

Univerzita Hradec Králové
Fakulta informatiky a managementu
Katedra informatiky a kvantitativních metod

Predikční analýzy ve společnosti Vitesco Technologies

Bakalářská práce

Autor: Miluše Machová

Studijní obor: Informační management

Vedoucí práce: prof. RNDr. PhDr. Antonín Slabý, CSc.

Hradec Králové

duben 2021

Prohlášení:

Prohlašuji, že jsem bakalářskou práci zpracovala samostatně a s použitím uvedené literatury.

V Hradci Králové dne 30.4.2021

Miluše Machová

Poděkování

Tímto děkuji panu prof. RNDr. PhDr. Antonínu Slabému, CSc. za jeho cenné rady a vedení mé bakalářské práce. Dále bych ráda poděkovala řediteli závodu Vitesco Technologies v Trutnově panu Lukáši Rosůlkovi a vedoucímu údržby panu Václavu Šimkovi za umožnění spolupráce. Také děkuji za odborný dohled a připomínky panu Zdeňku Machovi a Tomáši Mizerovi a všem, kteří mě při psaní této práce podpořili.

Anotace:

Předmětem bakalářské práce je seznámení s predikčními analýzami a jejich metodami jako jsou analýzy časových řad, klasifikační a regresní stromy, neuronové sítě a Kalmanův filtr. Dále se práce zabývá existujícími metodikami a strategiemi údržby včetně prediktivní údržby. V praktické části se práce věnuje společnosti Vitesco Technologies a přístupem k údržbě v tomto podniku. Následuje vysvětlení jednotlivých charakteristik vibrací měřených senzory na konkrétním zařízení a popisuje možnosti zavedení prediktivní údržby na tomto zařízení. Na závěr jsou popsány možnosti softwaru MATLAB s jeho nadstavbou Simulink a doplňkem Predictive Maintenance Toolbox.

Klíčová slova:

Predikční analýzy, prediktivní údržba, vibrodiagnostika

Annotation:

The aim of this bachelor thesis is an acquaintance with prediction analysis and its methods as the time series analysis, classification and regression trees, neuron networks and Kalman's filter. Thesis also deals with existing methodologies and maintenance strategies, including predictive maintenance. In practical part, thesis concentrates on Vitesco Technologies company and its proceeding to maintenance. Follows explanation of individual characteristics of vibrations, measured by sensors on particular machine and describing possibilities for implementation of predictive maintenance on this machine. Finally, MATLAB software features are described including its extension Simulink and Predictive Maintenance Toolbox addon.

Keywords:

Predictive analysis, predictive maintenance, vibrodiagnostics

Obsah

1	Úvod.....	1
1.1	Definice prediktivní analýzy	2
1.2	Důležitost prediktivní analýzy a oblasti využití	3
2	Terminologie.....	4
3	Analýza časových řad.....	6
3.1	Kvalitativní metody	6
3.2	Kvantitativní metody	6
3.3	Očištění časových řad	7
3.4	Charakteristiky časových řad	8
3.5	Dekompozice časových řad	9
3.6	Popis trendu časové řady.....	10
3.6.1	Regresní analýza	11
3.6.2	Metoda klouzavých průměrů	12
3.6.3	Metoda exponenciálního vyrovnání.....	12
4	Klasifikační a regresní stromy.....	14
5	Umělé neuronové sítě.....	16
6	Kalmanův filtr	18
7	Vyhodnocení výkonu predikčního modelu	20
8	Poruchy strojů	22
8.1	Opotřebení.....	22
8.2	Koroze.....	24
8.3	Otlačení.....	25
8.4	Deformace	25
8.5	Trhliny a lomy.....	25
8.6	Ostatní poškození.....	25

9	Strategie údržby.....	26
9.1	Údržba po poruše (Corrective Maintenance).....	26
9.2	Preventivní údržba (Preventive Maintenance)	26
9.3	Proaktivní údržba.....	26
9.4	Diagnostická údržba (Condition Based Maintenance)	27
9.4.1	Monitoring významných parametrů zařízení	27
9.4.2	Druhy diagnostiky	27
9.5	Prediktivní údržba (Predictive Maintenance)	28
10	Metodiky údržby.....	31
10.1	TPM – Komplexní produktivní údržba	31
10.2	RCM – Údržba zaměřená na bezporuchovost	32
11	Představení společnosti Vitesco Technologies	34
12	Strategie a metodiky údržby ve společnosti VT.....	35
12.1	Preventivní údržba.....	35
12.2	Údržba po poruše.....	36
12.3	TPM karty.....	36
12.4	Diagnostická údržba	36
12.4.1	Tribodiagnostika	36
12.4.2	Snímání teploty a vibrací.....	37
13	Odsávač výparů ze svařování Nederman	38
13.1	Umístění senzorů	38
13.2	Sledované charakteristiky signálu	39
13.3	Parametry časového průběhu signálu	40
13.4	Software ifm moneo a nastavení prahových hodnot	41
14	Analýza vibračních charakteristik při poruše	43
15	Možnosti zavedení prediktivní údržby	45
16	Volba indikátorů stavu zařízení	47

17	Prediktivní údržba v prostředí MATLAB.....	52
18	Závěr	55
19	Použitá literatura.....	56
20	Seznam obrázků	61
21	Seznam tabulek.....	62

1 Úvod

Prediktivní analýza, dále jen PA, je disciplína, která se zabývá předpovídáním nadcházejících událostí na základě dostupných dat z minulých období. Nejsme sice schopni do budoucnosti nahlédnout, ani ji přesně předpovědět, ale jsme schopni ji s určitou přesností odhadnout. Přesnost takové predikce závisí na kvalitě a množství relevantních dat.

PA se stává čím dál tím významnějším oborem v řadě odvětví. Na začátku každé predikce jsou data. Při každé platbě kartou, návštěvě lékaře, vyhledávání na Googlu a tak dále se o nás zaznamenávají a ukládají data. Firmy ukládají a využívají velké množství různorodých dat o zaměstnancích, dodavatelích, zákaznících, výrobních procesech, poruchách strojů a mnoho dalších. Ten, kdo ovládá PA, je pak schopen z určité části dat odhadnout budoucí události, chování a výsledky. Klíčem k vytvoření predikce je hledání vzorů v datech, strojové učení, matematické vzorce, výpočetní algoritmy.

Předpovídání je součástí našich životů, aniž bychom si to uvědomovali. Každý z nás, se pravděpodobně setkal s cílenou reklamou v prostředí internetu. Po vyhledávání nejlepšího kempu pro svou letní dovolenou, nám cílené reklamy nabízí koupi stanů, karimatek a dalšího vybavení, protože je zde předpoklad, že některé vybavení pro kempování budeme potřebovat dokoupit. Firmy využívají predikční analýzy pro zvýšení svých zisků a získání nových zákazníků. Manažeři se mohou připravit na nadcházející navýšení objednávek, řídit efektivněji skladové zásoby a mnoho dalšího.

Historie predikční analýzy sahá až k období druhé světové války. Vědec Norbert Wiener vymyslel statistický model pro předpovídání trajektorie letadla, aby pomohl střelci bombardér zasáhnout ^[1] Motivy k využívání predikční analýzy mohou být tedy různé. V každém případě ale můžeme s jistotou prohlásit, že se jedná o velice mocný nástroj, který se od dob druhé světové války značně vyvinul a jeho možnosti se rozšířili.

V této práci budeme považovat slova predikční a prediktivní za synonyma.

1.1 Definice prediktivní analýzy

Prediktivní analytika, jejíž důležitou částí jsou i vybrané metody data miningu (dolování dat), má v literatuře různě formulované definice, které se ve své podstatě příliš neliší. Vybrala jsem několik definic od různých autorů.

Eric Siegel, zakladatel společnosti Predictive Analytics World, napsal knihu, přístupnou pro širokou „neanalytickou“ veřejnost s titulem Kdo klikne koupí, lže nebo zemře: Síla předpovědí pomocí prediktivní analytiky. V knize definuje PA následovně:

„Prediktivní analytika je technologie, která na základě minulých zkušeností (dat) učí predikovat budoucí chování jednotlivců a napomáhat tak kvalitnějšímu rozhodování.“ [2, s 123]

Daniel T. Larose ve své knize Data Mining and Predictive Analytics uvádí definici: *„Prediktivní analýza je proces získávání informací z velkých datových sad za účelem vytváření předpovědí a odhadů budoucích výsledků“*¹, [3, s 4]

Dinov Ivo v knize Data science and predictive analytics: Biomedical and health applications using R definuje PA:

*„Prediktivní analýza je proces využívající pokročilé matematické vzorce, výkonné statistické výpočetní algoritmy, efektivní softwarové nástroje a služby k reprezentaci, dotazování a interpretaci komplexních dat s cílem předvídat trendy, vzory v datech nebo předpovídat chování“*², [4, s 9-10]

Predikce, vytváření předpovědí, předvídání – synonyma, které mají všechny definice společné. Abychom mohli předpovídat co nejpřesněji, využijeme prediktivního modelování – procesu odhalování vztahů v datech k vytvoření prediktivního

1 Pozn. překl.: „Predictive analytics is the process of extracting information from large data sets in order to make predictions and estimates about future outcomes“

2 Pozn. překl.: „Predictive analytics is the process of utilizing advanced mathematical formulations, powerful statistical computing algorithms, efficient software tools and services to represent, interrogate, and interpret complex data. As it's name suggest, a core aim of predictive analytics is to forecast trends, predict patterns in the data, or prognosticate the process behavior“

modelu – modelu předpovědi, který zahrnuje vzory v datech a statistický vztah mezi předchozí a aktuální hodnotou proměnné. [5], [6]

1.2 Důležitost prediktivní analýzy a oblasti využití

Jak už bylo nastíněno v úvodu, prediktivní analýza zasahuje určitým způsobem do každodenního života nás všech. Sílu PA využívají firmy, obchodníci s akciemi, lékaři, banky, pojišťovny, politici, mobilní operátoři, obchodní řetězce apod.

Prediktivní analýzy ve firmách mohou manažerům usnadňovat rozhodování a pomáhat při plánování, zacílit marketing, předpovědět kteří zaměstnanci mají tendenci podat výpověď. Na základě prediktivní analýzy přizpůsobují kapacitu výroby, řízení zásob, plánování rozpočtů. Další oblast, kde je prediktivní analýza významným nástrojem, jsou finanční investice. Investoři chtějí znát pravděpodobnost návratu svých investic. Užitečné jsou také předpovědi hlavních ekonomických proměnných např. hrubý domácí produkt, nezaměstnanost, inflace. Vláda využívá demografické předpovědi jako je míra úmrtnosti, porodnosti a migrace, aby přizpůsobila svou politiku a zajistila sociální služby. [6]

2 Terminologie

Než začneme rozebírat jednotlivé metody prediktivních analýz, uvedu několik termínů, které je nutné definovat.

Data

Data dělíme na kvalitativní – konkrétní hodnoty bez měřítka – např. barva (zelená, modrá...) a kvantitativní – mají přirozené číselné stupnice a vyjadřují množství. (teplota, cena, váha...) [7]

Data vstupující do prediktivních rovnic a modelů nazýváme prediktory neboli nezávisle proměnné. Data, která z těchto rovnic a modelů vystupují nazýváme výsledkem nebo závisle proměnnou. [5]

Bílý šum

Bílým šumem se nazývá náhodná složka datového souboru, signálu, s nulovou střední hodnotou. Jde o chyby v měřeních, okolní rušení apod. [8]

Prediktivní model

Prediktivní model – model předpovědi, který zahrnuje vzory v datech a statistický vztah mezi předchozí a aktuální hodnotou proměnné. Je výsledkem prediktivního modelování – procesu odhalování vztahů v datech. [6],[5]

Časový horizont

Predikce se dělí dle časového rámce – jak daleko do budoucnosti chceme předpovídat. Z tohoto hlediska se predikce dělí na krátkodobé, střednědobé a dlouhodobé. Krátkodobé představují odhad v rámci několika časových období do budoucnosti (dny, týdny, měsíce). Střednědobé se týkají období 1-2 let a dlouhodobé mohou přesahovat rámec mnoha let. [6]

Strojové učení

„Strojové učení je nauka o algoritmech, které umožňují učení umělých objektů. Učením se je rozuměno automatické zlepšování se na základě zkušeností.“ [7, s8] Proces učení dělíme na proces učení s učitelem (supervised learning) a učení bez učitele (unsupervised

learning). Učení s učitelem spočívá v rozdělení sady dat, ze které se má stroj učit, na dvě části – trénovací (učící data), a testovací data. [2] Trénovací data slouží k vývoji a učení modelů, po vyhodnocení se pak porovná výsledek s částí testovací. Podle toho, do jaké míry se výsledek predikce liší od reálných dat, stroj (algoritmus) neustále upravuje parametry v modelu tak, aby se výsledek od reálných (testovacích) dat lišil co nejméně. V procesu učení bez učitele není datová sada rozdělena na trénovací a testovací sadu, ale stroj má celý objem dat k dispozici pro učení se. „V takovém případě jsou v datech hledány dosud neznámé souvislosti, jsou hledány tzv shluky (clusters), tedy oblasti tvořené daty, která jsou si vzájemně podobná.“ [7, s 12]

3 Analýza časových řad

„Časová řada je časově orientovaná nebo chronologická posloupnost pozorování sledované proměnné“³, [6, s 2]

Pro předpovídání na základě časových řad můžeme využít metody rozdělené do dvou hlavních skupin:

- Kvalitativní metody
- Kvantitativní metody

3.1 Kvalitativní metody

Kvalitativní metody se využívají zejména tam, kde je k dispozici nedostatek dat z minulých období, proto hlavní roli v této metodě hraje subjektivní úsudek odborníků. Mezi kvalitativní postupy patří například tzv. DELPHI metoda. [6] DELPHI metodu vynalezli Olaf Helmer a Norman Dalkey ze společnosti RAND v 50. letech minulého století. Základy principu této metody jsou postaveny na sestavení skupiny expertů v daném oboru, kteří individuálně na základě poskytnutých dat určí své prognózy. Důležité je, že analýzy provádějí odděleně (jeden tak neovlivňuje druhého) a členové skupiny zůstávají v anonymitě (nejsou ovlivňováni politicky, sociálně ani jiným způsobem). Výsledné, konečné předpovědi jsou sestaveny agregací jednotlivých předpovědí odborníků. [9]

3.2 Kvantitativní metody

Kvantitativní metody využívají historická data a model předpovědi. Model předpovědi zahrnuje vzory v datech a statistický vztah mezi předchozí a aktuální hodnotou proměnné. [6]

Protože je téměř nemožné předpovědět pomocí metod predikční analýzy přesná čísla, je dalším důležitým pojmem takzvaná chyba prognózy – odhad s jakou odchylkou bychom měli v předpovědi počítat.

³ Pozn. překl.: „A time series is a time-oriented or chronological sequence of observations on a variable of interest.“

Další důležité termíny jsou horizont prognózy – doba předpovědi a interval prognózy – frekvence s jakou jsou počítány nové prognózy. S intervalem a horizontem prognózy souvisí i pojem klouzavého, nebo pohyblivého horizontu – to znamená, že v každém období intervalu prognózy (např. 1 měsíc) přepočítáváme data předpovědi na určité pevně dané období (horizont prognózy) – označme toto období T. Interval prognózy je zároveň stejný jako základní časové období, pro které je každá prognóza vytvořena, můžeme mluvit o pohyblivém horizontu. Tento systém je hojně využíván a reviduje předpovědi pro T-1 období, jak je znázorněno v následující tabulce (Obr 01). [6]

Horizont předpovědi T=3; Interval předpovědi = 1

Předpověď

Aktuální období

Revidované období

	Období						
	1	2	3	4	5	6	7
předpověď 1							
předpověď 2							
předpověď 3							
předpověď 4							
předpověď 5							

Obr 01 – Ukázka předpovědi s pohyblivým (klouzavým horizontem) [10]

Dále časové řady dělíme na intervalové – vyznačují se tím, že data za jednotlivá období lze sčítat a vytvořit kumulativní součty za více období (vznik, či zánik události nebo jevu, k určitému časovému intervalu). Například počet svateb, roční tržba atd.

Druhým typem jsou okamžikové časové řady (stav k určitému intervalu – okamžiku). Například počet obyvatel, nebo počet zaměstnanců k určitému datu. Při práci s intervalovými časovými řadami se musíme také ujistit, že časové intervaly jsou stejné délky a popřípadě data upravit. Pokud by časové intervaly byly různé, zkreslily by celkový vývoj časové řady. [11]

3.3 Očištění časových řad

Na přesnost a věrohodnost analýzy má vliv kvalita dat. Abychom dostali co nejlepší výsledek, neměli bychom zapomenout na očištění dat. Očištěním dat se myslí odstranění, jak kvalitativních odchylek, jako jsou neplatné nebo zdvojené a chybějící hodnoty, tak i očištění od kalendářních vlivů (každý měsíc jiný počet dnů, svátky...).

Pro tyto účely se zavádí například standardní měsíc o délce 30 dnů nebo se využívají kvartální data. [8],[12]

3.4 Charakteristiky časových řad

Průměr intervalové řady

Nyní si představíme několik základních charakteristik časových řad. [11]

Základní charakteristikou časové řady je průměr intervalové řady – \bar{y} , který spočítáme jako aritmetický průměr hodnot časové řady v jednotlivých intervalech, kde y_i jsou hodnoty časové řady v jednotlivých –intervalech / okamžicích t_1, t_2, \dots, t_n :

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

Nevážený chronologický průměr

Pokud se nejedná o časovou řadu s intervalovým ukazatelem, ale okamžikovým, pak se nazývá průměr řady neváženým chronologickým průměrem – \bar{y} a počítáme ho jako:

$$\bar{y} = \frac{1}{n-1} \left[\frac{y_1}{2} + \sum_{i=2}^{n-1} y_i + \frac{y_n}{2} \right]$$

Tyto vzorce platí pro situaci, kdy jsou vzdálenosti mezi časovými okamžiky nebo intervaly stejné. Pokud by nebyly, výpočty by byly složitější.

První diference

Někdy také nazývané absolutní přírůstky – označené ${}_1d_i(y)$, které vypočítáme jako rozdíl dvou po sobě jdoucích hodnot časové řady:

$${}_1d_i(y) = y_i - y_{i-1}, \quad i = 2, 3, \dots, n$$

První diference vyjadřuje rozdíl mezi určitým obdobím a obdobím tomuto období předcházejícím. „Zjistíme-li že první diference kolísají kolem konstanty, lze říci, že sledovaná časová řada má lineární trend, tedy její vývoj lze popsat přímkou.“ [11, s 119]

Průměrem prvních diferencí lze určit průměrnou změnu za jednotkový časový interval:

$$\overline{{}_1d_i(y)} = \frac{1}{n-1} \sum_{i=2}^n {}_1d_i(y) = \frac{y_n - y_1}{n-1}$$

Rychlost růstu časových řad

Rychlost růstu časových řad – $k_i(y)$ vyjádřená poměrem dvou po sobě jdoucích hodnot:

$$k_i(y) = \frac{y_i}{y_{i-1}}, \quad i = 2, 3, \dots, n$$

Průměrný koeficient růstu

Průměrný koeficient růstu definuje průměrnou změnu koeficientů růstu za časovou jednotku:

$$\overline{k_i(y)} = \sqrt[n-1]{\frac{y_n}{y_1}}$$

3.5 Dekompozice časových řad

Pokud časová řada není monotónní, ale vykazuje části, kde klesá a roste, je třeba rozložit řadu na jednotlivé složky, abychom zjistili zákonitosti chování řady. Tento proces nazýváme dekompozicí časových řad.

Jednotlivé složky, které zkoumáme u časových řad, jsou: ^[11]

- Trendová složka – T_i
- Sezónní složka – S_i
- Cyklická složka – C_i
- Náhodná složka – e_i

Hodnoty y_i v čase t lze vyjádřit jako součet jednotlivých složek:

$$y_i = T_i + S_i + C_i + e_i$$

Trend časové řady

První důležitou složkou je trend časové řady. „Trend vyjadřuje obecnou tendenci dlouhodobého vývoje sledovaného ukazatele v čase. Je důsledkem působení sil, která systematicky působí ve stejném směru.“ [11, s 122] Jedná se například o změny ve výši příjmů obyvatelstva. Trend může obecně klesat nebo stoupat, pokud se pohybuje přibližně na stejné úrovni říkáme, že časová řada trend nemá. [11]

Sezónní složka

Sezónní složka označuje stav, kdy se určitý vzor chování časové řady během roku opakuje každý rok. Příkladem můžou být vyšší tržby obchodníků v období Vánoc. „Pro zkoumání této složky jsou vhodná především měsíční nebo čtvrtletní měření“ [11, s 123]

Cyklická složka

Pokud se střídá fáze růstu a poklesu v cyklech pak hovoříme o cyklické složce časové řady. „Délka jednotlivých cyklů časové řady, která je rovna vzdálenostem mezi dvěma sousedními horními, resp. dolními body zvratu, a také intenzita jednotlivých fází cyklického průběhu se mohou měnit. Cyklická složka může být důsledkem evidentních vnějších vlivů, někdy je ale určení jejich příčin velmi obtížné.“ [11, s 123]

Náhodná složka

Někdy také označována jako reziduální, reprezentuje náhodné hodnoty a chyby v měřeních. „Je tvořena náhodnými fluktuacemi v průběhu časové řady, které nemají rozpoznatelný systematický charakter.“ [11, s 123]

3.6 Popis trendu časové řady

Pomocí různých metod můžeme popsat trend časové řady a tím také prognózu jejího dalšího vývoje. Cílem je nalézt takovou křivku, která by co nejpřesněji přiléhala ke skutečným hodnotám časové řady. Vyhodnocení přesnosti predikce určíme pomocí některé chybové funkce (viz kapitola 7 Vyhodnocení výkonu predikčního modelu).

V případech, kdy lze vyrovnat celou časovou řadu jednou trendovou funkcí, lze využít regresní analýzu. V ostatních případech lze uplatnit některý z adaptivních postupů,

jako je například metoda klouzavých průměrů, nebo metoda exponenciálního vyrovnání. [13]

3.6.1 Regresní analýza

V případech, kdy trend odpovídá určité matematické funkci, se používá regresní analýza.

Metoda regresní analýzy slouží k odhadu (predikci) hodnoty výstupní proměnné ve vztahu ke vstupní proměnné. Princip je založen na co nejbližší aproximaci vztahu mezi těmito dvěma proměnnými. [11]

Jinými slovy regresní analýza zkoumá vztah mezi nezávisle proměnnou – x (vstupem) a závisle proměnnou – y (výstupem). Tento funkční vztah vyjádříme jako $y = \varphi(x)$, kde funkce $\varphi(x)$ nám není známá, nebo je složité ji vyjádřit, známe ale výsledek y při nastavení určité vstupní proměnné x . (Například vztah mezi počtem členů domácnosti a výdaji této domácnosti). Na vztah mezi vstupem x a výstupem y působí neznámé vlivy, které jsou náhodné a nepředvídatelné. Tyto vlivy označujeme obecně za „šum“ – náhodnou veličinu e , kvůli které se výstup y chová taktéž jako náhodná veličina – označme ji Y . Předpokládaná hodnota střední hodnoty náhodné veličiny e je nula (znamená to, že odchylky se pohybují rovnoměrně do záporných i kladných hodnot): [11]

$$E(e) = 0$$

„Abychom závislost náhodné veličiny Y na proměnné x vyjádřili, zavedeme podmíněnou střední hodnotu náhodné veličiny Y pro hodnotu x , označenou $E(Y|x)$, a položíme ji rovnu vhodně zvolené funkci, kterou označíme $\eta(x; \beta_1, \beta_2, \dots, \beta_p)$, pro niž použijeme stručné označení $\eta(x)$ lze zapsat takto:“ [11, s 79]

$$E(Y|x) = \eta(x; \beta_1, \beta_2, \dots, \beta_p)$$

Úkol regresní analýzy spočívá v odhadnutí parametrů (regresních koeficientů) $\beta_1, \beta_2, \dots, \beta_p$, ($p \geq 1$) pro regresní funkci $\eta(x; \beta_1, \beta_2, \dots, \beta_p)$, v závislosti na zadaných datech (x_i, y_i) , ($i = 1, 2, \dots, n$), tak, aby co nejlépe aproximovala vztah mezi vstupní a výstupní proměnnou. [11]

3.6.2 Metoda klouzavých průměrů

Pokud je trend nerovnoměrný a nelze ho popsat matematickou funkcí, lze použít metodu klouzavých průměrů. [11]

Metoda klouzavých průměrů se řadí mezi takzvané adaptivní metody a principem je rozdělení časové řady na menší části, které aproximujeme polynomem nízkého stupně. [8]

Při této metodě vybereme délku klouzavých průměrů a postupujeme po časové ose vždy o jednu hodnotu dopředu – „kloužeme po časové ose“. [14]

Rozlišujeme dva druhy klouzavých průměrů – jednoduché a vážené.

- Jednoduché klouzavé průměry – jednotlivé úseky nahrazujeme aritmetickým průměrem vypočteným z jejich členů.
- Vážené klouzavé průměry – podobné jako jednoduché klouzavé průměry, místo obyčejného aritmetického průměru používáme průměr vážený. K odvození vah můžeme odvodit metodou nejmenších čtverců. [13]

Nevýhodou této metody je, že prvních a posledních m hodnot zůstává nevyhlazeno. Obzvláště vyhlazení koncových hodnot je důležité, pokud chceme predikovat. Pro vyhlazení těchto počátečních a koncových hodnot existují specifické techniky. [15]

3.6.3 Metoda exponenciálního vyrovnání

Při vyhlazování časové řady touto metodou hraje největší roli hodnota vyhlazovaného bodu, následně pak všechny dostupné předchozí hodnoty. Čím dále je hodnota od vyrovnávaného bodu, tím má menší váhu a vliv. *„Pro odhad parametrů se používá vážená metoda nejmenších čtverců, kdy váhy exponenciálně klesají směrem do minulosti.“* [13]

$$(Y_t - \hat{Y}_t)^2 + (Y_{t-1} - \hat{Y}_{t-1})^2 \alpha + (Y_{t-2} - \hat{Y}_{t-2})^2 \alpha^2 + \dots$$

α – vyrovnávací konstanta, $0 < \alpha < 1$

Konstantou α ovlivňujeme, jak rychle bude vliv minulých pozorování klesat – čím vyšší hodnota, tím pomaleji bude klesat vliv předchozích pozorování a naopak.


Rozlišujeme tři druhy exponenciální vyrovnání: ^[13]

- Jednoduché
Předpokládáme, že trend je v krátkých časových úsecích konstantní.
- Dvojité
Předpokládáme, že trend lze vyrovnat v krátkých časových úsecích přímkou.
- Trojité
Předpokládáme, že trend lze v krátkých časových úsecích vyrovnat parabolou.

4 Klasifikační a regresní stromy

Princip klasifikačního stromu spočívá v rozdělení (přefiltrování) dat do několika kategorií. „Cílem klasifikačního stromu je sekvencně rozdělit data tak, aby se maximalizovaly rozdíly v závislé proměnné.“ [16, s 14]

Klasifikační stromy jsou speciálním druhem grafů – stromů. Uzel horní vrstvy se nazývá kořenový uzel. Uzly ve spodní vrstvě se nazývají listy (terminální uzly). Kořen reprezentující celý soubor se nachází nahoře a postupně se větví směrem dolů až k listům. Dále rozlišujeme klasifikační stromy dle toho, zda se dělí na dvě větve (binární), nebo na více větví (nebinární). [17] Hloubku stromu je určena počtem hran od kořene k listům. [7]



Obr 02 – Struktura rozhodovacího stromu [7]

Pro vytvoření rozhodovacího stromu můžeme použít jednu ze dvou skupin metod – klasifikační nebo regresní. Jakou metodu použít se rozhodujeme na základě druhu proměnné. Klasifikační stromy používáme pro kvalitativní závisle proměnné, regresní stromy používáme v případě kvantitativní závisle proměnné. [17]

Pro stanovení parametrů (tzv. kalibraci) jednotlivých uzlů se používá metoda strojového učení. „Parametry se nastavují podle srovnání výsledku modelu se známými hodnotami, což je označováno jako validace modelu. Proces validace modelu se opakuje a parametry uzlů se stále zpřesňují. Pokud již model nejsme schopni více zlepšit, proces učení končí“ [17, s 3]

Jedním z klíčových rozhodnutí je, kdy ukončit proces dělení stromu. Další dělení uzlů ukončíme, pokud dosáhneme stanoveného omezení (například minimální počet prvků v uzlu), nebo pokud dalším dělením již model nelze zpřesnit. Problém, který může nastat, je takzvané přeučení stromu. Jedná se o jev, kdy je strom příliš přerostlý anebo

byl ovlivněn takzvaným šumem (závislostmi, které nesouvisí s analyzovanou problematikou). Řešením tohoto problému je technika, která se nazývá prořezávání stromu. Využije se testovacích dat k odhalení, kde je strom již příliš přerostlý a takové větve se prořezou. Prakticky to vypadá tak, že učení vrátíme o určitý počet kroků zpět. [2], [18]

Jednou z metod je klasifikace a analýza regresního stromu – CART (Classification and regression trees). CART navrhli Leo Breiman, Jerome Friedman, Richard Olshen, a Charles Stone v roce 1984. [2] Tato metoda si poradí jak s kvalitativními, tak kvantitativními proměnnými. Metoda umí sama identifikovat nejvýznamnější proměnné a eliminovat nevýznamné. Na rozdíl od jiných prediktivních algoritmů jako je třeba lineární regrese, se dobře umí vypořádat s odlehlými hodnotami, které izoluje v samostatném uzlu. [19], [7] Metoda funguje na následujícím principu:

„V podstatě se snažíme o takové rozdělení závisle proměnné Y prediktorem X , aby hodnoty proměnné Y byly uvnitř uzlu co nejhomogennější a zároveň mezi uzly co nejrozdílnější. Na začátku tvorby stromu patří všechna pozorování souboru do jednoho uzlu neboli kořene. Následně jsou tato pozorování rozdělena do dvou dceřiných uzlů, na základě hodnoty a prediktoru X , které jsou dále děleny opět binárně na další uzly.“ [17, s 9-10]


Metody klasifikačních a regresních stromů neprodukují oproti ostatním metodám ty nejpřesnější prediktivní modely, vynikají za to svou jednoduchostí a přehledností. [2] Další výhodou rozhodovacích stromů je skutečnost, že umí efektivně zpracovat mnoho typů prediktorů a jsou schopny se dobře vypořádat s chybějícími daty. [17]

5 Umělé neuronové sítě

Umělé neuronové sítě, dále jen UNS, jsou matematickými modely biologických neuronových sítí. Za první průkopníky nové vědní disciplíny – UNS jsou považováni Warren S. McCulloch a Walter Pitts (1943). Základní stavební jednotkou UNS je neuron, reprezentovaný matematickým modelem, který má několik vstupů a jeden výstup. [20]

„Neuron si můžeme představit jako matematický procesor, kde vstupem je n -rozměrný vektor parametrů, resp. vstupního signálu, výstupem je skalár, resp. m -rozměrný vektor výstupního signálu.“ [20, s 12]

Pokud spolu navážeme více neuronů, tak že výstup jednoho neuronu bude vstupem stejného nebo jiného neuronu, hovoříme o neuronové síti. Neurony v síti rozlišujeme do třech skupin – vstupní, skryté a výstupní. To, jakým způsobem jsou mezi sebou neurony propojeny, určuje topologie sítě. Pokud topologie sítě obsahuje uzavřenou smyčku (neurony zapojené do kruhu) nazýváme topologii cyklickou (rekurentní), v opačném případě se jedná o acyklickou (dopřednou) topologii. [21]



Obr 03 – Acyklická topologie neuronové sítě [22]

Každý vstup má odlišný vliv, který je určený jeho vahou. Váhy se mění v průběhu činnosti sítě. Nastavení vah provádíme buď učením UNS, nebo ve výjimečných případech přímým výpočtem. Pro učení UNS lze využít metodu jak strojového učení s učitelem, tak i bez učitele. Základy učení NS jsou založené na takzvaném Hebbově zákoně učení. Toto pravidlo definoval Donald Hebb v roce 1949 při studiu podmíněných reflexů. Hebbův zákon je založen na předpokladu posilování nejčastěji

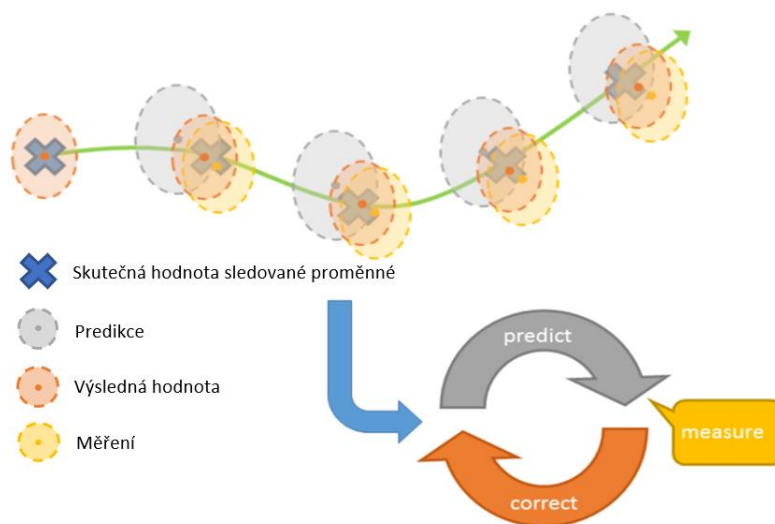
používaných vazeb mezi jednotlivými neurony. Naopak u vazeb, které nejsou tak často využívány se naopak váhy oslabují. [22], [21]

Výhodou neuronových sítí je skutečnost, že pomocí nich lze řešit i velice složité úlohy, v podstatě stačí jen dostatečné množství příkladů. Bohužel ale výsledek nelze použít k vysvětlení řešení úlohy, protože je ukryt ve struktuře sítě a nelze jej interpretovat. Vhodné je neuronové sítě využívat u složitých případů, které obsahují velké množství složitě propojených vazeb a u kterých hraje roli náhoda (například oblast investičního modelování). [23],[24]

6 Kalmanův filtr

Kalmanův filtr, dále jen KF, je rekurzivní algoritmus (existující v řadě modifikací), který se využívá pro oddělení náhodné složky (bílého šumu) od užitečného (skutečného) signálu. Autorem této techniky je R. E. Kalman, který ji představil v 60. letech. Dnes se využívá zejména v oblasti navigace a zpracování signálu. [25], [26]

KF se využívá v řadě aplikačních oblastí včetně oblasti prediktivní údržby. KF má své využití všude tam, kde nelze změřit sledovanou proměnnou přímo a měření je zatíženo bílým šumem, vnějšími vlivy a další činností systému. Své využití má například v oblasti vibrodiagnostiky, kde je jeden z hlavních problémů zašumění signálu okolními vlivy. KF pracuje na principu, při kterém se střídají dvě fáze – predikční (predict) a aktualizací (correct).



Obr 04 – Vizualizace cyklu Kalmanova filtru, volně převzato z [27]

KF odhaduje budoucí hodnoty procesu pomocí tzv. zpětnovazebního řízení. Nejprve predikuje výstup systému pro následující časový okamžik s ohledem na všechny dostupné informace. V dalším kroku využije zpětné vazby v podobě měření a upraví hodnotu predikce (pouze v případě že se hodnota predikce nerovná hodnotě měření) a zároveň aktualizuje parametry predikčních rovnic. Algoritmus se skládá ze dvou typů rovnic – časových (predikčních; angl. time update equations), které zajišťují promítání aktuálního stavu do budoucích hodnot a aktualizací (filtračních; angl. measurement update equations), které upravují predikci a zajišťují změnu parametrů časových

rovnice v závislosti na hodnotě měření a kovariační odchylky (chyby predikce). [25], [28], [27], [29]

Dalším důležitým parametrem je Kalmanův zisk, kterým nastavujeme míru důvěryhodnosti měření vůči predikci, kterou vytváří model. [27]

Kalmanův filtr je určen pro lineární systémy, pokud systém není lineární, musíme využít Rozšířeného Kalmanova filtru, který nejprve linearizuje systém a následně pokračuje aplikací klasického KF.

7 Vyhodnocení výkonu predikčního modelu

Další důležitou částí je vyhodnocení výkonu predikčního modelu. Hodnocení modelu je založeno na chybě předpovědi e_t v čase t , spočítané jako: [6]

$$e_t = y_t - \hat{y}_t(t-1)$$

chyba = reálná hodnota – předpověď

Kde $\hat{y}_t(t-1)$ je předpověď hodnoty y_t vytvořené predikčním modelem o období dříve. Porovnávají se tedy předpovězené hodnoty s reálnými daty a rozdíl mezi těmito hodnotami je chyba predikce.

K celkovému hodnocení modelu se využívají míry kvality předpovědi. [6], [8]

Střední chyba (mean error) ME

Za předpokladu že máme n období, pak spočítáme střední chybu předpovědi ME:

$$ME = \frac{1}{n} \sum_{t=1}^n y_t - \hat{y}_t(t-1)$$

Střední absolutní odchylka (mean absolute deviation) MAD

Další mírou přesnosti je střední absolutní odchylka MAD, která se od střední chyby liší tím, že kvůli absolutní hodnotě není její výsledek ovlivněn zápornými odchylkami:

$$MAD = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t(t-1)|$$

Střední kvadratická odchylka (mean squared error) MSE

Stejně tak není ovlivněna zápornými hodnotami střední kvadratická odchylka MSE spočítaná jako součet kvadrátů chyby předpovědi:

$$MSE = \frac{1}{n} \sum_{t=1}^n [y_t - \hat{y}_t(t-1)]^2$$

Průměrná absolutní procentuální chyba (Mean Absolute Percentual Error) MAPE

ME, MAD i MSE jsou vyjádřené ve stejných jednotkách jako jsou hodnoty měření – nejsou tedy normovány a nelze je použít k porovnání výkonu mezi modely zabývající se proměnnými v odlišných jednotkách. Pro tento účel je užitečné vyjádření relativní chyby prognózy v procentech:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{|e_t|}{y_t}$$

8 Poruchy strojů

Poruchy strojů jsou způsobovány mechanismem poruchy – kombinací vlivů a procesů uvnitř stroje. Tyto kombinace vlivů mohou být různého charakteru. Může jít například o mechanické, chemické, tepelné aj. působení na součástky stroje a jejich následné poškození, které se projeví ztrátou funkčnosti stroje. [30] Dalším významným aspektem je lidský činitel. Pochybení obsluhy, nedodržování provozních podmínek, nedostatečné znalosti a mnoho dalších má významný vliv na vznik poruch. [31]

Mechanismy poškození způsobují různé druhy degradace strojních součástí. Klasifikujeme do je několika skupin: [30]

1. Opotřebení
2. Koroze
3. Otláčení
4. Deformace
5. Trhliny a lomy
6. Ostatní poškození

8.1 Opotřebení

„Opotřebení je fyzikální jev, který vede k úbytku, deformaci nebo změně materiálu.“ [30, s 427]

Opotřebení se dále dělí na šest základních druhů: adhezivní, vibrační, abrazivní, erozivní, únavové, kavitační.

Adhezivní opotřebení

Vzniká v místech, kde se dotýkají dvě tělesa, která se o sebe navzájem smýkají a třou, přičemž se uvolňují a přemísťují částice materiálu. Dochází k porušování povrchu a vzniku adhezních mikrospojů.

Vibrační opotřebení

Je způsobováno vibracemi různého původu. V důsledku vibrací se oddělují částice materiálu a poškozují se i velmi tvrdé materiály. V místě poškození částice oxidují a

objevuje se hnědočervené až hnědočerné zbarvení, které se označuje jako „krvácení materiálu“.

Abrazivní opotřebení

Vzniká vzájemným působením tvrdých drsných povrchů a dochází tím k oddělování částic a vnikají v materiálech rýhy a zářezy. Příkladem jsou rýhy na lžících bagrů.

Erozivní opotřebení


U erozivního poškození, stejně jako u abrazivního, vznikají v materiálech rýhy a zářezy. U erozivního jsou zářezy způsobeny dopadáváním částic, které jsou nesené proudem kapaliny, kapek, páry nebo plynu, na povrch součástky a vzniká typické zvrásněné, nerovnoměrné poškození.

Únavové poškození

Vzniká cyklickým působením sil. Nejprve je poškozena tenká vrchní vrstva materiálu, poškození se pak dále rozvíjí. Nejčastějším projevem únavového poškození je takzvaný pitting (tvoření důlků), dochází také ale může k odlupování materiálu (spalling). Tento druh poškození je typický například pro valivá ložiska. Únavové poškození je ovlivněno tvrdostí použitých materiálů, drsností povrchu, ale i případnými nečistotami.

Kavitační opotřebení

Vzniká v důsledku zanikání kavitačních dutin (bublinek) v kapalině a rázů, které při tom vznikají. Z povrchu součástky se oddělují částice a vzniká poškození. Tento typ opotřebení můžeme nalézt například v pračkách nebo vodních turbínách. [30], [32]



Obr 05 – Druhy opotřeby [32]

8.2 Koroze

„K tomu, aby lidé mohli používat kovy, musí k jejich výrobě a úpravě dodat energii. Vzniká tak energeticky bohatý produkt, kov, který zpravidla není v prostředí stabilní a podléhá samovolně korozi. Energie, vynaložená na jeho výrobu, se při tom uvolňuje do okolního prostředí. Kov přechází během koroze do stabilnějšího stavu s menším obsahem energie a méně uspořádanou strukturou, do korozních produktů, které jsou vzhledem i složením blízké výchozí surovině pro výrobu – rudě.“ [30, s 439-440]

Okolní prostředí ovlivňuje významně rychlost koroze. Nejčastěji jsou to klimatické podmínky jako jsou vlhkost, teplota a znečištění vzduchu. Dalším agresivním prostředím jsou kapaliny – zejména voda. Zde je nejvýznamnějším parametrem tvrdost, hodnota pH, teplota a množství plynů rozpuštěných v kapalině (především kyslíku). Proces koroze kovů není možné úplně potlačit, je ale možné ji značně zpomalit pomocí protikorozních opatření. Už při návrhu zařízení je potřeba zvážit druh materiálu. Vhodné jsou korozivzdorné oceli (slitiny železa s obsahem chromu). Další možnost ochrany kovů je protikorozní úprava povlaky. Úkolem protikorozního povlaku je oddělení materiálu, který není odolný proti korozi od okolního korozního prostředí. Nejčastěji používaný kov používaný k potahování jsou uhlíkové oceli, nebo organické povlaky v podobě nátěrových hmot. Je třeba také zvážit úpravu okolního prostředí – změnu fyzikálních vlastností – jako je například snížení vlhkosti vzduchu, snížení teploty, změkčení a chemická úprava vody apod. [30],[33]

8.3 Otlačení

Otlačení je místní povrchová deformace způsobená vnějšími silami. „Objem materiálu se nemění, materiál neubývá, ale přemísťuje se a vytváří valy okolo místa působení tlaku.“ [30, s 446]

8.4 Deformace

„Deformace je trvalá nežádoucí změna geometrického tvaru součásti“ [30, s 446]

8.5 Trhliny a lomy

„Trhlina je porušení homogenity materiálu v části průřezu, lom je porušení homogenity v celém průřezu součásti.“ [30, s 447] Příčiny vzniku trhlin a lomů může být celá řada od nevhodné konstrukce, přes nevhodně použité materiály, až po stárnutí a únavu materiálu a mnoho dalších faktorů. Rozlišujeme dva typy lomů, které se liší mechanismem vzniku a svým vzhledem – lomy statické, vznikající překročením meze pevnosti materiálu a lomy únavové, vznikající překročením meze únavy materiálu. [30]

8.6 Ostatní poškození

Například stárnutí materiálu, tepelná degradace (zejména u plastových součástí) aj.

9 Strategie údržby

Základním cílem údržby není opravovat vzniklé poruchy, ale především poruchám předcházet. Dále je cílem naplňovat požadavky na zajištění vysoké produktivity a optimalizaci provozu po celou dobu životnosti stroje, popřípadě i prodloužení životnosti stroje a zajištění optimální bezpečnosti provozu. [34]

Každá minuta zastavené výroby znamená pro firmu nemalé finanční ztráty. Proto je v zájmu každého výrobce tyto prostoje v provozu minimalizovat. Snaha zvýšit co nejvíce efektivitu výrobních zařízení zajistila zkoumání a stimulovala vývoj oboru managementu údržby.

Nyní si představíme několik základních strategií údržby.

9.1 Údržba po poruše (Corrective Maintenance)

Tento přístup byl hojně využíván až do období druhé průmyslové revoluce v roce 1870. Jednoduše řečeno, problém se řešil, až když nastal. Pokud se stroj porouchal, bylo prioritou ho pouze uvést znovu do provozuschopného stavu. Tento přístup není příliš efektivní, snižuje životnost výrobních zařízení a způsobuje neplánované prostoje. Přesto se s ním můžeme setkat v některých případech ještě v dnešní době. [35]

9.2 Preventivní údržba (Preventive Maintenance)

Během druhé průmyslové revoluce vznikl přístup preventivní údržby. Tato strategie se snaží neplánovaným poruchám předcházet pravidelnou údržbou a kontrolou výrobních zařízení. Výhodou je, že lze provádět údržby v plánovaných odstávkách výroby a nezvyšovat tak prostoje. [35] Tyto údržby se řídí vypracovaným harmonogramem (plánem údržby) a provádí se bez předchozího zjištění stavu výrobního zařízení. [36]

9.3 Proaktivní údržba

Při vzniklé poruše se klade důraz na zjištění příčin vzniku závady a nastaví se vhodná nápravná opatření. [34]

9.4 Diagnostická údržba (Condition Based Maintenance)

Diagnostická údržba patří do kategorie preventivních údržeb, je však založena na reálných datech (monitoringu významných parametrů výrobního zařízení). Oproti předchozí strategii se liší v tom, že není prováděna údržba, dokud to není nezbytně nutné a opotřebení, nebo jiné sledované parametry výrobního zařízení nedosáhly hodnot, kdy je třeba údržbu provést. [36]

9.4.1 Monitoring významných parametrů zařízení

Monitoring parametrů zařízení se dělí do několika fází: [34]

1. Zjištění referenčních hodnot – jako první činnost by měla být provedena diagnostika zařízení v okamžiku, kdy je plně funkční a správně seřízené za pomoci důkladného měření a zjištění referenčních hodnot.
2. Stanovení významných parametrů a jejich monitoring – měření a sbírání dat z kritických částí zařízení.
3. Nastavení poplachových mezí – data z bodu č. 2. se analyzují a stanoví se hodnoty poplachových mezí (limity hodnot za běžného provozu).
4. Podrobná analýza a měření při vzniku problému, zjištění příčiny poruchy a následné návrhy a nastavení nápravných opatření.

9.4.2 Druhy diagnostiky

Postupy diagnostiky rozlišujeme dle druhu sledovaných parametrů: [34]

- Provozní diagnostika – sleduje všechny dostupné měřené parametry
- Tribodiagnostika – analýza maziva
- Termodiagnostika – měření teplot přímo na určených místech, nebo za pomoci termovize
- Ultrazvuková diagnostika
- Elektrodiagnostika – analýza elektrických veličin
- Vibrodiagnostika

V následující tabulce (Tab 01) si můžeme všimnout, že každá změna hodnot sledovaných parametrů, může ukazovat na různé typy závad zařízení (v tomto případě

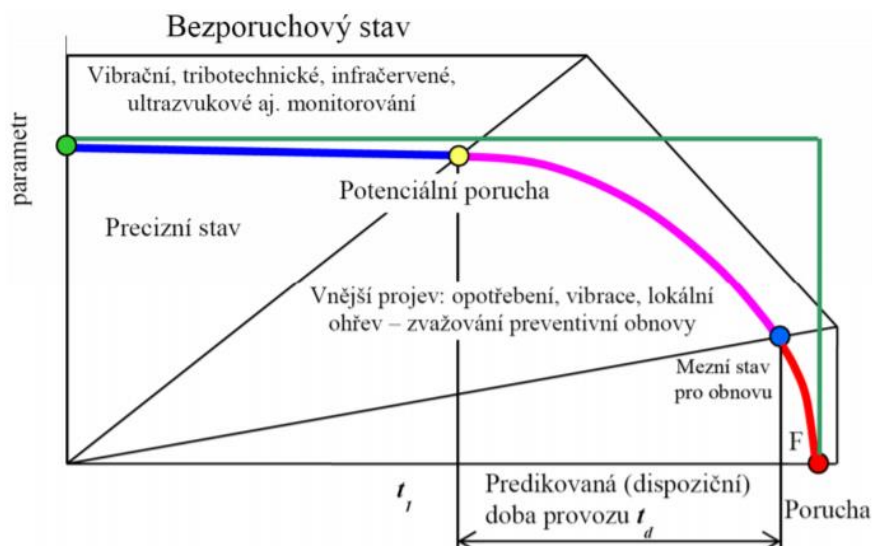
čerpadla). Zkušený technik a analytik dat je schopný z naměřených dat vyčíst příčinu změny chování stroje a včas zasáhnout.

Typ stroje: Čerpadlo	Změna symptomu nebo parametru									
Závada	Únik kapaliny	Měření délek	Výkon	Tlak nebo vakuum	Otáčky	Vibrace	Teplota	Doba doběhu	Znečištění oleje	Netěsnost oleje
Poškozené oběžné kolo		
Poškozené ucpávky				
Excentrické oběžné kolo				
Poškozené ložisko	
Opotřeбенé ložisko		
Chybná montáž						.				
Nevyváženost						.				
Nesouosost		.				.				
* Když se vyskytne závada, může se vyskytnout indikovaný symptom nebo změna parametru.										

Tab 01 – Tabulka příklady změn parametrů v závislosti na druhu závady [34]

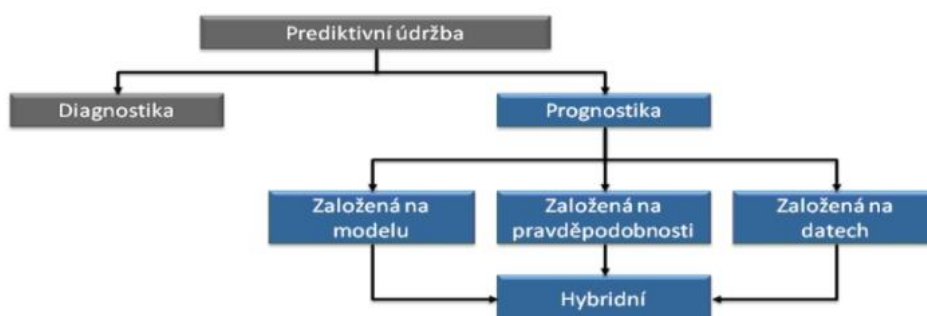
9.5 Prediktivní údržba (Predictive Maintenance)

Prediktivní údržba někdy také nazývaná Údržbou 4.0 je moderní přístup k údržbě strojů. Stejně jako diagnostická údržba se neobejde bez dat (monitoringu významných parametrů výrobního zařízení, snímaných v reálném čase). Velice důležitou roli zde hraje datový analytik, který je schopen pomocí technik dataminingu předpovědět poruchu konkrétního výrobního zařízení tak, aby pracovník údržby mohl včas zasáhnout, ještě než k poruše dojde. Analýzy dat se také využívají k aktualizacím plánu údržeb. [35] Mezi postupy, které analytik využívá, patří například neuronové sítě a další druhy umělé inteligence. [36]



Obr 06- Princip prediktivní údržby [36, s 6]

Prediktivní údržbu lze chápat jako diagnostickou údržbu, rozšířenou o prognostiku. Prognostické metody se dále dělí na tři kategorie – založené na modelu, založené na pravděpodobnosti a založené na datech, nebo jejich kombinace. [37]



Obr 07 – Metody prognostiky [37]

Metody založené na datech jsou převážně statistické metody, pomocí kterých se snažíme nalézt konkrétní vzor v datech monitorovaného zařízení. Jejich přesnost a efektivita závisí zejména na množství a kvalitě historických dat, která máme k dispozici. Mezi tyto metody se řadí například multivariační statistické metody, neuronové sítě, rozhodovací stromy, bayesovy sítě a mnoho dalších. [37]

Metody založené na modelu se využívají u zařízení, která lze popsat matematickým a fyzikálním modelem. Výstupní data zařízení se porovnávají s modelem a rozdíl

(reziduum) je malé v případě normálního chodu zařízení, naopak v případě nestandardního chování se zvýší. [37]

Metody založené na pravděpodobnosti pracují s historickými daty, výrobními parametry zařízení a provozními údaji a odhadují pravděpodobnost poruchy zařízení v čase. Využívají zejména distribuční funkce pravděpodobnosti pro jednotlivé části nebo komponenty zařízení. [37]

Vývoj politiky údržby se stále vyvíjí a od dob první průmyslové revoluce dosáhl podstatných změn. Prediktivní údržba si postupně nachází cestu do českých firem, na které ji čeká mnoho překážek, mezi které patří nedostatek dat, financí a kvalifikovaných odborníků.

V průzkumu, který provedl David Ženíšek a kol. ze Západočeské univerzity v Plzni (2019) vyplynulo, že pouze 1 z 11 dotázaných podniků v České republice (zabývajících se výrobou či výzkumem, nad 140 zaměstnanců) využívá Big Data analytiku pro účely údržby. [35]

10 Metodiky údržby

V reálných podmínkách se typicky kombinuje více strategií. Důraz se klade na oblast preventivní údržby a vzniklo několik specifických metodik. V této kapitole si představíme metodiku TPM a RCM.

10.1 TPM – Komplexní produktivní údržba

System TPM (Total Productive Maintenance) se zabývá předcházením poruch výrobních zařízení. Jeho autorem je Japonec Seiichi Nakajima, který se zabýval systémy preventivní údržby (Preventive Maintenance) a produktivní údržby (Productive Maintenance). Zdůrazňuje důležitost zapojení všech pracovníků, včetně vrcholového vedení.

„Komplexní produktivní údržba je moderní způsob organizace a řízení údržby výrobních zařízení v rámci podniku. Jejím cílem je maximální efektivita zařízení po celou dobu jejich života a týká se všech zaměstnanců všech oddělení a všech úrovní. Orientuje se na zapojení všech pracovníků v dílně do aktivit, které směřují k minimalizaci prostojů, poruch a neshodných výrobků.“ [30, s 137]

Zdánlivé drobnosti jako například pravidelné čištění, kontrola, mazání výrobních zařízení a další aktivity, které mohou provádět řadoví zaměstnanci, kteří obsluhují výrobní zařízení, mohou značně přispět k efektivitě výroby, prodloužit životnost stroje a omezit vznik poruch. Koncept je založen na skutečnosti, že pracovník, který obsluhuje výrobní zařízení je schopen zpozorovat jako první abnormality, včas zareagovat a předejít budoucí poruše, ke které se schyluje - je na něho tak přenesena část zodpovědnosti oddělení údržby.

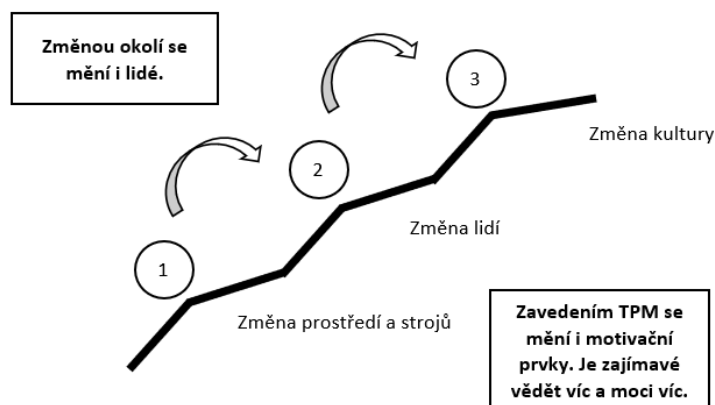
Jako příčiny prostojů lze identifikovat 3 základní faktory: [30]

1. Znečištění (42 %)

Až 42 % prostojů je způsobeno znečištěním (jako je např. prach, třísky, kyselost / zásaditost, olej, mazivo atd.). Pro eliminaci těchto prostojů se zavádí koncept 5S, který zajistí organizaci a čistotu pracoviště.

2. Člověk (33 %)

Pochybení operátorů, obsluhy výrobních zařízení, nedostatečné vědomosti, ztráta motivace, bezmyšlenkovitost mohou vést k neplánovaným prostojům výroby. Cestami k eliminaci poruch způsobených člověkem jsou neustálé vzdělávání a školení obsluhy, odměňování, týmová organizace, celková změna myšlení lidí a firemní kultury. TPM má pozitivní vliv na myšlení lidí a firemní kulturu.



Obr 08 - Princip změn při aktivitách TPM [30, s 139]

3. Opotřebení (25 %)

Opotřebení zařízení – tření, teplota, tlak, lomy atd. Důležité je včasné odhalení obsluhou, zpozorování abnormálního chování zařízení a včasná reakce.

10.2 RCM – Údržba zaměřená na bezporuchovost

RCM (Reliability Centred Maintenance) je nástroj pro zlepšování jakosti údržby. Dokáže odhadnout, kde je nutné provést preventivní údržbu, která zabere méně času, než případný následný prostoje z důvodu poruchy a poškození výrobního zařízení a například výměny součástky, čekání na dodání náhradního dílu apod.

„RCM je metodika vypracování programů údržeb zpravidla pro složité stroje a zařízení s cílem zajistit jejich co největší bezporuchovost.“ [30, s 319]

„Údržba zaměřená na bezporuchovost (RCM) je metoda pro zavedení programu preventivní údržby, který umožní účelně a účinně dosáhnout požadované úrovně bezpečnosti a pohotovosti výrobního zařízení, a je určena k tomu, aby vedla ke zlepšení celkové bezpečnosti, pohotovosti a hospodárnosti provozu“ [38, s 3]

Pro správnou funkčnost a zavedení RCM metody údržby je důležitá dobrá znalost a definice funkce systému a jeho částí, stanovení funkčně významných prvků a dobré pochopení důsledků jednotlivých poruch. [30] Pro tento účel je vhodnou metodou analýza způsobů a důsledků poruch Failure Modes and Effects Analysis (FMEA) a analýza způsobů, důsledků a kritičnosti poruch Failure Modes, Effects and Criticality Analysis (FMECA). FMECA se skládá z analýzy FMEA a analýzy kritičnosti poruchy CA. [39] Analýza kritičnosti představuje úroveň rizika, zahrnující hodnocení všech následků poruchy. [30]

Výpočet kritičnosti poruchy RPN (Risk Priority Number) se vyjadřuje součinem: [39]

$$RPN = S \cdot O \cdot D$$

- S = Závažnost (Severity)
- O = Výskyt (Occurrence)
- D = Odhalitelnost (Detection)

Každý z činitelů je popsán na 10bodové stupnici, kde 10 je nejvyšší hodnotou (z toho vyplývá rozmezí RPN 1 až 1000).

Cílem RCM je nastavit program údržby tak, aby zajistil co nejvyšší bezporuchovost výrobních zařízení a následně výsledky zahrnout do komplexní produktivní údržby TPM. [38]

11 Představení společnosti Vitesco Technologies

Divize Powertrain společnosti Continental AG od roku 2019 převzala nový obchodní název Vitesco Technologies (dále jen VT). K úplnému oddělení společnosti VT od koncernu Continental je plánováno v průběhu roku 2021. V České republice se VT nachází ve třech lokalitách – Ostrava, Frenštát pod Radhoštěm a nakonec lokalita, které se budeme věnovat v této práci – Trutnov.

VT v Trutnově se zaměřuje na výrobu komponent do diesellových i benzinových spalovacích motorů jako jsou vysokotlaká čerpadla, vstřikování a turbodmychadla. V portfoliu firmy mají své zastoupení také aktuátory, senzory a ventily (například EGR ventil pro recirkulaci výfukových plynů) a mnoho dalších. VT je subdodavatelem světových významných automobilek. Největšími odběrateli jsou například Ford, Daimler, Hyundai, Renault, Volkswagen, Fiat, PSA a další.

Dlouhodobá strategie společnosti VT je zaměřena na čistou a udržitelnou mobilitu a jejím cílem je včas reagovat na měnící se požadavky trhu (zpřísnování norem pro spalovací motory) a také zvyšující se míra elektrifikace vozidel. ^[40]

Závod v Trutnově má celkem 3 výrobní haly a aktuálně přes 1500 zaměstnanců (údaj k 1.3.2021).

V této práci se zaměříme na oblast údržby ve společnosti. Analyzujeme systém a metodiku údržby a navrhujeme možnosti zavedení prediktivní údržby.

12 Strategie a metodiky údržby ve společnosti VT

V této kapitole analyzujeme přístup k údržbě výrobních zařízení ve společnosti VT. Zaměříme se na plány údržby a využívané metodiky údržby. [41]

12.1 Preventivní údržba

Pro každé výrobní zařízení je vypracován plán údržby, zpracovaný na míru s ohledem na jeho náročnost na údržbu. Základními dokumenty pro vypracování plánu údržby je dokumentace k zařízení od výrobce a expertní zkušenosti pracovníků oddělení údržby. Plán údržby standardně obsahuje následující informace:

- posloupnost pravidelně prováděných úkonů v daných časových intervalech
- odpovědnosti (kdo je odpovědný za provedení jednotlivých úkonů)
- návod, jak jednotlivé úkony provádět včetně využívaných prostředků
- bezpečnostní pokyny

Plány údržby jsou založené na preventivní strategii. Je důležité efektivní nastavení jednotlivých úkolů a jejich frekvence opakování. Úkony v plánech údržby rozděleny do třech kategorií:

- Preventivní údržba – úroveň 1 (autonomní údržba, provádí obsluha zařízení – seřizovač, operátor)
- Preventivní údržba – úroveň 2 (provádí oddělní údržby)
- Preventivní údržba – úroveň 3 (provádí externí servis)

Část úkonů provádí pracovníci oddělení údržby. Jedná se zpravidla o technicky náročnější zásahy (kontroly a inspekce, výměny náhradních dílů atd.) opakující se v delších časových intervalech (měsíčně, čtvrtletně, půlročně, ročně).

Další část úkonů je odpovědnostně přenesena na obsluhu zařízení, prováděná v kratších časových intervalech na denní, nebo týdenní bázi. Zpravidla se jedná o jednodušší úkony jako jsou prohlídky, čištění, mazání atd.

Poslední část úkonů, pro kterou nemá oddělení údržby potřebné vybavení, kvalifikaci, nebo znalosti, vyžaduje objednání služeb externího servisu (nejčastěji plánované na výrobní odstávky).

12.2 Údržba po poruše

Při poruše výrobního zařízení nápravu zajišťuje prioritně seřizovač. Pokud není náprava a vrácení zařízení do provozuschopného stavu v jeho silách, ohlásí výpadek pracovníkům oddělení údržby, kteří provedou opravu okamžitě, s odložením, nebo při odstávce, podle stanovených priorit.

Cílem oddělení údržby je efektivní nastavení preventivní údržby (plánů údržby) a tím minimalizování vzniku poruch a výpadků výrobních zařízení, tak aby byla zajištěna co možná nejvyšší dostupnost výrobních zařízení.

12.3 TPM karty

Úkony z plánů údržby, které odpovědnostně spadají pod obsluhu zařízení, prováděné denně či týdně (preventivní údržba úroveň 1), jsou přeneseny do takzvané „TPM karty“. Spolu s těmito úkony definovanými plány údržby se do TPM karet mohou zahrnout i další povinnosti jako očištění nečistot ze zařízení, kontrolu zařízení a další...

Vytvořené TPM karty jsou zalité v laminovací folii, vyvěšené na každém z výrobních zařízení. Obsahují obdobně jako plány údržby seznam úkonů a frekvenci, ve které jsou prováděny, návod, jak jednotlivé úkoly provádět a využívané prostředky. Navíc ještě obsahují pole pro datum a stvrzení splnění úkolu podpisem pracovníka, který úkol provedl. Záznamy se provádějí fixem na povrch laminovací folie, tak aby mohly být opětovně zapisovány a mazány.

O metodice TPM jsme již pojednávali v teoretické části. Koncept TPM celkově zvyšuje efektivitu údržby, tím snižuje riziko poruchy, prodlužuje dostupný čas výrobního zařízení a prodlužuje jeho životnost. Cílem TPM karet je zapojení obsluhy zařízení do procesu údržby.

12.4 Diagnostická údržba

12.4.1 Tribodiagnostika

Technická tribodiagnostika (analýza stavu oleje) je nástroj, který sleduje určené parametry hydraulického oleje. Znečištění oleje má vliv na kvalitu jeho mazání, proto je tribodiagnostika jedním z účinných nástrojů prediktivní analýzy. Činnost zařízení

také způsobuje opotřebení, při kterém se do oleje uvolňují částice. Sledováním množství částic v oleji tak lze také odhalit blížící se poruchu zařízení (opotřebení součástí hydraulického systému stroje).

Ve VT jsou výsledky z tribodiagnostiky využívány jako prvek diagnostické údržby. Na základě výsledků této analýzy je prováděna výměna hydraulických olejů ve výrobních zařízeních. V pravidelném intervalu 6 měsíců je odeslán vzorek oleje do laboratoře (v případě horších výsledků je frekvence odesílání vzorků do laboratoře kratší). Pokud se výsledky analýzy vyšplhají nad stanovené limity, je olej vyměněn.

Pro analýzy oleje se využívají služby externí firmy KleenTek.

12.4.2 Snímání teploty a vibrací


Oddělení údržby využívá senzory k snímání aktuálního stavu zařízení. Senzory snímající data v reálném čase jsou umístěny na několika zařízeních. Jedná se o snímání vibrací a teploty v reálném čase. Data ze senzorů jsou odesílána a zpracována s použitím speciálního softwaru, který zobrazuje graficky jejich vývoj v čase. Při vývoji dat do kritických hodnot, je nastaven alarm, který okamžitě informuje zodpovědné osoby o kritické situaci (blíže se tomuto tématu věnujeme v kapitole 13.4).

13 Odsávač výparů ze svařování Nederman


Průmyslový odsávač výparů od výrobce Nederman se využívá k odsávání výparů ze svařování. Ve společnosti VT se používá na čistém prostoru k odsávání výparů ze svařování na montážní lince GHP2, kde se vyrábí benzínové vysokotlaké pumpy pro známé světové automobilky, jako je například Volkswagen, Audi, General Motors, Bentley, Ford a další.

13.1 Umístění senzorů

Na zařízení se nacházejí dva IO-Link vibrační senzory od firmy IFM, které měří vibrace a teplotu a v reálném čase je odesílají ke zpracování. Umístění senzorů ukazuje Obr 09. Jeden ze senzorů je umístěn na motoru zařízení, druhý na hřídeli.



Obr 09 – Schéma odsávacího zařízení Nederman a umístění senzorů na motoru a hřídeli



Obr 10 – Fotografie ukazující reálné umístění senzorů

Data ze senzorů zpracovává software ifm moneo, který umožňuje sledovat aktuální stav zařízení, ale také lze nahlížet do minulosti a data porovnávat. V ifm moneo lze také nastavit prahy poplachových mezí a při naměření abnormálních hodnot jsou upozorněny zodpovědné osoby, aby se mohla naplánovat oprava, popřípadě seřízení stroje.

13.2 Sledované charakteristiky signálu

Charakteristiky, které senzory vyhodnocují a druhy závad, které lze diagnostikovat: [42]

- $v\text{-RMS}$ [mm/s] – rychlost vibrací v efektivní hodnotě (RMS velocity) měří celkové zatížení rotujícího stroje. V hodnotách $v\text{-RMS}$ lze odhalit nevyváženost stroje, chyby vyrovnání, problémy s řemenem apod.
- $a\text{-RMS}$ [m/s²] – zrychlení vibrací v efektivní hodnotě (RMS acceleration) detekuje mechanický kontakt součástí stroje, jako je například v důsledku poškozeného ložiska, opotřebení ozubeného kola apod.
- $a\text{-Peak}$ [m/s²] – vrcholové nebo špičkové zrychlení (Peak acceleration) je měřítkem sil působících na stroj. Lze pozorovat zvýšené hodnoty při nárazu, nebo v pravidelných intervalech například při poškození ložisek.
- crest faktor – činitel výkmitu je poměr maximální hodnoty (špičkové hodnoty vibrací – peak) k efektivní hodnotě (RMS). Při zhoršování technického stavu

stroje se v důsledku opakujících se rázů zvyšují hodnoty crest faktoru a jeho trend roste

$$Crest = \frac{Peak}{RMS}$$

- temperature [°C] – měření teploty, pomocí teploty lze detekovat závady jako je ztráta maziva, elektrické problémy nebo nadměrné zatížení

Měřicí rozsahy senzorů využívaných na zařízení Nedrman:

Měřicí rozsahy senzoru VVB011	
Frekvence	2 – 10000 Hz
v- RMS	0 – 45 mm/s
a- Peak / a-RMS	0 – 490,3 m/s ²
Crest	1 – 50
Teplota	-30 – 80 °C

Tab 02 – měřicí rozsahy senzorů typu VVB011 [43]

13.3 Parametry časového průběhu signálu


Výkmit – špičková hodnota (peak) je vzdálenost mezi špičkovou hodnotou a referenční hodnotou.

Rozkmit – vzdálenost od špičky k protilehlé špičce vlny.

Průměrná hodnota – průměrná hodnota amplitudy.

Výpočet efektivní hodnoty RMS (root mean square):

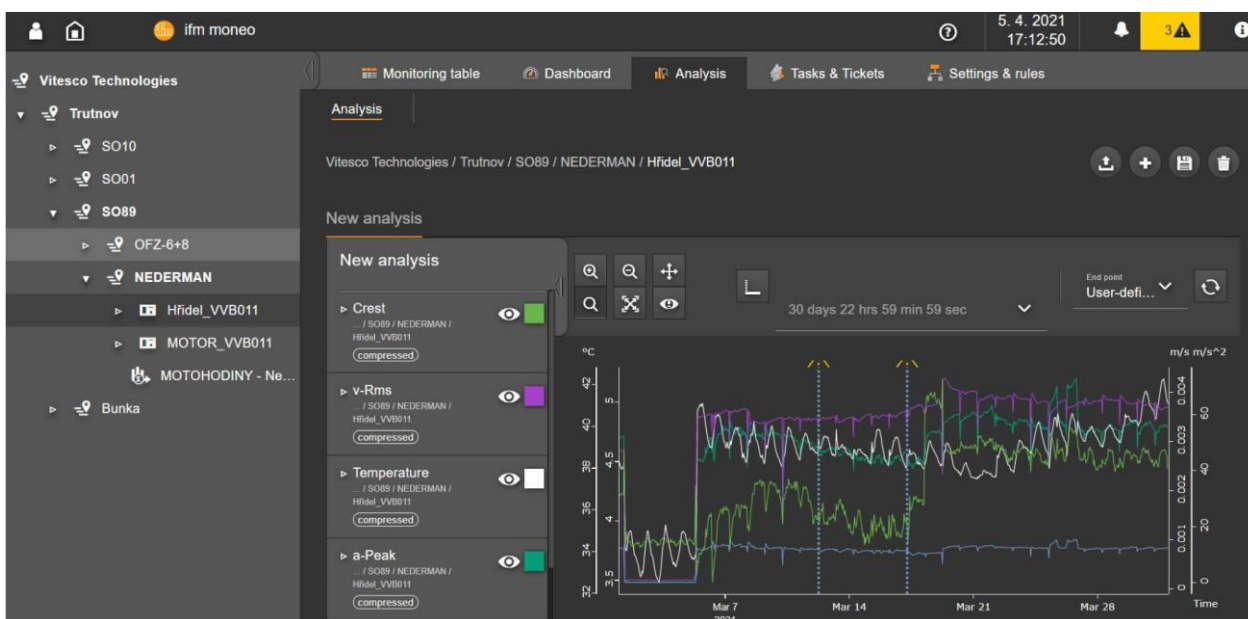
$$X_{ef} = \sqrt{\frac{1}{T} \int_0^T X^2(t) dt}$$



Obr 11 – Parametry časového průběhu kmitavého pohybu – signálu [44]

13.4 Software ifm moneo a nastavení prahových hodnot

Ifm moneo je nástroj pro vizualizaci sledovaných charakteristik měřených rozmístěnými senzory. Na obrázku (Obr 12) můžeme vidět ukázkou uživatelského rozhraní. Vlevo se nachází rozdělovník, který je rozčleněn podle pracovních oblastí na první úrovni, dále podle názvů zařízení a umístění senzorů na zařízení. Další částí je okno pro analýzu dat, kde si můžeme zvolit časový úsek a konkrétní charakteristiky, které potřebujeme analyzovat. Data lze také exportovat do csv souboru. Ifm moneo poskytuje možnost centrálně nastavovat parametry jednotlivých senzorů.



Obr 12 – Uživatelské rozhraní ifm moneo

Software zároveň sleduje pro každou charakteristiku překročení prahových hodnot a v případě upozorní na jejich abnormální vývoj. Tyto prahové hodnoty jsou stanoveny na základě zkušeností a pozorování chování stroje v běžném bezporuchovém provozu. Prahové meze jsou rozděleny do dvou stupňů – varovné a poplachové.

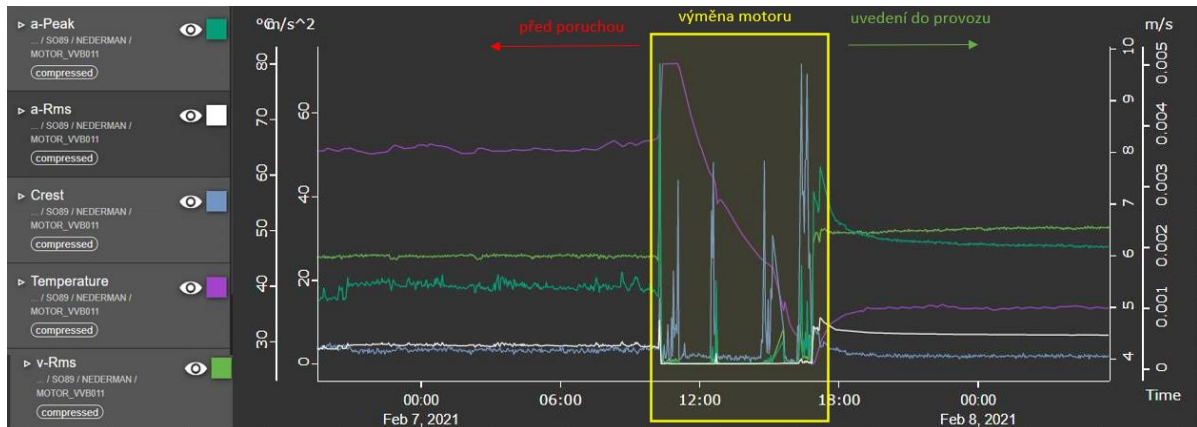
Stanovení varovných a poplachových mezí (alarmů) pro jednotlivé charakteristiky – zařízení Nederman:

	Hřídel		Motor	
	Varování	Alarm	Varování	Alarm
Teplota [°C]	45	55	45	55
a-RMS [m/s ²]	50	90	x	x
a - peak [m/s ²]	70	90	40	60

Tab 03 – Nastavení prahových mezí – Nederman

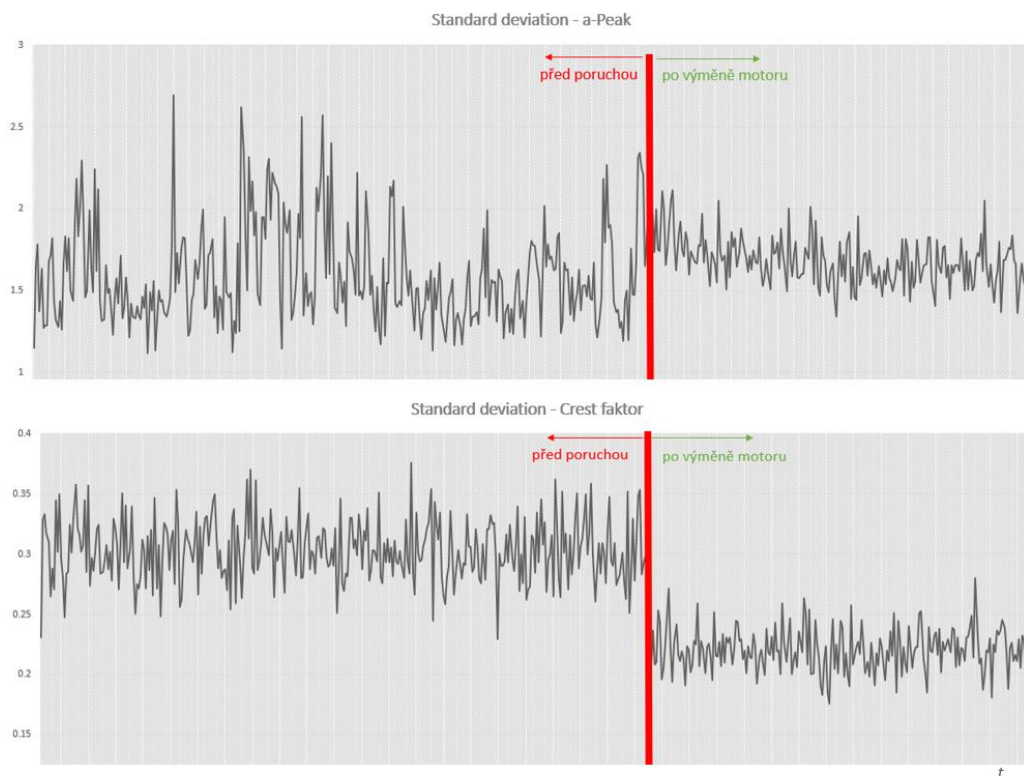
14 Analýza vibračních charakteristik při poruše

Senzory jsou na zařízení umístěné teprve několik měsíců (od února 2021). Za toto období zatím nastala jediná porucha – dne 7.2.2021 poškození ložiska na motoru. Motor byl vyměněn za nový a byl obnoven provoz zařízení. Na grafu níže (Obr 13) je vyznačen průběh poruchy a můžeme sledovat vývoj jednotlivých charakteristik vibrací a teploty.

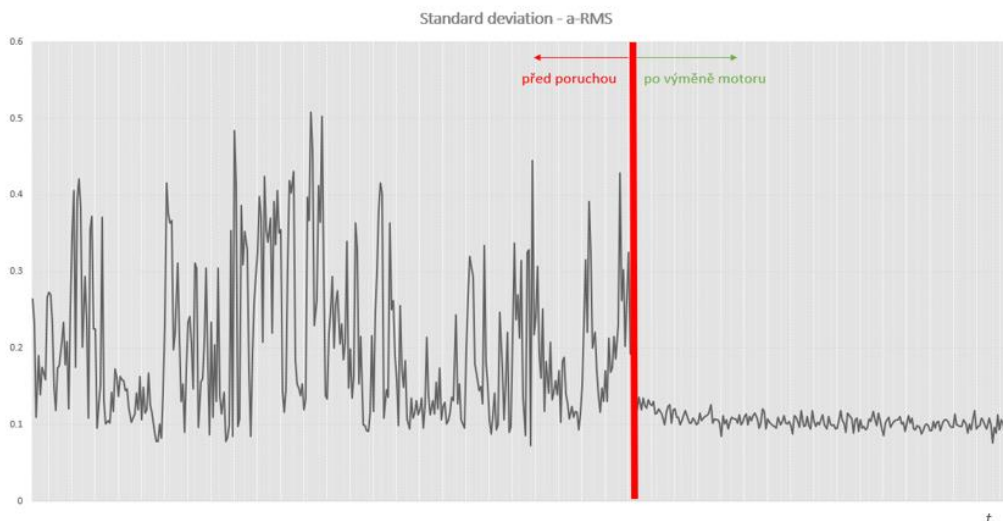


Obr 13 – Časový průběh poruchy motoru

Z grafických výstupů je na první pohled zřejmá zvýšená teplota před poruchou, která se pohybovala kolem cca 65 °C (alarm nastaven na 55 °C). Viditelný je také rozdílný průběh jednotlivých charakteristik před a po havarijním stavu, nicméně z tohoto grafu není změna jednotlivých charakteristik příliš čitelná. V následujících grafech můžeme vidět hodnoty směrodatné odchylky, vypočítané z naměřených hodnot jednotlivých charakteristik za určitý časový interval (v tomto případě cca 11,7 min) před a po poruše. Uvedeny jsou směrodatné odchylky crest faktoru, a-Peak a a-RMS, kde jsou patrné signifikantní rozdíly průběhu před a po poruše.



Obr 14 – Průběh směrodatných odchylek a-Peak a crest faktoru před a po poruše



Obr 15 – Průběh směrodatné odchylky a-RMS před a po poruše

Z grafů je zřejmý význam vibrační analýzy v diagnostické a prediktivní údržbě. Ve společnosti VT je průběh vibrací pravidelně sledován diagnostikem z oddělení údržby, který při abnormálním vývoji charakteristik zjišťuje příčinu. Nicméně dat zatím není nasbíráno mnoho, senzory jsou v provozu teprve několik měsíců, takže se spíše experimentuje a využívají se data pro účely diagnostické údržby.

15 Možnosti zavedení prediktivní údržby

Pro zavedení prediktivní údržby pro odsavač Nederman si představíme doporučený postup a dva možné přístupy vytvoření prediktivního modelu, které však lze považovat za obecně platné pro většinu zařízení.

Před zavedením prediktivní údržby na kterémkoliv zařízení je vhodné nejprve zvážit finanční náročnost a návratnost investic. Měli bychom dobře znát zařízení, na kterém chceme prediktivní údržbu zavést, a také si udělat přehled všech možných poruch, které mohou nastat, včetně jejich důsledků. Vhodným nástrojem je FMEA, nebo FMECA.

Na zařízení jsou umístěné senzory, které mohou také samozřejmě selhat. Existuje nástroj, který je schopen posoudit stav a přesnost senzorů – MSA (Measurement System Analysis), který stanovuje odchylku mezi naměřenou a skutečnou hodnotou. Tento krok je volitelný, ale jelikož pro prediktivní údržbu je důležité spolehlivé měření, tak ho lze doporučit.

První z přístupů vytvoření prediktivního modelu je nasbírání velkého množství datových sad, zahrnujících jak poruchové, tak bezporuchové stavy. Nasbíraná data lze následně analyzovat a použít pro vytrénování a vytvoření algoritmu. Vhodné je také sbírat data z více stejných zařízení (bohužel v tomto případě nejsou k dispozici), která jsou v provozu v různých pracovních podmínkách. Data z více zařízení zajistí vytvoření robustnějšího prediktivního modelu.

Druhým možným přístupem, který se využívá při nedostatku nasbíraných dat, je vytvoření matematického modelu zařízení, který by simuloval provoz zařízení (poruchový i bezporuchový) a odhadoval senzory naměřené hodnoty (syntetická data). Tato data vytvořená matematickým modelem, mohou doplňovat data ze senzorů na reálném zařízení a pomoci vytvořit prediktivní model.

Nasbíraná data je před jejich analýzou a použitím k trénování algoritmu nutné očistit od nežádoucích složek jako jsou odlehlé hodnoty, chybějící hodnoty, bílý šum a další, abychom předešli zkreslení výsledků a dosáhli vytvoření efektivnějšího algoritmu. Také nám tento krok usnadní analýzu dat, ještě před vytvořením prediktivního modelu, kdy potřebujeme nalézt vhodné charakteristiky, které reprezentují technický stav zařízení – takzvané indikátory stavu zařízení. Některé indikátory se hodí pro

vytrénování modelu, jiné zase pro klasifikaci jednotlivých poruch. Na jejich vhodném výběru závisí spolehlivost a přesnost celé prediktivní údržby. [45]

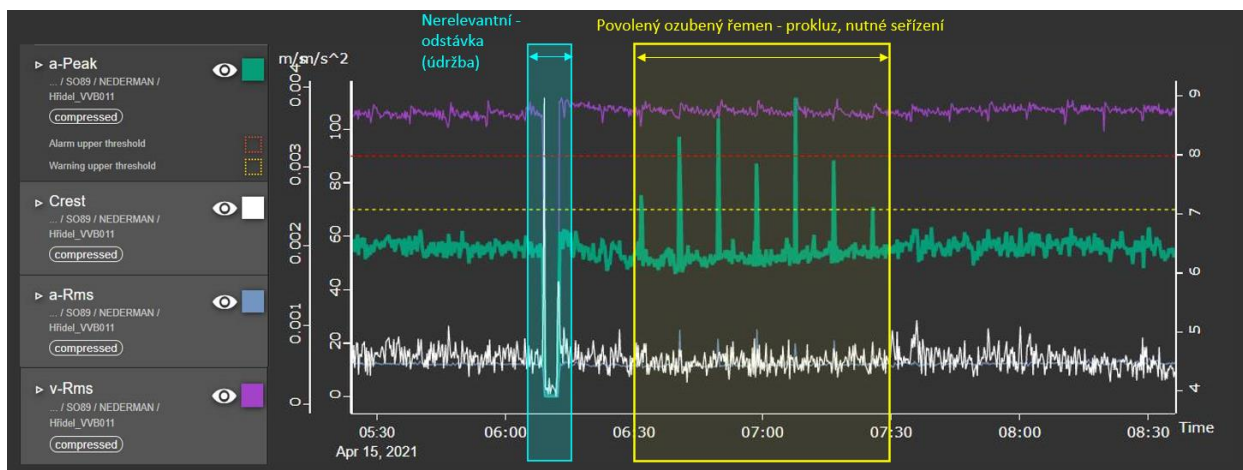
16 Volba indikátorů stavu zařízení

Přesnost vytvořeného prediktivního modelu závisí zejména na kvalitě a množství dat, ale také správně zvolených indikátorech stavu, které budou k vytrénování modelu použity. Je vhodné zvolit takové charakteristiky, které mění své hodnoty se zhoršujícím se stavem zařízení. Použití nesprávných, nebo nerelevantních charakteristik by mohlo model negativně ovlivnit a jeho předpovědní schopnost by se značně zhoršila, protože by tyto nevhodné indikátory způsobovaly v modelu šum.

Algoritmus, vytrénovaný pomocí strojového učení lze využívat v prediktivní údržbě ke třem základním účelům – detekci abnormálního chování, klasifikaci poruchy a odhadu zbývajících provozuschopného stavu zařízení – RUL (Remaining Useful Time). Aby mohl prediktivní model správně klasifikovat druh poruchy je důležité mít nasbíráno dostatek dat k jednotlivým druhům poruch a stanovit vhodně indikátory, dle kterých bude model schopen klasifikovat o kterou konkrétní poruchu se jedná.

Výběr vhodných indikátorů si demonstrujeme na následujícím příkladu.


V dubnu 2021 nastala situace, kdy se začal projevovat abnormální vývoj a-Peak (špičkového zrychlení). Průběh a-Peak těsně po náběhu zařízení v pravidelných intervalech dosahoval vysokých hodnot, které se vyšplhaly až nad varovnou, a zanedlouho i nad poplašnou hodnotu nastavených mezí. Po čase se zase hodnoty stabilizovaly a incident se opakoval vždy po spuštění zařízení (Obr 16). Zařízení bylo zkontrolováno pracovníkem údržby, který diagnostikoval prokluzující ozubený řemen a bylo nutné naplánovat a provést seřízení, jinak by bez zásahu došlo po nějaké době k poruše zařízení.



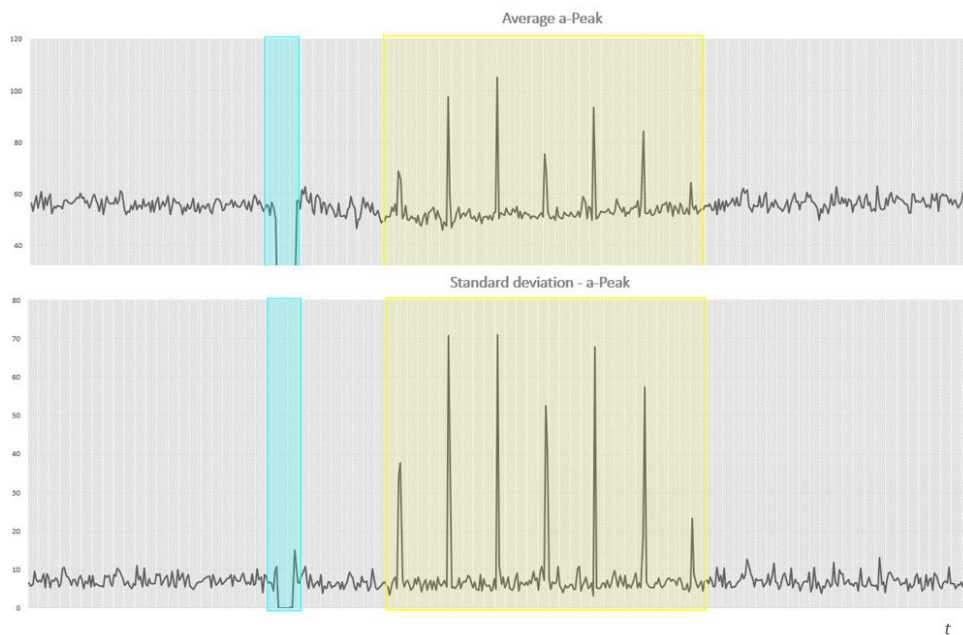
Obr 16 – Ifm moneo, vizualizace charakteristik ovlivněných prokluzujícím ozubeným řemenem

Pokud analyzujeme vývoj jednotlivých charakteristik, které byly v časovém intervalu od přibližně 6:30 do 7:30 ovlivňovány povoleným řemenem (zvýrazněno žlutě), můžeme stanovit vhodné indikátory pro kategorizaci incidentu uvolněného řemenu. Mezi časem 6:07 až 6:12 bylo zařízení na několik minut zastaveno z důvodu naplánované pravidelné denní údržby, proto nebudeme data z toho časového úseku považovat za relevantní (zvýrazněno modře).

Charakteristiky, které vykazují největší změny průběhu v tomto období jsou hodnoty obou druhů zrychlení jak špičkového, tak v efektivní hodnotě (a-Peak a a-RMS – Obr17, Obr18)




Obr 17 – Grafy uvolněný řemen – a-RMS



Obr 18 – Grafy uvolněný řemen – a-Peak

Naopak minimální nebo žádné změny pozorujeme u hodnot crest faktoru a v-RMS (Obr 19). Proto se tyto charakteristiky nebudou dobrou volbou pro kategorizaci tohoto typu incidentu – uvolněného ozubeného řemenu.



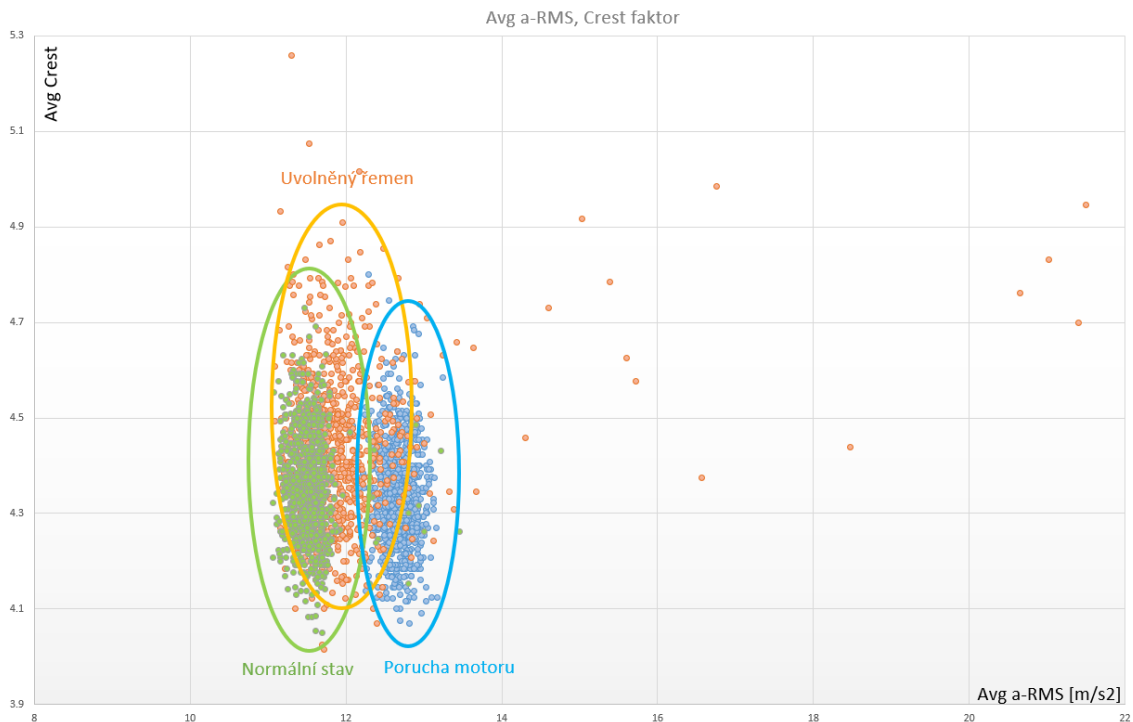
Obr 19 – Grafy uvolněný řemen – Crest faktor a v-RMS

Nyní porovnáme data z uvolněného řemenu z dubna 2021 s daty naměřenými těsně před poruchou motoru v únoru 2021 a referenčních hodnot provozu zařízení za normálního stavu. Z dostupných charakteristik použijeme průměrné hodnoty zrychlení a rychlosti v efektivní hodnotě (a-RMS a v-RMS), které se jeví jako nejvhodnější pro kategorizaci těchto dvou poruch. Vizualizaci jsme znázornili v bodovém grafu (Obr 20). Aby byl schopen algoritmus správně klasifikovat druh poruchy, je cílem najít takové indikátory stavu, které budou hodnoty jednotlivých poruch co nejvíce odlišovat. Využili jsme pro tyto účely dvě charakteristiky, lze ale využít kombinace více charakteristik.



Obr 20 – Porovnání poruchových hodnot s bezporuchovým stavem a-RMS, v-RMS

Na následujícím příkladu (Obr 21) je ukázka nevhodně zvolených indikátorů stavu, kdy se jednotlivé poruchy překrývají a algoritmus by kategorizoval poruchy s vyšší mírou nejistoty a zároveň by je častěji zaměňoval za bezporuchový stav, což je z hlediska prediktivní údržby nepřijatelné.



Obr 21 – Porovnání poruchových hodnot s bezporuchovým stavem a-RMS, Crest faktor

Při této demonstrativní ukázce jsme vycházeli z dostupných dat a naměřených charakteristik, kterých není mnoho a pro stanovení kategorizace jednotlivých poruch a indikátorů by bylo třeba důkladnějších analýz signálu. Někdy se při výběru vhodných indikátorů stavu pro kategorizaci poruchy setkáme s dvěma či více poruchami, které jsou z hlediska vývoje jednotlivých charakteristik téměř stejné a pro predikční model je nemožné rozeznat tyto druhy poruch s uspokojivou mírou spolehlivosti. V těchto případech je nutné prozkoumat vývoj charakteristik z různých úhlů pohledu a najít odlišnost mezi těmito poruchami, která bude využita jako indikátor stavu. Signál je nutné analyzovat několika různými způsoby, v případě vibrací je vhodné provést časovou analýzu (průměr, rozptyl, šikmost, špičatost, standardní směrodatná odchylka...), frekvenční analýzu (vrcholy, maximální frekvence...) a časově-frekvenční analýzu a nalézt tak vhodné indikátory stavů, kterými lze charakterizovat rozdíly mezi jednotlivými poruchami. [46]

Pro zavedení prediktivní údržby je potřeba zvolit vhodný software, který bude schopný předzpracovat nasbíraná zašumělá data, analyzovat signál, vytrénovat prediktivní model a v reálném čase následně data zpracovávat a vytvářet predikce. V této práci si představíme možnosti softwaru MATLAB s jeho nadstavbou Simulink a doplňkem Predictive Maintenance Toolbox.

17 Prediktivní údržba v prostředí MATLAB

MATLAB je produktem společnosti MathWorks, Inc. Představuje software a programovací jazyk, který se využívá zejména pro analýzu dat, numerické výpočty, vývoj algoritmů a simulaci, ke které využívá nadstavbovou platformu Simulink.

„MATLAB poskytuje řešení v oblastech, jako je aplikovaná matematika, strojové učení, zpracování signálu a komunikace, zpracování obrazu a počítačové vidění, finanční analýza a modelování, návrh řídicích systémů, robotika a mnoha dalších. Příkladem aktuálního využití systému MATLAB může být vývoj systémů aktivní bezpečnosti automobilů, robotické sondy vesmírného programu, monitorovací systémy ve zdravotnictví, inteligentní energetické sítě nebo LTE systémy.“ [47]

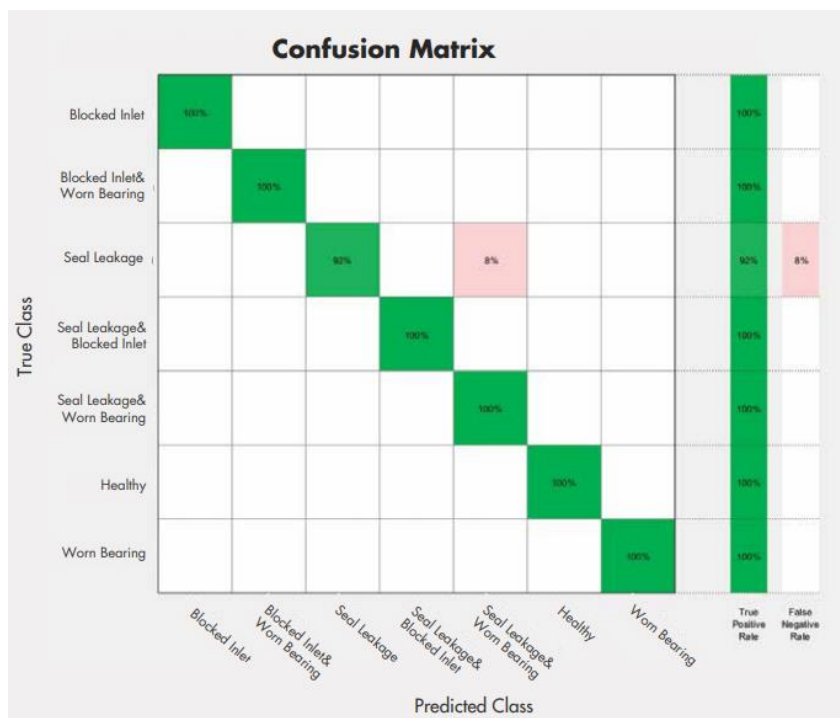
Predictive Maintenance Toolbox byl vyvinut pro účely prediktivní údržby, je doplňkem systému MATLAB a dokáže pokrýt proces zavedení prediktivní údržby od sběru surových dat, přes jejich předzpracování, analýzu dat, extrahování vhodných indikátorů stavu a jejich ohodnocení, vytrénování prediktivního modelu až po uvedení prediktivní údržby do provozu. Využít lze také možnost vytvoření matematického modelu a generování syntetických dat pomocí platformy Simulink.

Simulink je nástroj k vytváření dynamických systémů, pomocí blokových schémat reálných systémů, nebo rovnic. Systémy lze simulovat v reálném čase a vizualizovat výsledky. [47]

Pro zpracování signálů nabízí MATLAB balíčky Signal Processing Toolbox nebo Wavelet Toolbox – funkce z oblasti časové analýzy, frekvenční analýzy a časově-frekvenční analýzy, díky čemu poskytuje plnou podporu pro důkladnou analýzu vibračních signálů ze senzorů umístěných na zařízeních.

MATLAB obsahuje také funkci pro vyhledávání vhodných indikátorů stavu, které lze následně ohodnotit pomocí funkce rank features. Po nalezení vhodných kandidátů pro indikátory stavu, vytrénujeme pomocí strojového učení model, nebo modely, s využitím zvolených metod (například neuronové sítě, bayesovské sítě, kvadratická diskriminační analýza atd.). U vytvořených modelů MATLAB vyhodnotí jejich přesnost například s využitím matice záměn (Confusion Matrix – Obr 21) na základě čehož si vybereme nejpřesnější model. Pokud nejsme spokojeni s přesností vytvořených

prediktivních modelů, musíme se vrátit o krok zpět k výběru indikátorů stavu a zvolit jejich vhodnější kombinaci.



Obr 22 – Confusion Matrix MATLAB [46]

Pro výpočet RUL (Remaining Useful Time), tedy času zbývajícího do poruchy využívá MATLAB tři metody výpočtu. První metoda, založená na podobnosti (similarity model), porovnává naměřená data z konkrétního zařízení s daty naměřenými na jiném podobném zařízení a odhaduje zbývající čas do poruchy. Druhou metodou, je metoda založená na přežití (survival model), která pracuje s historickými daty, konkrétně historickými výskyty poruch a dobou mezi nimi. Pomocí statistických metod a pravděpodobnostní distribuce pak odhaduje čas do následující poruchy. Poslední metodou je metoda založená na degradaci (degradation model), která předpovídá poruchu na základě historických naměřených dat na konkrétním zařízení a snaží se vytrénovat lineární, nebo exponenciální model, který odhaduje čas do překročení hodnot stanovených poruchových mezí. Jelikož nejsou k dispozici data z jiného odsavače výparů ze svařování Nederman, bylo by nejvhodnějším řešením využití poslední metody – metody založené na degradaci, samozřejmě po nasbírání dostatečného množství dat jak k vytrénování modelu, tak k odhadu RUL pomocí degradačního modelu.

Vytvořené modely lze poté snadno exportovat například ve formě scriptu a nasadit v reálném prostředí, přímo na zařízení, serveru, cloudu apod. [48], [45]

Velikou výhodou využití systému MATLAB jsou volně dostupná naučná videa a dokumentace, jak teoretické, tak z oblasti praktické z reálného prostředí (například zavedení prediktivní údržby ve společnosti Mercedes). Jsou tedy oporou při práci se softwarem, jak pro zkušené uživatele, kteří si mohou prohloubit znalosti, ale také je ocení zejména začátečníci, kteří se teprve se systémem MATLAB seznamují. Kromě dostupné online podpory v podobě dokumentace a videí, se také konají online semináře a konference.

18 Závěr

Teoretická část bakalářské práce se nejprve zabývá vysvětlením pojmu predikčních analýz a jejich využitím. Následuje vysvětlení související terminologie a základních kvantitativních metod jako je analýza časových řad, neuronové sítě, klasifikační a regresní stromy a Kalmanův filtr. V další části jsou představeny metody a strategie údržby včetně prediktivní údržby a popsány druhy poruch a degradace strojů. V praktické části se práce věnuje analýze přístupu k údržbě výrobních zařízení ve společnosti Vitesco Technologies, kde zjišťujeme, že nejvyužívanější strategií jsou preventivní údržby, prováděné dle plánů údržeb, a údržba po poruše. Dále se využívá a rozvíjí strategie diagnostické údržby, zahrnující zejména tribodiagnostiku, analýzu vibrací a teploty. Následně se věnujeme datům nasbíraných z vibračních senzorů, umístěných na odsavači výparů ze svařování od výrobce Nederman, které jsou využívány k diagnostické údržbě a sledování aktuálního stavu zařízení. Sensory jsou uvedeny do provozu od února 2021, takže dostupných dat není zatím mnoho. Jsou popsány jednotlivé dostupné charakteristiky, které jsou ze senzorů získávány a jejich význam v diagnostické údržbě. Následně jsou nastíněny dva možné přístupy pro přechod z diagnostické na prediktivní údržbu. Jeden z přístupů je nasbírání dostatečného množství dat a vytvoření prediktivního modelu založeného na datech, druhá možnost je vytvoření matematického modelu a generování syntetických dat, která by doplňovala data ze senzorů. Tento přístup se často využívá u významných systémů, u kterých je nepřijatelné dojít až k selhání zařízení, a také je nutné mít podrobné znalosti týkající se konstrukce zařízení a zkušenosti s vytvářením a simulací modelů. Navázali jsme výběrem vhodných indikátorů stavu zařízení, které jsme demonstrovali na konkrétním příkladu. Na závěr jsme představili možnosti systému MATLAB s jeho nadstavbou Simulink a doplňkem pro prediktivní údržby Predictive Maintenance Toolbox. Možným rozšířením nebo navázáním na tuto práci by mohlo být použití Kalmanova filtru pro filtrování a analýzu vibračního signálu. Tato metoda je ve vibrodiagnostice a prediktivní údržbě využívána zejména kvůli své adaptabilitě a odolnosti vůči rušení, což bývá ve vibrodiagnostice významným problémem. Také by bylo možné pokračovat zpracováváním a analýzou dat a vytvářením prediktivního modelu v softwaru MATLAB.

19 Použitá literatura

- [1] JERISON, David; STROOCK, Daniel. Norbert Wiener. *Notices of the AMS*, 1995, 42.4: 430-438.
Dostupné z: <https://www.ams.org/notices/199504/wiener.pdf>
- [2] SIEGEL, Eric. Kdo klikne, koupí, lže nebo zemře: síla předpovědí pomocí prediktivní analytiky. Brno: BizBooks, 2014. ISBN 978-80-265-0168-8.
- [3] LAROSE, Daniel T. a Chantal D. LAROSE. *Data mining and predictive analytics*. 2ND edition. New Jersey: Wiley, 2015. ISBN 978-1-118-11619-7.
- [4] DINOVI, Ivo D. *Data science and predictive analytics: Biomedical and health applications using R*. Springer, 2018. ISBN: 978-3-319-72346-4
- [5] KUHN, Max a Kjell JOHNSON. *Applied predictive modeling*. New York: Springer, 2013. ISBN 978-1-4614-6848-6.
- [6] DOUGLAS, C. M., L. J. CHERYL AND K. MURAT *Introduction to Time Series Analysis and Forecasting*. New Jersey: Wiley, 2008. ISBN 978-0-471-65397-4
- [7] HONZÍK, Petr. *Strojové učení*. Elektronická skripta VUT Brno, 2006.
- [8] KŘIVÝ, Ivan. *Analýza časových řad* [online]. Ostrava: Ostravská univerzita, 2012. [cit. 2021-02-09]. Dostupné z: <https://web.osu.cz/~Bujok/files/ancas.pdf>
- [9] HYNDMAN, Rob J. a George ATHANASOPOULOS. *Forecasting: Principles and Practice* [online]. 2ND edition. Monash University (Australia): OTexts, 2018 [cit. 2020-10-29]. ISBN 978-0987507112. Dostupné z: <https://otexts.com/fpp2/>
- [10] *What is a Rolling Forecast?* Planful [online]. [cit. 2021-4-25]. Dostupné z: <https://planful.com/blog/what-is-a-rolling-forecast/>
- [11] KROPÁČ, Jiří. *Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady*. 2., dopl. vyd. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009. ISBN 978-80-214-3295-6
- [12] CUESTA, Hector. *Analýza dat v praxi*. Přeložil Jiří HUF. Brno: Computer Press, 2015. ISBN 978-80-251-4361-2.
- [13] ŘEZANKOVÁ, Hana, Luboš MAREK a Michal VRABEC. *IASTAT - INTERAKTIVNÍ UČEBNICE STATISTIKY* [online]. [cit. 2021-02-09]. Dostupné z: <https://iastat.vse.cz/>

- [14] HINDLS, Richard, NOVÁK, Ilja a HRONOVÁ, Stanislava. Metody statistické analýzy pro ekonomy. Praha: Management Press, 2000. s. 137. ISBN 80-7261-013-9. Dostupné také z: <https://ndk.cz/uuid/uuid:a91e1f90-02b4-11e4-a680-5ef3fc9bb22f>
- [15] ARLT, Josef, ARLTOVÁ, Markéta, RUBLÍKOVÁ, Eva a Fakulta informatiky a statistiky. Analýza ekonomických časových řad s příklady. Praha: Oeconomica, 2004. s. 52. ISBN 80-245-0777-3. Dostupné také z: <https://ndk.cz/uuid/uuid:278fb801-2196-11e6-918e-5ef3fc9ae867>
- [16] RUD, Olivia Parr. Data Mining: praktický průvodce dolováním dat pro efektivní prodej, cílený marketing a podporu zákazníků (CRM). Praha: Computer Press, 2001. Databáze. ISBN 80-7226-577-6
- [17] KOMPRDOVÁ, Klára. Rozhodovací stromy a lesy. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-785-7
- [18] SKALSKÁ, Hana a Fakulta informatiky a managementu. Data mining a klasifikační modely. Hradec Králové: Gaudeamus, 2010. s. 90. ISBN 978-80-7435-088-7. Dostupné také z: <https://ndk.cz/uuid/uuid:d8b0e950-8928-11e8-bb44-5ef3fc9ae867>
- [19] TIMOFEEV, Roman. Classification and regression trees (CART) theory and applications. Humboldt University, Berlin, 2004, 1-40
- [20] TUČKOVÁ, Jana a Elektrotechnická fakulta. Úvod do teorie a aplikací umělých neuronových sítí. Praha: Vydavatelství ČVUT, 2003. s. 8. ISBN 80-01-02800-3. Dostupné také z: <https://ndk.cz/uuid/uuid:6f201711-dfa8-11e2-a0b3-5ef3fc9bb22f>
- [21] VESELÝ, Arnošt a Katedra informačního inženýrství. Úvod do umělé inteligence. V Praze: Česká zemědělská univerzita v Praze, Provozně ekonomická fakulta, 2005. s. 85. ISBN 80-213-1361-7. Dostupné také z: <https://ndk.cz/uuid/uuid:6f93cb70-0050-11e7-97b4-5ef3fc9ae867>
- [22] Matematická biologie učebnice: Koncept umělé neuronové sítě. Matematická biologie učebnice: Úvod [online]. [cit. 2021-01-30]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologicky-ch-dat--umela-inteligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--koncept-umele-neuronove-site>
- [23] Matematická biologie učebnice: Principy učení neuronu obecně. Matematická biologie učebnice: Úvod [online]. [cit. 2021-01-30] Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologicky-ch-dat-->

umela-inteligence--neuronove-site-jednotlivy-neuron--adaptacni-dynamika-neuronu--principy-uceni-neuronu-obecne

[24] DOSTÁL, Petr, RAIS, Karel a SOJKA, Zdeněk. Pokročilé metody manažerského rozhodování: konkrétní příklady využití metod v praxi. Praha: Grada, 2005. s. 51. ISBN 80-247-1338-1. Dostupné také z: <https://ndk.cz/uuid/uuid:94c37960-13e3-11e4-90aa-005056825209>

[25] FORBELSKÁ, Marie a Přírodovědecká fakulta. Stochastické modelování jednorozměrných časových řad. Brno: Masarykova univerzita, 2009. s. 240. ISBN 978-80-210-4812-6. Dostupné také z: <https://ndk.cz/uuid/uuid:02d8a590-004a-11e4-a680-5ef3fc9bb22f>

[26] Technický slovník naučný. Encyklopedický dům. sv. 4 s. 19. ISBN 80-86044-26-2. Dostupné také z: <https://ndk.cz/uuid/uuid:4e3ff253-8af0-483c-8b87-0cc010594c5a>

[27] JURÍČ, Darko. Object Tracking: Kalman Filter with Ease. Code Project: For those who code [online]. Kanada, 2015 [cit. 2021-4-25]. Dostupné z: <https://www.codeproject.com/Articles/865935/Object-Tracking-Kalman-Filter-with-Ease>

[28] WELCH, Greg a Gary BISHOP. An Introduction to the Kalman Filter. Chapel Hill, 2006. University of North Carolina, 2006. [cit. 2021-4-25]. Dostupné z: https://www.cs.unc.edu/~welch/media/pdf/kalman_intro.pdf

[29] ALMASI, Amin. Why Second Order Kalman Filter is needed for Advanced Vibration Monitoring. Turbomachinery [online]. 2011 [cit. 2021-4-25]. ISSN 1528-8900. Dostupné z: <https://www.turbomachinerymag.com/why-second-order-kalman-filter-is-needed-for-advanced-vibration-monitoring/>

[30] LEGÁT, Václav. Management a inženýrství údržby. Druhé doplněné vydání. Praha: Kamil Mařík – Professional Publishing, 2016. ISBN 978-80-7431-163-5.

[31] Analýza poruch technických zařízení a její přínos pro zvyšování spolehlivosti: Materiály z 38. setkání odborné skupiny pro spolehlivost [online]. Praha: Česká společnost pro jakost, 2010. [cit. 2021-01-30]. ISBN 978-80-02-02217-6. Dostupné z: https://www.csq.cz/fileadmin/user_upload/Spolkova_cinnost/Odborne_skupiny/Spolehlivost/Sborniky/Sbornik_192_38_Analyza_poruch.pdf

[32] KLIMEŠ, Pavel a Ústav konstruování. Části a mechanismy strojů, II: Tribologie, ložiska, převody. Brno: Akademické nakladatelství CERM, 2003. ISBN 80-214-2422-2. Dostupné také z: <https://ndk.cz/uuid/uuid:bbfc5d30-d357-11e2-92ff-001018b5eb5c>

- [33] HLUCHÝ, Miroslav a HANĚK, Václav. Strojírenská technologie 2, 2. díl: Koroze, základy obrábění, výrobní postupy. Praha: Scientia, 2001. ISBN 80-7183-245-6. Dostupné také z: <https://ndk.cz/uuid/uuid:f1c45c96-3ffb-4b24-94c5-f50d1a0221bb>
- [34] BILOŠ, Jan a Alena BILOŠOVÁ. Aplikovaný mechanik jako součást týmu konstruktérů a vývojářů: část Vibrační diagnostika. Ostrava: VŠB-TU Ostrava, 2012. ISBN 978-80-248-2755-1. Dostupné z: <http://projekty.fs.vsb.cz/147/ucebniopory/978-80-248-2755-1.pdf>
- [35] ŽENÍŠEK, David, Michal ŠIMON, Josef BASL a Peter POOR. Údržba v Průmyslu 4.0 dnes: Průmyslové inženýrství 2019: Mezinárodní studentská vědecká konference. Západočeská univerzita v Plzni. [cit. 2021-1-30]. doi:10.24132/PI.2019.08948.169-176
- [36] Zajištěnost údržby v koncepci Průmysl 4.0: materiály ze 72. semináře Odborné skupiny pro spolehlivost[online]. Praha: Česká společnost pro jakost, 2018. [cit. 2021-01-30]. ISBN 978-80-02-02819-2. Dostupné z: https://www.csq.cz/fileadmin/user_upload/Spolkova_cinnost/Odborne_skupiny/Spolehlivost/Sborniky/sbornik72.pdf
- [37] MIROSLAV, Krupa. Technická prognostika v kontextu prediktivní údržby. Automa: časopis pro automatizační techniku. Děčín: FCC Public, 2012, 2012(2), 16-19. [cit. 2021-4-25]. ISSN 1210-9592. Dostupné z: https://www.automa.cz/Aton/FileRepository/pdf_articles/9344.pdf
- [38] LEGÁT, Václav, Pavel FUCHS a Josef POŠTA. ÚDRŽBA ZAMĚŘENÁ NA BEZPORUCHOVOST (RCM) [online]. Praha: Česká společnost pro jakost, 2004. [cit. 2021-01-30]. Dostupné z: https://www.csq.cz/fileadmin/user_upload/Spolkova_cinnost/Odborne_skupiny/Spolehlivost/Sborniky/17_RCM.pdf
- [39] LIPOL, Lafayet Sultan a Jahirul HAQ. Risk Analysis Method: FMEA/FMECA in the Organizations. International Journal of Basic & Applied Sciences [online]. IJENS Publishers, 2011, 11(05), 49-57 [cit. 2021-01-30]. ISSN 2077-1223. Dostupné z: http://ijens.org/Vol_11_I_05/117705-3535-IJBAS-IJENS.pdf
- [40] ROSŮLEK, Lukáš, Online setkání s ředitelem (18.01.2021)
- [41] Procedura údržby Vitesco Technologies - CAP0607740 Údržba výrobních prostředků
- [42] Device manual: Vibration sensor with IO-Link interface. 2020. Dostupné také z: <https://www.ifm.com/mounting/80298004UK.pdf>
- [43] Vibrační senzor VVB011 [online]. Praha, 2020 [cit. 2021-4-25]. Dostupné z: <https://www.ifm.com/cz/cs/product/VVB011?tab=details>

[44] ZUTH, Daniel a František VDOLEČEK. Měření vibrací ve vibrodiagnostice. Automa: časopis pro automatizační techniku [online]. Děčín: FCC Public, 2010(1) [cit. 2021-4-25]. ISSN 1210-9592.

Dostupné z: <http://www.odbornecasopisy.cz/res/pdf/40375.pdf>

[45] JIROKOVSKÝ, Jaroslav. Online seminář Prediktivní údržba systému v prostředí MATLAB a Simulink. 21.4.2021

[46] Predictive Maintenance with MATLAB [online]. MathWorks [cit. 2021-4-25]. Dostupné z: <https://www.mathworks.com/content/dam/mathworks/ebook/gated/predictive-maintenance-ebook-all-chapters.pdf>

[47] MATLAB. Humusoft [online]. Praha [cit. 2021-4-25]. Dostupné z: <https://www.humusoft.cz/matlab/details/>

[48] JIRKOVSKÝ, Jaroslav. Analýza dat a vývoj algoritmů pro monitorování stavu zařízení a prediktivní údržbu v prostředí MATLAB. Humusoft [online]. Praha, 2019 [cit. 2021-4-25]. Dostupné z: <https://www.humusoft.cz/blog/20190724-prediktivni-udrzba/>

20 Seznam obrázků

- Obr 01 – Ukázka předpovědi s pohyblivým (klouzavým horizontem)
- Obr 02 – Struktura rozhodovacího stromu
- Obr 03 – Acyklická topologie neuronové sítě
- Obr 04 – Vizualizace cyklu Kalmanova filtru
- Obr 05 – Druhy opotřebení
- Obr 06- Princip prediktivní údržby
- Obr 07 – Metody prognostiky
- Obr 08 - Princip změn při aktivitách TPM
- Obr 09 – Schéma odsávacího zařízení Nederman a umístění senzorů na motoru a hřídeli
- Obr 10 – Fotografie ukazující reálné umístění senzorů
- Obr 11 – Parametry časového průběhu kmitavého pohybu – signálu
- Obr 12 – Uživatelské rozhraní ifm moneo
- Obr 13 – Časový průběh poruchy motoru
- Obr 14 – Průběh směrodatných odchylek a-Peak a crest faktoru před a po poruše
- Obr 15 – Průběh směrodatné odchylky a-RMS před a po poruše
- Obr 16 – Ifm moneo, vizualizace charakteristik ovlivněných prokluzujícím ozubeným řemenem
- Obr 17 – Grafy uvolněný řemen – a-RMS
- Obr 18 – Grafy uvolněný řemen –a a-Peak
- Obr 19 – Grafy uvolněný řemen – Crest faktor a v-RMS
- Obr 20 – Porovnání poruchových hodnot s bezporuchovým stavem a-RMS, v-RMS
- Obr 21 – Porovnání poruchových hodnot s bezporuchovým stavem a-RMS, Crest faktor
- Obr 22 – Confusion Matrix MATLAB

21 Seznam tabulek

Tab 01 – Tabulka příklady změn parametrů v závislosti na druhu závady

Tab 02 – měřicí rozsahy senzorů typu VVB011

Tab 03 – Nastavení prahových mezí – Nederman

Podklad pro zadání BAKALÁŘSKÉ práce studenta

Jméno a příjmení: **Miluše Machová**
Osobní číslo: **I1800094**
Adresa: **Spojenecká 123, Trutnov – Střední Předměstí, 54101 Trutnov 1, Česká republika**
Téma práce: **Predikční analýzy ve společnosti Vitesco Technologies**
Téma práce anglicky: **Prediction Analysis at Vitesco Technologies company**
Vedoucí práce: **prof. RNDr. PhDr. Antonín Slabý, CSc.**
Katedra informatiky a kvantitativních metod

Zásady pro vypracování:

Osnova:

Rešeršní a teoretická část

1. Úvod: Definice prediktivní analýzy, důležitost oblasti
2. Terminologie
3. Výběr z využitelných metod (Analýza časových řad, Klasifikační a regresní stromy, Neuronové sítě, Bayesovská síť ...)
4. Poruchy strojů
5. Strategie údržby
6. Vitesco Technologies – představení podniku

Praktická část

7. Získání dat z podniku Vitesco Technologies, zhodnocení, úpravy
8. Výběr metod
9. Demonstrace vybraných metod k parciální odpovědi
10. Porovnání a zhodnocení přístupů, výhod a nevýhod
11. Závěr

Seznam doporučené literatury:

- 1) MONTGOMERY, Douglas C., Cheryl L. JENNINGS a Murat KULAHCI. Introduction to time series analysis and forecasting. Second edition. Hoboken, New Jersey: Wiley, [2015]. ISBN 1118745116
- 2) KROPÁČ, Jiří. Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady. 2., dopl. vyd. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009. ISBN 978-80-214-3295-6
- 3) SIEGEL, Eric. Kdo klikne, koupí, lže nebo zemře: síla předpovědi pomocí prediktivní analytiky. Brno: BizBooks, 2014. ISBN 978-80-265-0168-8
- 4) SKALSKÁ, Hana. UNIVERZITA HRADEC KRÁLOVÉ. FAKULTA INFORMATIKY A MANAGEMENTU. Data mining a klasifikační modely. Hradec Králové: Gaudemus, 2010. 154 s.; 21 cm. ISBN 978-80-7435-088-7

5) VESELÝ, Arnošt a Katedra informačního inženýrství. Úvod do umělé inteligence. V Praze: Česká zemědělská univerzita v Praze, Provozně ekonomická fakulta, 2005. s. 88. ISBN 80-213-1361-7

Podpis studenta:

Datum:

Podpis vedoucího práce:

Datum:

© IS/STAG, Portál – Podklad kvalifikační práce, machomi2, 20. dubna 2021 18:38