktivní údržby. Ve spolupráci s ostatními diagnostickými metodami dokáže poskytovat zásadní informace pro zajištění



dlouhodobé spolehlivosti a jakosti výroby. Účinnost tribodiagnostiky naráží často na malé množství dat, které do budoucna budou dostupnější díky on-line snímačům. Přesné vyhodnocení dat, trendů a propojení informací z provozu zatím vyžaduje hlavně lidský úsudek a zkušenost. Díky masivnímu rozvoji informačních technologií a průmyslu 4.0 budeme v budoucnosti schopni efektivně zapojit algoritmy strojového zpracování dat a algoritmy umělé inteligence, které významně zvýší efektivitu tribodiagnostiky.

Použitá literatura:

- [1] Interní materiály společnosti KLEENTEK spol. s r.o.
- [2] <https://www.machinerylubrication.com/Read/28374/oils-grease-nuclear-generator>
- [3] <https://www.machinerylubrication.com/Read/108/oil-analysis-power-generation>

Kontakt

Ing. Jan Novák
Česká zemědělská univerzita v Praze, Technická fakulta, katedra jakosti a spolehlivosti strojů,
Kamýcká 129, 165 21 Praha – Suchbátka
E-mail: jan.novak@kleentek.cz

Prediktivní údržba – zkušenosti z pohledu auditů údržby

Ing. Jan Hroch, člen předsednictva a výkonný ředitel ČSPÚ

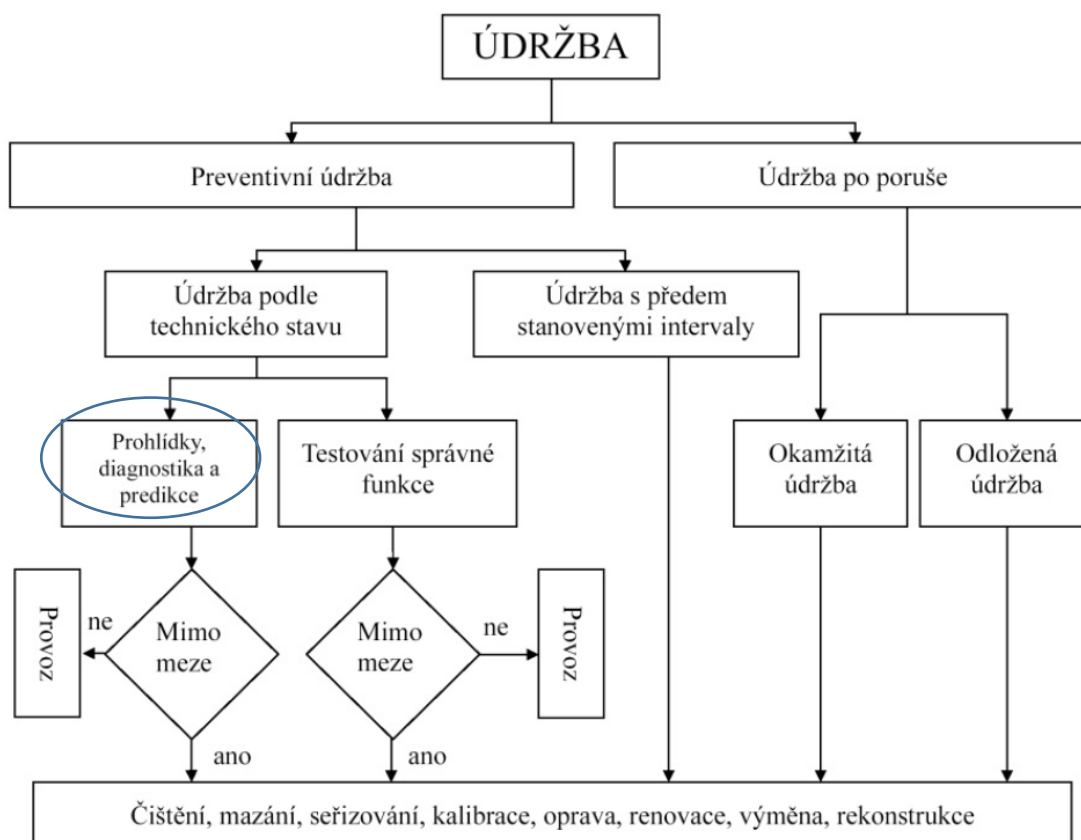
Václav Šimek, vedoucí údržby Vitesco Technologies a člen předsednictva ČSPÚ

prof. Ing. Martin Pexa, Ph.D., vedoucí KJSS TF, ČZU v Praze a předseda ČSPÚ

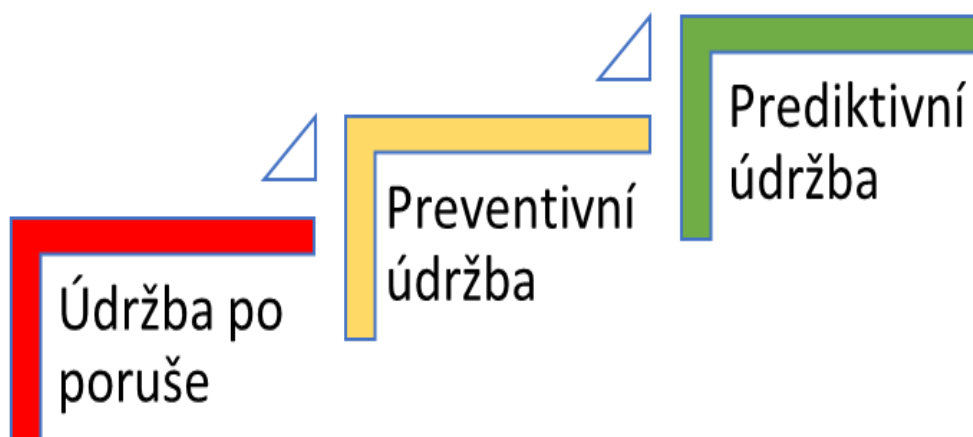
1. Úvod

Téma prediktivní údržby je v údržbářských kruzích diskutováno již poměrně dlouhou dobu. **Údržba představuje proces řízení definovaný jako kombinace všech technických, administrativních a manažerských opatření během životního cyklu objektu, zaměřených na jeho udržení ve stavu nebo jeho navrácení do stavu, v němž může vykonávat požadovanou funkci.**

Prediktivní údržba je součástí strategie údržby a je jedním z vyšších stupňů preventivní údržby (obr. 1 a 2). **Prediktivní údržba (předpovídaná údržba) je údržba podle stavu, prováděná na základě předpovědi odvozené z opakované analýzy, nebo ze známých charakteristik a vyhodnocení významných parametrů degradace objektu.**



Obr. 1 Přehled typů údržby dle [1]



Obr. 2 Predikce jako vyšší stupeň prevence

Česká společnost pro údržbu se dlouhodobě zabývá údržbou z komplexního pohledu. Pro posouzení stavu zajištění údržby využívá metodiku Auditů údržby. Na stav uplatnění metod prediktivní údržby se příspěvek zaměří z pohledu auditů údržby provedených ČSPÚ v průmyslových firmách v České republice v období I. – III.Q 2022.

2. Audit (analýza) managementu údržby jako základ pro zlepšování

Audit je chápán jako systematický, nezávislý a dokumentovaný proces získávání důkazů z auditu a jeho objektivního hodnocení s cílem stanovit rozsah splnění kritérií auditu. Kritéria auditu jsou obecně chápána jako soubor politik, postupů nebo požadavků na systém managementu kvality, kvality procesu nebo produktu. Důkazy z auditu jsou tvořeny záznamy, konstatováním skutečnosti nebo jinými informacemi, které souvisejí s kritérii auditu a jsou ověřitelné jak ve formě kvalitativní, tak i kvantitativní. Zjištění z auditu jsou výsledky hodnocení shromážděných důkazů z auditu podle kritérií. Zjištění z auditu mohou označovat buď shodu nebo neshodu s kritérii, nebo příležitosti ke zlepšování.

Na základě výše uvedených kritérií auditu má ČSPÚ vypracován postup založený na systému otázek (indikátorů) a jejich váhy, které umožňují prakticky vykonávat audit managementu údržby v organizacích různého typu a zaměření.

Výstupem je:

- soubor zjištění z auditu,
- kvantitativní zhodnocení současného stavu managementu údržby,
- grafické vyjádření,
- popis silných a slabých stránek,
- formulace opatření ke zlepšení,
- návrh spolupráce při realizaci opatření.

Metodika Auditů údržby ČSPÚ vychází z metodiky harmonizované s požadavky EFNMS (Evropská federace národních společností pro údržbu) a je zaměřena na oblasti uvedené v tabulce číslo 1.

Tab. 1 Oblasti Auditů (analýzy) managementu údržby

| | |
|---|--|
| 1 | <p>Charakteristika podnikatelských činností a výrobních zařízení v organizaci</p> <ul style="list-style-type: none"> • podnikatelské plány, vztah k údržbě • reprodukční hodnota a náklady na údržbu • pasportizace výrobních zařízení, provoz a BOZP • QM ve vztahu k údržbě • životní cyklus výrobních zařízení, obnova a modernizace |
| 2 | <p>Strategie a systémy údržby v organizaci</p> <ul style="list-style-type: none"> • strategie a cíle údržby • kapitálové investice do obnovy a modernizace výrobních zařízení, podíl údržby • rozpočty údržby, interní, externí údržba, outsourcing • hodnocení dodavatelů, smlouvy |
| 3 | <p>Organizace a řízení personálu v údržbě (systém, legislativa)</p> <ul style="list-style-type: none"> • řídicí struktura, pravomoci a odpovědnosti pracovníků v údržbě • plánování kapacit údržby • kvalifikace pracovníků • pracovní týmy, komunikace v údržbě • pracovní morálka, absence, fluktuace, pracovní podmínky • výběr a hodnocení pracovníků v údržbě, motivační systém • výcvik a vzdělávání pracovníků v údržbě |
| 4 | <p>Administrativa a dokumentace managementu údržby výrobních zařízení</p> <ul style="list-style-type: none"> • dokumentace managementu údržby v organizaci • sběr, zpracování, využití dat • záznamy o údržbě, historie poruch, ND • náklady údržby • dodavatelé výrobních zařízení, VD • využití dat pro preventivní a prediktivní údržbu |
| 5 | <p>Preventivní údržba</p> <ul style="list-style-type: none"> • postavení preventivní údržby a strategie organizace • identifikace klíčových procesů a zařízení • programy preventivní údržby • vedení a využití záznamů o poruchách • využití metod FMEA a FMECA pro tvorbu programů údržby • optimalizační metody, RCM, návratnost preventivní údržby • využití preventivní údržby v procesu zlepšování |
| 6 | <p>Plánování, rozvrhování a pracovní příkazy v údržbě</p> <ul style="list-style-type: none"> • tvorba rozpočtů údržby • postupy pro údržbu • spolupráce údržby a výroby na plánování a postupech • plánování ND pro údržbu • externí dodavatelé a outsourcing • systém zadávání a vyhodnocování požadavků na údržbu • pracovní příkazy |
| 7 | <p>Realizace údržbářských procesů (postupy, bezpečnost)</p> <ul style="list-style-type: none"> • poruchové stavy – identifikace, odstranění, limity pro údržbu |

| | |
|----|--|
| | <ul style="list-style-type: none"> • údržba po poruše a plánovaná údržba • preventivní a prediktivní údržba • pokyny a postupy, bezpečnost, QM údržby • využití diagnostiky • odstávky a zarážky |
| 8 | Nakupování, skladování a řízení zásob náhradních dílů a materiálu <ul style="list-style-type: none"> • nákupní strategie, postupy, odpovědnosti • hodnocení dodavatelů • schvalovací procesy, spolupráce nákupu a údržby • řízení procesu skladování, sledování a optimalizace ND a materiálů pro údržbu • QM NDM • ukazatele efektivnosti zásob NDM |
| 9 | Měření účinnosti a efektivity údržby, její zlepšování a hodnocení spokojenosti zákazníků <ul style="list-style-type: none"> • sledování nákladů ve vztahu k údržbě • měření a vyhodnocování provozních ukazatelů výrobních zařízení • OEE, bezporuchovost, udržovatelnost, životnost • výkonnost údržbářských procesů, KPI, SLA, benchmarking údržby • výkonnost pracovníků údržby • hodnocení kvality údržby • hodnocení externích dodavatelů |
| 10 | Počítačová podpora řízení údržby <ul style="list-style-type: none"> • systém PC podpory údržby, SW • návaznost a kompatibility se systémem řízení organizace • moduly pro údržbu výrobního zařízení • odpovědnosti a pravomoci pracovníků údržby • využití PC podpory, data, analýzy, optimalizace • vizualizace • digitalizace |

Audit (analýza) probíhá v několika krocích.

Poznávací návštěva - slouží k prvnímu seznámení s firmou zadavatele a výměně základních informací.

Zpracování plánu analýzy - definuje předpokládaný rozsah analýzy na základě předchozí návštěvy, seznámení týmu se zadáním, zpracování harmonogramu, příprava podkladů, zaslání zadavateli, dohoda a součinnost se zadavatelem.

Provedení analýzy na místě - v průběhu se provádí sběr informací a dat, rozhovory s odpovědnými pracovníky, SWOT analýzy, prohlídky pracoviště (zapůjčení vybrané dokumentace).

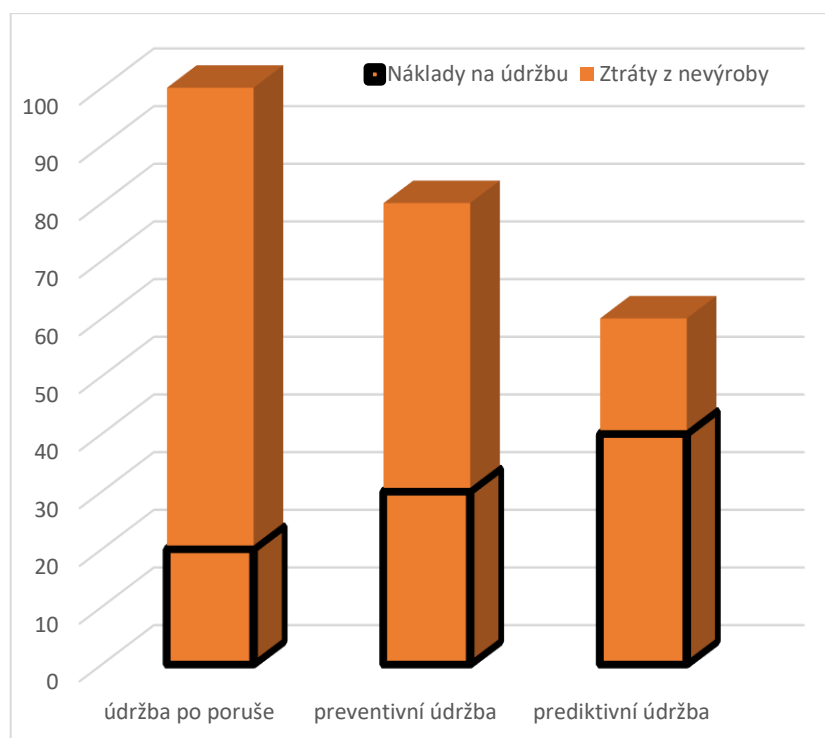
Zpracování závěrečné zprávy a její předání zadavateli k prostudování, úpravy zprávy podle připomínek, návrh a formulace opatření ke zlepšení.

Projednání závěrečné zprávy u zadavatele analýzy, projednání návrhů doporučení ke zlepšení, nabídka možností další spolupráce, předání zprávy.

3. Preventivní a prediktivní údržba v auditu údržby

Pro zjištění stavu o preventivní a prediktivní údržbě je v metodice auditu několik otázek, ve kterých je problematika diskutována a je zjišťován praktický přístup, postupy a přínosy.

Hlavním cílem prevence a predikce je optimalizace nákladů na údržbu spolu s minimalizací ztrát ve výrobě, způsobených nevyrábějícím zařízením (obr. 3).



Obr. 3 Vývoj nákladů na údržbu a ztrát z nevýroby

Příklad konkrétních otázek, které souvisí s preventivní a prediktivní údržbou v rámci auditu jsou uvedeny v tabulce číslo 2, napříč jednotlivými sledovanými oblastmi.

Tab. 2 Příklady auditních otázek souvisejících s preventivní a prediktivní údržbou

| | |
|-----|--|
| 1.2 | Má organizace dokumentovány počty a druhy výrobních zařízení, jejich technický stav a stáří, rozmístění ve výrobních provozech, halách a pracovištích, specifikace kritičnosti a důležitosti zařízení? |
| 1.3 | Jaká je reprodukční hodnota udržovaného majetku , celkové náklady na jeho údržbu (z toho na interní a externí údržbu a na preventivní údržbu a údržbu po poruše), roční obrat, počet údržbářů včetně manažerů a celkový počet zaměstnanců organizace? |
| 1.4 | Má organizace provedenou pasportizaci výrobních zařízení (návody k obsluze a k údržbě, dílenské příručky, katalogy náhradních dílů a materiálů, výkresy, schémata zapojení apod.) a na jaké úrovni? |
| 2.1 | Má organizace vypracovanou strategii a cíle údržby (organizační a řídicí struktura, outsourcing údržby, zdroje (personál a výcvik, technické informace, náradí a přístroje, náhradní díly a materiál, objekty, finance), koncepty (systémy) údržby , plánování a rozvrhování údržby, technologie údržby, logistická podpora údržby, informační technologie v údržbě, ekonomika údržby, systém jakosti v údržbě, environmentální management, bezpečnost a ochrana zdraví při práci, měření výkonnosti a účinnosti údržby, zlepšování údržby)? |

| | |
|------|---|
| 3.14 | <i>Na jaké úrovni je vzdělávací a výcvikový proces pro pracovníky údržby? (všeobecně, technické oblasti, problémy vedení, řešení problémů, management údržby)</i> |
| 5.1 | <i>Má preventivní údržba podporu vrcholovým managementem organizace?</i> |
| 5.2 | <i>Jsou využívány výsledky technických a inspekčních prohlídek ke tvorbě programu a přípravě preventivní údržby?</i> |
| 5.6 | <i>Je prováděna analýza návratnosti vkladů do preventivní údržby?</i> |
| 5.9 | <i>Využívá organizace metody prediktivní údržby pro neustálé zlepšování efektivnosti a účinnosti výrobního zařízení?</i> |
| 7.7 | <i>Jaká je úroveň rozpracování pokynů a návodů pro realizaci preventivní a prediktivní údržby?</i> |
| 7.9 | <i>V jakém rozsahu je využívána diagnostika a monitorování technického stavu a jiné nedestruktivní techniky (defektoskopie) při realizaci údržby?</i> |

Požadavky na údržbu jsou také součástí systémových norem aplikovaných a auditovaných zejména v automobilním průmyslu a řetězci dodavatelů automotive, jak je uvedeno v tabulce 3. Příkladem je ISO TS 16949 – Systémy managementu kvality - Zvláštní požadavky na používání ISO 9001 – v organizacích zajišťujících sériovou výrobu a výrobu náhradních dílů v automobilovém průmyslu.

Tab. 3 Příklad požadavku normy na preventivní údržbu [1]

| 7.5.1.3 Ověřování seřízení | | |
|--|--|---|
| | Požadavky | Odkazy |
| 7.5.8 | Ověřuje organizace průběh seřízení kdykoli se provádí? | Záznamy o seřízení a uvolnění seřízení. |
| 7.5.9 | Jsou pracovní instrukce organizace pro zaměstnance provádějící seřízení dostupné? | Instrukce pro průběh seřizování. |
| 7.5.10 | Používá organizace pro ověřování, kde to je možné, statistické metody? | Záznamy o seřízení. |
| 7.5.1.4 Preventivní a prediktivní údržba | | |
| 7.5.11 | Identifikuje organizace zařízení nezbytné pro klíčové procesy, poskytuje zdroje pro údržbu strojů/zařízení a buduje účinný systém plánované celkové preventivní údržby? | Existence preventivní údržby. |
| 7.5.12 | Zahrnuje systém preventivní údržby organizace minimálně: <ul style="list-style-type: none"> plánované činnosti údržby, balení a konzervaci zařízení, nástrojů a měřidel, dostupnost náhradních dílů pro klíčová výrobní zařízení, dokumentování, hodnocení a zlepšování cílů údržby? | Efektivnost systému doložená ukazateli specifických měření. Seznam klíčového zařízení. Záznamy o údržbě. Příklady prediktivní údržby. Prohlídka závodu. |
| 7.5.13 | Využívá organizace metody prediktivní údržby pro neustálé zlepšování efektivnosti a účinnosti výrobního zařízení? | Příklady prediktivní údržby. |

V tabulce číslo 4 je uvedena reakce na otázku v bodě 5.9 jako příklad realizovaného auditu a z něj plynoucího zjištění.

Tab. 4 Příklady odpovědí na auditní otázku 5.9.

5.9. Využívá organizace metody prediktivní údržby pro neustálé zlepšování efektivity a účinnosti výrobního zařízení?

Odpovědi a závěry:

Společnost využívá pro zlepšování efektivity a účinnosti výrobního zařízení technickou diagnostiku, kterou zajišťuje Technická skupina (TS).

Viz TS – trendy měření v excelovské tabulce V případě, že se naměřené hodnoty dostanou do „červeného pole,, - plánován zákrok údržby.

1. Jedná se o údržbu diagnostickou, metody predikce nejsou zavedeny.

Individuální NONSTOP monitoring na periferie důležitých strojů, diagnostika sledování přesnosti stroje, tribodiagnostika, termovize, vibrodiagnostika, diagnostika úniků vzduchu Fluke ii9000 viz výše

externě vibrodiagnostika, úniky vzduchu
vibro - sledovány trendy
tribo diagnostika - např. čerpadla
termovize - při výpadku kompresorů, která fáze se ohřívá
měření kruhovitosti-příklad. poškození kuličkového šroubů

2. Převážně se jedná o diagnostiku bez využití v prediktivní údržbě

3. Nevyužívá.

4. Prediktivní údržba se nevyužívá.

Online forma diagnostiky na kritických zařízeních. Ideální stav trendy a jakmile je překročen stanovený limit automatická informace do Profylaxu s vygenerováním pracovního příkazu pro provedení kontroly zařízení.

5. Prediktivní údržba není zavedena.

Ano

Ano. Ne však dle normy.

Ano

6. Příklad prediktivní údržby nebyl v rámci auditu předložen, prediktivní údržba není popsána a zavedena, jedná se o diagnostickou údržbu.

V praxi je prediktivní údržba chápána spíše jako údržba periodická preventivní případně údržba diagnostická. Ve skutečnosti je prediktivní údržba nadstavbou údržby preventivní diagnostické.


Využívány jsou zejména diagnostické metody:

- Vibrodiagnostika – zde jsou sledovány trendy, je využíván on-line monitoring nebo napojení na expertní systém (např. SKF),
- Tribodiagnostika – zejména rozbory olejů zajištěné dodavatelsky odbornou firmou, bývá kombinováno s outsourcingem fluid managementu,
- Termodiagnostika – zejména v kontrolách elektrozařízení, nebo v kombinaci s vibrodiagnostikou,
- Měření úniků médií – převážně stlačeného vzduchu, je používáno většinou pro inspekční kontrolu rozvodů v rámci odstávek provozů,
- Sledování dalších provozních parametrů (tlaky, výkon, spotřeba energie apod.).

Po provedení auditu probíhá jeho zpracování s cílem odpovědi zadavatele převést na kvantitativní vyjádření, které se uvádí formou tabulky (tab. 5 a 6) nebo grafu (obr. 4 a 5). Tabulka číslo 5 a obrázek číslo 4 uvádí příklad výsledku auditu, kdy je preventivní údržba slabým článkem systému údržby. Opačný výsledek je zobrazen v tabulce číslo 6 a na obrázku číslo 5, kdy je preventivní údržba silným článkem systému.

Tab. 5 Příklad hodnocení výsledků auditu – preventivní údržba je slabý článek systému.


| Hodnocení výsledků auditu | | |
|--|----------------------|----------------------------|
| | plnění požadavků (%) | potenciál pro zlepšení (%) |
| Charakteristika podnikatelských činností a výrobních zařízení v organizaci | 78,5 | 21,5 |
| Strategie a systémy údržby v organizaci | 61,9 | 38,1 |
| Organizace a řízení personálu v údržbě (systém, legislativa) | 71,4 | 28,6 |
| Administrativa a dokumentace managementu údržby výrobních zařízení | 67,2 | 32,8 |
| Preventivní údržba | 36,3 | 63,8 |
| Plánování, rozvrhování a pracovní příkazy v údržbě | 67,2 | 32,8 |
| Realizace údržbářských procesů (postupy, bezpečnost) | 63,7 | 36,3 |
| Nakupování, skladování a řízení zásob náhradních dílů a materiálu | 90,0 | 10,0 |
| Měření účinnosti a efektivity údržby, její zlepšování a hodnocení spokojenosti zákazníků | 73,5 | 26,5 |
| Počítačová podpora řízení údržby | 44,1 | 55,9 |



Obr. 4 Příklad hodnocení výsledků auditu – preventivní údržba je slabý článek systému.


Tab. 6 Příklad hodnocení výsledků auditu – preventivní údržba je silný článek systému, chybí uplatnění prediktivní údržby.

| Hodnocení výsledků auditu | | |
|--|----------------------|----------------------------|
| | plnění požadavků (%) | potenciál pro zlepšení (%) |
| Charakteristika podnikatelských činností a výrobních zařízení v organizaci | 60,0 | 40,0 |
| Strategie a systémy údržby v organizaci | 73,8 | 26,2 |
| Organizace a řízení personálu v údržbě (systém, legislativa) | 79,3 | 20,7 |
| Administrativa a dokumentace managementu údržby výrobních zařízení | 48,4 | 51,6 |
| Preventivní údržba | 90,0 | 10,0 |
| Plánování, rozvrhování a pracovní příkazy v údržbě | 76,0 | 24,0 |
| Realizace údržbářských procesů (postupy, bezpečnost) | 71,3 | 28,7 |
| Nakupování, skladování a řízení zásob náhradních dílů a materiálu | 83,3 | 16,7 |
| Měření účinnosti a efektivity údržby, její zlepšování a hodnocení spokojenosti zákazníků | 79,0 | 21,0 |
| Počítačová podpora řízení údržby | 90,0 | 10,0 |



Obr. 5 Příklad hodnocení výsledků auditu – preventivní údržba je silný článek systému.

Na obrázku číslo 6 jsou uvedeny příklady 6 firem a závěrečné hodnocení preventivní údržby realizované v roce 2022. Hodnoty značně kolísají v rozsahu od 22 % do 90 %.



Obr. 6 Hodnocení plnění požadavků na preventivní údržbu – audity ČSPÚ 2022

4. Preventivní a prediktivní údržba v reálném podniku

Pro účel příkladu dobré praxe v oblasti aplikace sběru a zpracování dat pro preventivní a prediktivní údržbu byl vybrán společně s Václavem Šimkem, vedoucím údržby Vitesco Technologies, členem předsednictva ČSPÚ a auditorem ČSPÚ příklad aplikace systému Condition Monitoring od firmy Siemens.

Společnost Vitesco Technologies nasadila k analýze dat systém Condition Monitoring od firmy Siemens



Aktualizace: 06.10.2022

07:45 Vydáno: 06.10.2022, 07:45

Vitesco Technologies/
 Společnost Vitesco Technologies, přední výrobce pohonných ústrojí pro čistou mobilitu a elektromobilitu, nasadila ve svém výrobním závodě v Trutnově systém Condition Monitoring od firmy Siemens. „**Digitální řešení Condition Monitoring je komplexní softwarové řešení pro sběr dat z výrobních strojů a dalších zdrojů a jejich**

analýzu,“ vysvětluje Pavel Kříž, vedoucí segmentu Servis systémů pro obráběcí stroje a pohony. „**Dokáže sbírat data z celého výrobního řetězce a jejich následná analýza umožní předem eliminovat příčiny poruch a prostožů a ušetřit tak čas a především peníze,**“ dodává Pavel Kříž.

Společnost Vitesco Technologies se zaměřuje na výrobu a vývoj technologií pro čistou mobilitu pro všechny typy vozidel. Její portfolio tak zahrnuje řešení pro čištění výfukových plynů, elektronické řídicí jednotky, senzory pro široké spektrum použití, elektrické pohony a silovou elektroniku pro hybridní vozidla a elektromobily.

Co umí Siemens Condition Monitoring

Systém Condition Monitoring společnosti Siemens je komplexním softwarovým řešením pro sběr dat z výrobních strojů a dalších zdrojů a jejich analýzu. Dokáže sbírat data týkající se výrobního zařízení, výrobního procesu, výrobku anebo výrobního prostředí. Tato data se následně ukládají do úložiště, kterým může být lokální databáze nebo cloudové úložiště. Nad těmito daty se v reálném čase provádí rozšířená analýza a vytvářejí se reporty či notifikace. Díky přesným a reálným informacím z výroby může uživatel eliminovat zásadní příčiny poruch a prostojů a docílit tak klíčových přínosů.

Systém Condition Monitoring pokrývá tři základní vrstvy: první vrstvou je konektivita strojů, případně jiných datových zdrojů, jako je SAP, MAS nebo jiné zákaznickovy již nainstalované systémy. Podotkněme, že konektivita strojů je vůbec první a nejdůležitější krok v oblasti průmyslové digitalizace. Druhou vrstvou je analýza získaných dat formou interaktivního webového prostředí nebo chytrého reportingu pro potřeby veřejné prezentace. Třetí vrstvou je pokročilá datová analytika pro snadné vytěžení důležitých informací, tedy indicií k optimalizaci výroby. ***V ní je například zahrnuta naše reálná prediktivní údržba, která slouží ke včasné predikci zařízení nebo automatické optimalizace technologického procesu s využitím neuronových sítí a strojového učení. Toto řešení je implementovatelné do všech typů řídicích systémů bez ohledu na jejich verzi nebo stáří.***

Siemens Condition Monitoring v aplikaci Vitesco Technologies



Technologie Condition Monitoring má v aplikaci ve společnosti Vitesco Technologies několik úkolů. „V první řadě poskytuje přesné a spolehlivé údaje o údržbě výrobních zařízení a celé výroby. Systém zabezpečuje i dokonalou transparentnost výroby tím, že identifikuje konkrétní provozní stavy jednotlivých strojů a zaměřuje se přitom na neproduktivní provozní stavy,“ popisuje Pavel Kříž.

Systém Condition Monitoring poskytuje data o výrobě, počtu vyrobených kusů i výrobních taktech. Tyto údaje následně předává jak prostřednictvím

webového rozhraní, tak interním systémem MES, který pro tento účel ve Vitescu zavedli. ***„Vedle uvedených funkcionalit Condition Monitoring poskytuje údržbě data z historie všech alarmů a hlášení na jednotlivých strojích,“*** uzavírá Pavel Kříž.

Podle Václava Šimka, vedoucího oddělení údržby společnosti Vitesco Technologies, bylo cílem dosáhnout zavedením Condition Monitoringu do oblasti obrábění standardu, který je obvyklý v oblasti montážních linek. „Obrábění je totiž specifické v tom, že oprava poruchy může trvat relativně krátkou dobu a následné uvolnění stroje kolegy z oddělení průmyslového inženýrství či kvality může trvat násobně delší dobu. Bylo třeba rozdělit dobu odstavení stroje na jednotlivé časové úseky a zkrátit tyto časy, kdy stroj nevyroběl na minimum jak v týmu údržby, tak v ostatních podpůrných týmech.“

Condition Monitoring poskytuje odborníkům na údržbu ve Vitesco Technologies exaktní informace, které ukazují, zda je údržba prováděna správně a bez zbytečných prostojů.



Na základě jasné definice toho, co je potřeba měřit, byly specifikovány stavy, které systém sleduje. Condition Monitoring je v aplikaci Vitesco Technologies individualizovaný tak, aby přesně odpovídal potřebám firmy.

„Nejdříve jsme pilotně odzkoušeli projekt na 13 strojích technologie pro broušení válců pro vstříkovací čerpadla,“ popisuje zavádění Condition Monitoringu Václav Šimek. „Postupně se do systému přidávaly další stroje a funkcionality, jako například vizualizace stavů, kdy stroj nevyrábí v sériovém režimu. Je to zejména stav při seřizování, kdy se rychlosti osníží pod 100 %, což může způsobit riziko.

Systém Condition Monitoring se ve společnosti Vitesco Technologies osvědčil a jeho výstupy využívá i oddělení výroby, a to stále intenzivněji.

Funkcionality systému se nadále rozvíjejí a vylepšují, pro další období je plánována implementace nové verze se zaměřením na vytížení a životnost obráběcích nástrojů.

5. Závěr

Při zpracování dat z auditů údržby provedených ČSPÚ v I. – III.Q roku 2022 lze učinit některé závěry, které je nutno považovat za příklady, neboť nebyl vybírán reprezentativní vzorek. Audity byly provedeny ve firmách, které měly zájem zlepšovat systém řízení údržby a byly si částečně vědomi svých slabých stránek.

Z obrázku 6 je patrné, že v uvedeném vzorku 6 ti firem, byla pouze jedna, ve které byla oblast zajištění preventivní údržby hodnocena jako silný článek systému. Naproti tomu byla preventivní údržba hodnocena jako slabý článek systému ve 3 auditovaných firmách. Zbylé 2 firmy vykazovaly naplnění požadavků na preventivní údržbu v průměrné výši.

V žádné z auditovaných firem nebyl popsán ani zaveden systém prediktivní údržby. Většina auditovaných firem chápe pojem prediktivní údržba ve smyslu preventivní a diagnostické.

Příklad nasazení systému Condition Monitoringu ve firmě Vitesco ukazuje správnou cestu a dobrou praxi k digitalizaci výrobních systémů, sběru a analýze dat a následně jejich využití pro predikci chování systému a správnému naplánování prediktivní údržby výrobního zařízení.



Použitá literatura

- [1] LEGÁT, V. a kol.: Management a inženýrství údržby. Professional Publishing, Praha 2016, ISBN978-80-7431-119-2.
- [2] Data ČSPÚ – Audity systému údržby 2022
- [3] Společnost Vitesco Technologies nasadila k analýze dat systém Condition Monitoring od firmy Siemens, ČESKÉ NOVINY, 6.10.2022

Kontakt:



Ing. Jan Hroch, výkonný ředitel, Česká společnost pro údržbu, z.s., areál České zemědělské univerzity v Praze, Technická fakulta, Kamýcká 872, 165 00 Praha – Suchbátka, www.udrzba-cspu.cz



+420 732 385 196



jan.hroch@udrzba-cspu.cz

www.linkedin.com/in/hroch-jan



Česká společnost pro jakost, Novotného lávka 5, 116 68 Praha 1
ÚLOHA PREDIKTIVNÍ ÚDRŽBY VE SPOLEHLIVOSTI, 6. 12. 2022

ISBN 978-80-02-02999-1

Úloha prediktivní údržby ve spolehlivosti

Sborník přednášek

kolektiv autorů

1. vydání

rok vydání 2022, Česká společnost pro jakost

vazba brožovaná, 54 stran