



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

ÚSTAV AUTOMATIZACE A INFORMATIKY

INSTITUTE OF AUTOMATION AND COMPUTER SCIENCE

**ANALÝZA DAT CONDITION MONITORINGU PRO
POTŘEBY KEY PERFORMANCE INDICATORS (KPI)**

CONDITION MONITORING ANALYSIS FOR USE BY KEY PERFORMANCE INDICATORS (KPI)

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Jan Kelbl

VEDOUcí PRÁCE

SUPERVISOR

Ing. Michal Ježek

BRNO 2021

Zadání bakalářské práce

Ústav: Ústav automatizace a informatiky
Student: **Jan Kelbl**
Studijní program: Strojírenství
Studijní obor: Základy strojního inženýrství
Vedoucí práce: **Ing. Michal Ježek**
Akademický rok: 2020/21

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma bakalářské práce:

Analýza dat Condition Monitoringu pro potřeby Key Performance Indicators (KPI)

Stručná charakteristika problematiky úkolu:

Condition monitoring je nástroj, který umožňuje v reálném čase měřit a vizualizovat a dále také archivovat procesní a technologické veličiny. Tato data je možno následně využít pro stanovování Key Performance Indicators (KPI) daných výrobních prostředků. Úkolem práce je analýza reálných Condition monitoring dat získaných z vybraných výrobních strojů, stanovení trendů KPI těchto strojů a následně definování doporučení pro optimalizaci provozu těchto strojů.

Cíle bakalářské práce:

Rešerše v oblasti Condition Monitoring.
Rešerše v oblasti Key Performance Indicators (KPI).
Výběr vhodného SW produktu pro práci s daty a datovou analýzu.
Příprava dat získaných z Condition Monitoringu pro potřeby další analýzy.
Analýza dat a stanovení trendů KPI.
Vyhodnocení trendů KPI.
Návrh doporučení vyplývající z analýzy pro využití v praxi.

Seznam doporučené literatury:

PARMENTER, David. Key performance indicators: developing, implementing, and using winning KPIs. Third edition. Hoboken: Wiley, 2015. ISBN 9781118925102.

PROVOST, Foster a Tom FAWCETT. Data science for business: what you need to know about data mining and data-analytic thinking. Sebastopol: O'Reilly, 2013, xviii, 384 s. : grafy. ISBN 978-1-4-9-36132-7.

BEN-GAN, Itzik. Exam ref 70-761: querying data with Transact-SQL. published with the authorization of Microsoft Corporation by: Pearson Education, Inc., [2017]. ISBN 1509304339.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2020/21

V Brně, dne

L. S.

doc. Ing. Radomil Matoušek, Ph.D.
ředitel ústavu

doc. Ing. Jaroslav Katolický, Ph.D.
děkan fakulty

ABSTRAKT

Bakalářská práce se zabývá analýzou sekundárních dat z technologie condition monitoring za účelem stanovení a vyhodnocení klíčových ukazatelů výkonnosti, zkráceně KPI (z anglického *Key Performance Indicators*), a jejich trendů. První část práce se zaměřuje na řešení problematiky condition monitoring a klíčových ukazatelů výkonnosti. Dále je v teoretické části zahrnut průzkum trhu na poli softwarových produktů pro zpracování a analýzu dat. Praktická část bakalářské práce se zabývá výběrem vhodného softwarového produktu pro analýzu a vizualizaci dat, přípravou, zpracováním a analýzou dat, stanovením klíčových ukazatelů výkonnosti, vizualizací těchto ukazatelů, stanovením trendů ukazatelů a vztahů mezi jednotlivými ukazateli. Na základě výsledků z praktické části jsou vyvozena doporučení týkající se klíčových ukazatelů výkonnosti pro energetickou společnost, která poskytla data pro realizaci této bakalářské práce.

ABSTRACT

This bachelor's thesis deals with secondary Condition Monitoring data analysis to measure Key Performance Indicators (KPIs). First part of the thesis contains a research necessary to understand the problematics of condition monitoring technology and Key Performance Indicators. Also, the theoretical part includes a research on suitable data analysis software. The practical part of the thesis deals with choosing a data analysis software, data processing and data analysis and Key Performance Indicators measurement. Then visualizations are made and trends are measured. Based on the results from the practical part, a recommendation in matter of KPIs is made for the company, which provided the data, on which this bachelor's thesis was realized.

KLÍČOVÁ SLOVA

monitorování stavu, vibrodiagnostika, tribodiagnostika, průmyslový internet věcí, klíčový ukazatel výkonnosti, efektivita výroby, údržba

KEYWORDS

condition monitoring, vibration analysis, oil analysis, industrial internet of things, key performance indicator, production efficiency, maintenance



ÚSTAV AUTOMATIZACE
A INFORMATIKY



2021

BIBLIOGRAFICKÁ CITACE

KELBL, Jan. *Analýza dat Condition Monitoringu pro potřeby Key Performance Indicators (KPI)*. Brno, 2021. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/132804>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav automatizace a informatiky. Vedoucí práce: Ing. Michal Ježek.

PODĚKOVÁNÍ

Tímto děkuji panu Ing. Michalovi Ježkovi za ochotu vést tuto bakalářskou práci a za rady a připomínky během realizace práce. Také děkuji brněnské energetické společnosti za poskytnutí cenných informací a především dat, bez kterých by tato práce nemohla vzniknout.

ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že tato práce je mým původním dílem, vypracoval jsem ji samostatně pod vedením vedoucího práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury.

Jako autor uvedené práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následku porušení ustanovení § 11 a následujících autorského zákona c. 121/2000 Sb., včetně možných trestně právních důsledků.

V Brně dne 20. 5. 2021

.....

Jan Kelbl

OBSAH

1	ÚVOD.....	15
2	PŘEHLED SOUČASNÉHO STAVU POZNÁNÍ.....	17
2.1	Condition monitoring	17
2.1.1	Přístupy k monitorování stavu	17
2.1.2	Vývoj technik condition monitoring.....	18
2.1.3	Moderní trendy v oblasti condition monitoring.....	23
2.1.4	Condition monitoring ve spojení s údržbou	25
2.2	Key performance indicators.....	27
2.2.1	Používané klíčové ukazatele výkonnosti	28
2.3	Produkty a nástroje pro datovou analýzu	35
2.3.1	Python	35
2.3.2	MATLAB	36
2.3.3	R.....	37
2.3.4	Vývoj popularity zmíněných softwarových produktů	37
3	VLASTNÍ ŘEŠENÍ.....	38
3.1	Představení výrobních strojů a vyráběných součástí	38
3.2	Výběr nástrojů	39
3.2.1	Pro práci s daty a analýzu dat	39
3.2.2	Pro vizualizaci dat	40
3.3	Rozbor dostupných dat	41
3.4	Výběr vhodných klíčových ukazatelů výkonnosti.....	42
3.5	Příprava dat vzhledem k vybraným klíčovým ukazatelům výkonnosti	45
3.5.1	Postup při přípravě a zpracování dat	46
3.6	Vizualizace a stanovení trendů	49
3.6.1	Vizualizace klíčových ukazatelů výkonnosti	50
3.6.2	Stanovení trendů klíčových ukazatelů výkonnosti a vztahů mezi nimi.....	54
3.7	Vyhodnocení výsledků	56
3.7.1	Vyhodnocení trendů klíčových ukazatelů výkonnosti.....	56
3.7.2	Vyhodnocení vztahů mezi klíčovými ukazateli výkonnosti	57
3.7.3	Porovnání klíčových ukazatelů výkonnosti mezi stroji	57
3.8	Doporučení vyplývající z analýzy	57
4	ZHODNOCENÍ A DISKUZE.....	59
4.1	Použité nástroje.....	59
4.2	Použité metody	59
5	ZÁVĚR	61
6	SEZNAM POUŽITÉ LITERATURY.....	63
7	SEZNAM ZKRATEK, SYMBOLŮ, OBRÁZKŮ A TABULEK	65
8	SEZNAM PŘÍLOH.....	69

1 ÚVOD

Průběh činností z technického i netechnického světa může být popsán souhrnem informací – záznamem dat. V dnešní době plné počítačů, senzorů a technologií jako umělá inteligence a internet věcí je monitorování a záznam dat jednodušší než kdy předtím. Záznamem dat to pouze začíná. Zásadní přitom je proměnit zaznamenaná data v něco smysluplného a jasně vypovídajícího, v něco, co napomůže jedinci nebo společnosti posunout svoji činnosti o krok dál. Jednou z technologií, která se zabývá sběrem a také vyhodnocením dat, je condition monitoring.

Zadání bakalářské práce vzniklo ve spolupráci s brněnskou energetickou společností vyrábějící turbíny. Tato společnost v rámci zavedené technologie condition monitoring sbírá také data, která nejsou přímo určena k monitorování stavu strojů, jsou však se stavem strojů úzce spojená. Jedná se o takzvaná sekundární data. Cílem bakalářské práce je proměnit sekundární data technologie condition monitoring dvou strojů v klíčové ukazatele výkonnosti.

V úvodní teoretické části bakalářské práce je provedena rešerše současného stavu poznání v oblasti technologie condition monitoring a dále v oblastech klíčových ukazatelů výkonnosti a softwarových produktů pro práci s daty. V navazující praktické části je proveden výběr vhodného softwarového produktu pro práci a analýzu dat, rozbor dostupných dat z výrobních strojů, výběr vyhodnotitelných ukazatelů a samotná příprava a zpracování dat za účelem stanovení klíčových ukazatelů výkonnosti. V rámci přípravy a zpracování dat jsou vytvořeny komentované postupy, které mohou sloužit například jako návody a ukázky základní práce s daty. Dále jsou stanoveny vybrané klíčové ukazatele výkonnosti, které jsou následně vizualizovány ve formě dashboardů. Také jsou stanoveny trendy klíčových ukazatelů výkonnosti a vztahy mezi jednotlivými ukazateli. Výsledky jsou na závěr praktické části vyhodnoceny a jsou vyvozena doporučení pro další využití v praxi.

2 PŘEHLED SOUČASNÉHO STAVU POZNÁNÍ

2.1 Condition monitoring

Pod pojmem condition monitoring, česky monitorování stavu, rozumíme měření specifických parametrů stroje. Měření mohou být například vibrace, teplota jednotlivých částí stroje, spotřebovaná elektrická energie, stav maziva, provozní stav a další parametry, které reflektují stav stroje. Technologie condition monitoring umožňuje sledovat jakékoliv výrazné změny a odchylky od nominálního stavu. Průběžné monitorování stavu stroje a rozpoznání anomálií, které stroj vykazuje a které by mohly vést ke snížení provozuschopnosti tohoto stroje, umožňuje efektivní plánování údržby stroje a dalších kroků k zajištění bezporuchového provozu [1].

Data nashromážděná pomocí technologie condition monitoring v průběhu let poskytují cenné informace nejen o aktuálním stavu zařízení, ale také o vývoji stavu v čase. Historický vývoj může sloužit k předvídaní vývoje budoucího a možných budoucích problémů. Taková předpověď slouží především k plánování údržby známé pod pojmem prediktivní údržba, tedy údržba založená na predikci poruch z historických dat [1].

Condition monitoring se využívá primárně pro sledování stavu zařízení, jejichž některé části konají rotační pohyb. Mezi ně patří například převodovky, pístové stroje, odstředivé stroje a zařízení jako jsou elektromotory, kompresory, spalovací motory a další [1].

Monitorování stavu strojů se řídí dle norem ISO. V českém prostředí jde například o normy ČSN ISO 13372, ČSN ISO 18436, ČSN ISO 17359, ČSN ISO 13381.

Využití technologie condition monitoring nejen v průmyslovém podniku může znamenat řadu výhod. Mezi největší výhody patří snížení nákladů na údržbu, snížení prostojů a prodloužení životnosti strojů [1].

2.1.1 Přístupy k monitorování stavu

Z hlediska pravidelnosti jsou dle [1] rozeznávány dva přístupy v oblasti monitorování stavu stroje:

- sledování trendu
- kontrola stavu

Sledováním trendu se rozumí nepřetržité měření a interpretace vybraných parametrů. Klíčovým předpokladem je výběr vhodného parametru pro měření. Takový parametr musí splňovat několik podmínek. Musí být měřitelný a musí se v něm odrážet stav zařízení. Sledování trendu se využívá například v leteckém průmyslu u letadlových motorů za účelem detekce a diagnostiky abnormalit v chodu motoru, aby se předešlo poruchám, které by mohly mít katastrofické následky [1].

Kontrola stavu je přístup založený na kontrolním měření parametrů během chodu stroje v pravidelných intervalech. To slouží k monitorování stavu stroje v daném čase. Příkladem využití této metody je kontrola stavu maziva zařízení v reálném čase pomocí skleněného průhledítka [1].

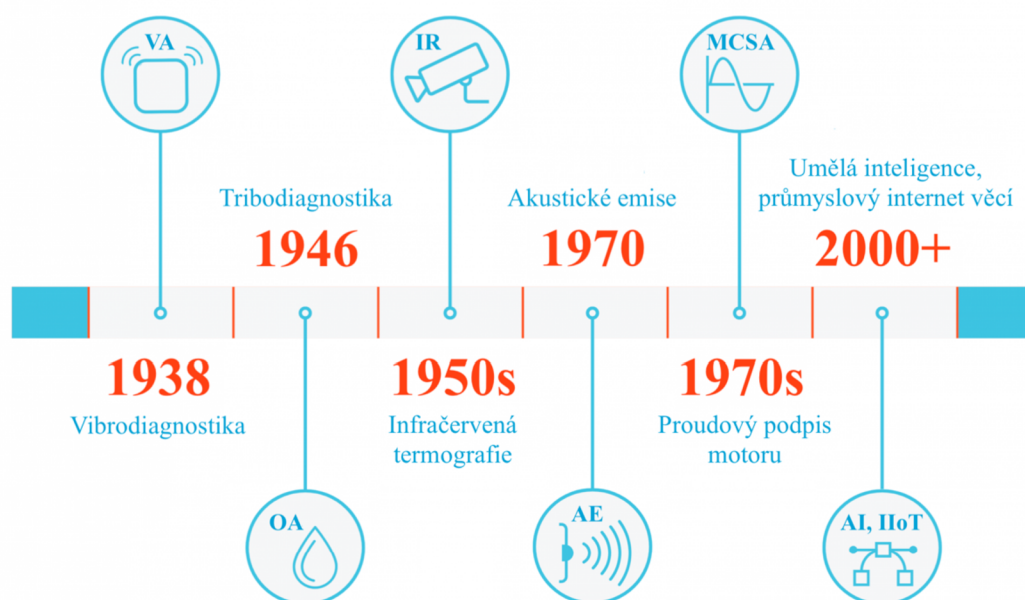
Monitorování stavu strojů a záznam monitorovaných parametrů na základě výše uvedených přístupů poskytuje technikům přehled o tom, jak zařízení a komponenty zařízení aktuálně fungují a jak se jejich stav v čase vyvíjel [1].

2.1.2 Vývoj technik condition monitoring

Existuje řada technik monitorování stavu strojů. V této části bakalářské práce jsou představeny a časově zařazeny ty nejvyužívanější z nich. Patří mezi ně:

- vibrodiagnostika
- tribodiagnostika
- infračervená termografie
- testování ultrazvukem
- akustické emise
- proudový podpis motoru

Historický vývoj technik monitorování stavu je znázorněn na obrázku č. 1. Z obrázku je zřejmé, že počátek monitorování stavu strojů se datuje do roku 1938.



Obr. 1: Vývoj technik monitorování stavu [2]

Vibrodiagnostika

Vibrodiagnostika, jinak vibrační analýza, zkráceně VA (z anglického *vibration analysis*), je obecně považována za první techniku, která umožňovala monitorovat stav stroje a na základě toho varovat před poruchou. První vědecká práce zabývající se analýzou vibrací jako nástrojem pro monitorování stavu strojů byla publikována roku 1938 vědcem T.C. Rathbonem [2].

Senzory pro monitorování vibrací jsou umístěny na monitorované součásti. Vibrační analýza spočívá v měření úrovně vibrací a frekvencí stroje a jeho komponent. Následuje vyhodnocení těchto dat za účelem určení stavu stroje. Vibrodiagnostika dokáže odhalit problémy jako jsou: nevyváženost stroje, porucha ložisek, nesouosost, porucha elektromotoru, porucha hřídele, porucha převodovky, rezonance, kavitace. Odhaduje se, že skutečné selhání komponenty stroje lze pomocí vibrodiagnostiky předvídat až tři měsíce dopředu [1, 2].

Vibrace jsou jedním z nejvhodnějších parametrů pro měření a analýzu stavu stroje, což dokazuje skutečnost, že nadprůměrná většina condition monitoring systémů je založena na vibrační analýze. Vibrace znázorňují pohyb těla stroje. Jde o kmitání stroje kolem střední polohy. Kmitání může být periodické a neperiodické a může být popsáno ve všech směrech. Stupeň volnosti tělesa určuje počet nezávislých souřadnic, kterými lze popsat pohyb tuhého tělesa. Tuhé těleso má obecně 6 stupňů volnosti: tři translační pohyby v osách x, y, z a tři rotační pohyby kolem těchto os. U většiny výrobních strojů jsou vibrace měřeny ve třech směrech. Vibrace lze měřit z pohledu výchylky, rychlosti nebo zrychlení [3].

Oproti ostatním technikám má vibrodiagnostika řadu výhod. Okamžitě reaguje na změny a díky tomu lze tuto techniku využít nejen pro monitorování stavu v pravidelných intervalech, ale i pro permanentní monitorování stavu. Pokud srovnáme vibrodiagnostiku s tribodiagnostikou (další rozšířenou technikou monitorování stavu), pak jsou výhody zřejmé. Proces tribodiagnostiky může trvat až několik dní od odebrání vzorku po jeho vyhodnocení v laboratoři, kdežto vibrace jsou vyhodnocovány okamžitě. U vibrodiagnostiky je pravděpodobnější, že poukáže na skutečně vadnou součást, protože dokáže monitorovat například konkrétní ložisko, které vykazuje zvýšené vibrace. Tribodiagnostika sice odhalí problém, ale nebude zřejmé, které z ložisek je skutečně vadné. Jednou z hlavních výhod vibrodiagnostiky je existence velkého množství metod zpracování signálu, které mohou být použity pro analýzu vibrací. Tyto metody dokáží extrahovat a zpracovat i velmi slabé indikace počínajících poruch [4].

Monitorování stavu stroje na základě vibrací může probíhat dle [4] permanentně nebo v pravidelných intervalech.

Permanentní monitorování se využívá k případnému vypnutí stroje v reakci na náhlé změny ve vibracích. Svým charakterem je primárně využíváno u kritických a drahých strojů, aby se zabránilo katastrofickému selhání stroje. Permanentní monitorování se zaměřuje na sledování relativně jednoduchých parametrů, které rychle reagují na změny. Pro měření vibrací se obvykle využívají bezkontaktní sondy a akcelerometry. Výhodou permanentního monitorování je ochrana před náhlými

poruchami, které nelze předvídat. Nevýhodou jsou vysoké náklady na provoz takového systému [4].

U většiny výrobních strojů není ekonomicky výhodné opatřit je permanentně monitorovacími systémy. Protože hlavním ekonomickým přínosem monitorování stavu stroje je schopnost předvídat selhání stroje a na základě toho plánovat údržbu, není permanentní monitorování tak důležité. Místo toho je vhodné využít monitorování v pravidelných intervalech [4].

Monitorování stroje v **pravidelných intervalech** se využívá k varování před možným vznikem poruchy v delším časovém horizontu. Tento způsob monitorování má v praxi větší oblibu než permanentní monitorování. Využívá se především ve společnostech, kde není hlavním ekonomickým faktorem cena stroje, ale plynulost výroby. Tento způsob monitorování je obvykle založen na analýze zrychlení vibrací, které je získáno z akcelerometrů. Výhodou oproti permanentnímu monitorování jsou nižší náklady na provoz monitorovacího systému a potenciál obdržet varování před poruchou s dostatečným předstihem. Nevýhodou je neschopnost reagovat na náhlou nepředvídatelnou poruchu [4].

Tribodiagnostika

Tribodiagnostika, jinak analýza maziv, zkráceně OA (z anglického *oil analysis*), byla poprvé použita roku 1946 v železničním průmyslu ve Spojených státech amerických. Účelem bylo analyzovat maziva vznětových motorů a na základě analýzy stanovit opotřebení součástí motorů. Použitá maziva byla prověřena pomocí spektrometru. Spektrometr dokázal v mazivu detekovat chemické prvky jako je železo nebo měď. Na základě množství nežádoucích chemických prvků v mazivu bylo stanoveno opotřebení součástí motorů [2].

V dnešní době se tribodiagnostika běžně používá ke zjištění stavu a znečištění maziv a ke stanovení míry opotřebení strojů. Proces zahrnuje analýzu vlhkosti maziva, stanovení množství chemických prvků v mazivu, stanovení kyselosti a zásaditosti maziva a měření viskozity. Vysoký obsah křemíku a hliníku v mazivu může znamenat kontaminaci nečistotami. Vysoký obsah železa může znamenat opotřebení součástí stroje [1].

Základními předpoklady pro správnou analýzu maziva jsou dle [5]:

- přesnost a reprezentativnost vzorku maziva
- použití vhodných a opakovatelných analytických metod
- přesná interpretace výsledků a ověření výsledků

Využití tribodiagnostiky je vhodné v hlučném a vibrujícím prostředí, pro stroj s jedním motorem, pro stanovení mechanických poruch, pro stroje poháněné stejnosměrným proudem, pro rotační stroje s malou úhlovou rychlostí. Použití není vhodné u špatně přístupných a nepřístupných strojů a u strojů, které jsou umístěny

v nepříznivých podmínkách. Dále není vhodné využití pro odhalení netěsností a poruch elektrického charakteru [6].

Tribodiagnostika může být provedena několika způsoby. Dle [4] patří mezi nejčastěji používané:


- **Využití detektorů odštěpků:** Pro tento způsob analýzy jsou speciálně navrženy filtry a magnetické zátky. Ty zadržují odštěpky, třísky a další nečistoty v mazivu, které cirkuluje systémem. Odštěpky jsou poté analyzovány. Zjišťuje se u nich množství, typ, tvar, velikost a další parametry. Na základě těchto parametrů mohou být vyvozeny závěry o stavu stroje [4].
- **Spektrografická analýza:** V pravidelných intervalech je odebírán vzorek maziva, který je následně podrobován spektrografické chemické analýze. Pomocí detekce stopových prvků v mazivu může být zjištěno opotřebení materiálů. Stopovými prvky mohou být legující prvky v ocelích, bronz a další. Dále může být pomocí spektrografické analýzy zjištěn únik kapaliny například z klikové skříně motoru. Únik chladicí kapaliny je charakteristický nárůstem chloridu sodného a dalších chemikálií, které pocházejí z chladicí kapaliny. Analýza maziva pomocí spektrografické analýzy zahrnuje také analýzu pozůstatků po opotřebení částí stroje, nečistot a přísad, dále měření viskozity a degradace maziva [4].
- **Ferografie:** Pod ferografií se rozumí mikroskopické zkoumání a analýza nečistot, které byly zadrženy působením magnetického pole. Nečistoty mohou obsahovat i nemagnetické částice, které byly zachyceny magnetickými částicemi. Mezi důležité zkoumané parametry patří množství, tvar a velikost částic. Tyto informace slouží k odhalení charakteru a místa selhání [4].

Infračervená termografie

Infračervená termografie, zkráceně IR (z anglického *infrared thermography*), byla poprvé využívána v 50. letech 20. století pro vojenské účely. Technologie termálních kamer byla pro civilní použití povolena až v 90. letech 20. století a byla založena na původní infračervené termografii z 50. let [2].

Tato technika spočívá v detekci tepelného záření pomocí termálních kamer. Cílem infračervené termografie je zajištění bezporuchového chodu stroje tím, že jsou odhaleny jakékoliv tepelné výchylky ve stroji, které mohou indikovat blížící se poruchu. Tato technika se používá k monitorování motorů, ložisek, izolace a dalších tepelně namáhaných komponent [1].

Využití termální kamery je znázorněno na obrázku č. 2. Kamera slouží k monitorování tepelného zatížení ložisek. Vyšší teplota jednoho ložiska oproti druhému je znázorněna červenou barvou a může znamenat poruchu ložiska.



Obr. 2: Příklad využití termální kamery pro monitorování ložisek [7]

Ultrazvuk

Diagnostika ultrazvukem je vhodná pro nízko a vysokorychlostní komponenty strojů. Digitální ultrazvukový měřič měří signály o vysoké frekvenci emitované z komponent stroje, kterými mohou být například ložiska. Tyto signály jsou reálném čase digitálně zobrazovány. Ultrazvuková technika monitorování stavu komponent strojů se často využívá spolu s vibrační analýzou [1].

Pro condition monitoring se ultrazvuk používá například v rámci metody rázových pulzů, zkráceně SPM (z anglického *shock pulse method*). Když dojde ke kontaktu dvou kovových objektů, začne se materiálem šířit tlaková vlna. Vlna narazí na senzor rázových pulzů a způsobí zpětný pohyb hmoty senzoru. Platí, že se zvětšující se vrstvou maziva na rozhraní materiálů klesá velikost rázového pulsu. Tato metoda je hojně využívaná pro stanovení správných intervalů mazání [1].

Akustické emise

Technika monitorování stavu zařízení pomocí akustických emisí se poprvé objevila v roce 1970. Tato technika monitorování stavu využívá senzorů umístěných na zařízení (přenos strukturou materiálu), nebo v jeho těsné blízkosti (přenos vzduchem). Sensory detekují a zaznamenávají zvukové vlny, které by mohly být způsobeny opotřebením součástí stroje. Frekvence takových vln jsou ve většině případů mimo rozsah vnímatelný lidským uchem [2].

Analýza akustických emisí spadá pod vibrační analýzu. Oproti vibrační analýze se liší tím, že jde o vibrace s mnohem větší frekvencí [1].

Proudový podpis motoru

Analýza proudového podpisu motoru, zkráceně MCSA (z anglického *motor current signature analysis*), pro monitorování stavu zařízení byla poprvé použita v 70. letech 20. století. Tento způsob monitorování stavu byl vyvinut pro využití v jaderných

elektrárnách, kde nebyla možná aplikace jiných technik. Tato technika je založena na skutečnosti, že proud odebíraný motorem obsahuje důležité informace o stavu stroje, jež motor řídí. Senzory snímající elektrický proud jsou umístěny mezi zdrojem a motorem. Tímto způsobem je možné analyzovat nejen stav zařízení, ale také spotřebu elektrické energie a účinnost procesu [2].

2.1.3 Moderní trendy v oblasti condition monitoring

Všechny výše jmenované techniky byly ve své době velmi náročné, protože vyžadovaly ruční sběr dat ze strojů a vysoce kvalifikované odborníky, kteří sbíraná data analyzovali a prezentovali. Rychlý vývoj informačních technologií na přelomu 20. a 21. století vedl k automatizaci analýz v reálném čase, nepřetržitému sběru a vyhodnocování obrovského množství dat, které je průběžně shromažďováno například pomocí bezdrátových senzorů. Od té doby se využívá technologií jako je umělá inteligence, zkráceně AI (z anglického *artificial intelligence*), nebo průmyslový internet věcí, zkráceně IIoT (z anglického *industrial internet of things*) [2].

Průmyslový internet věcí a condition monitoring

Průmyslový internet věcí představuje síť vzájemně propojených zařízení na mechanických a digitálních strojích. Tato zařízení umožňují přenášet data přes rozsáhlé sítě bez nutnosti zásahu člověka. Moderní systémy condition monitoring využívají průmyslový internet věcí k integraci mnoha monitorovacích softwarů do jednoho systému v reálném čase, odkudkoliv na světě a napříč zařízeními [1].

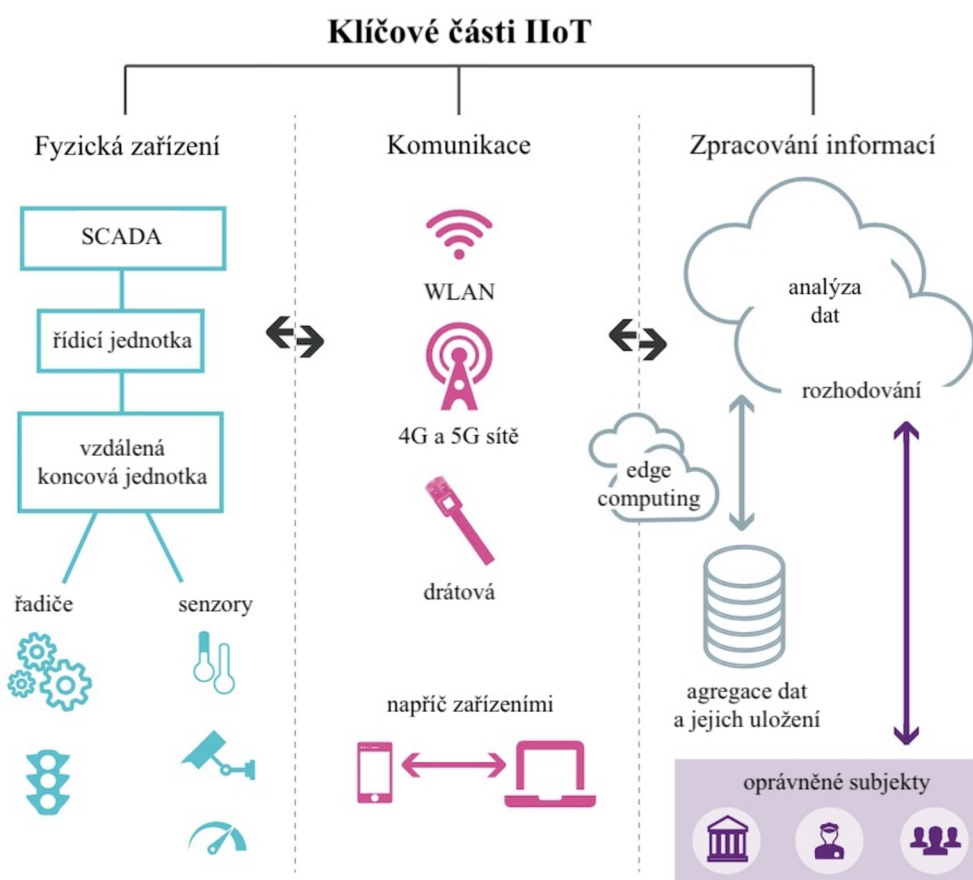
Systémy condition monitoring využívající průmyslový internet věcí umožňují společně jednoduše sledovat řadu aspektů všech jejich výrobních strojů. Mezi ně patří například monitorování výkonu stroje, detekce blížící se poruchy a plánování údržby na základě předem stanovených parametrů [1]. Mezi největší výhody využití průmyslového internetu věcí ve spojení se systémem condition monitoring patří dle [1]:

- **Cloudové úložiště:** Průmyslový internet věcí využívá takzvaného *cloud computing*, což společně umožňuje ukládat velké množství dat na cloudu na rozdíl od ukládání dat přímo ve společnosti nebo v datových centrech. To je velkou výhodou především kvůli neustálému toku dat ze strojů připojených k online monitorovacím systémům. Výzkum ukazuje, že při monitorování jedné větrné turbíny průměrně dochází ke dvěma tisícům odečtů za minutu, což odpovídá zhruba jednomu terabytu dat týdně [1].
- **Sofistikovaná analýza:** Systémy condition monitoring založené na průmyslovém internetu věcí využívají algoritmů strojového učení ke stanovování závěrů o věcech, jako je stav stroje, a způsobech, jak zvýšit přesnost diagnostiky [1].
- **Schopnost využití dat z více strojů:** Algoritmy strojového učení potřebují dostatek informací k vytvoření prediktivního modelu, a proto je zapotřebí

značné množství dat. K vytvoření dostatečně přesného modelu může být potřeba až sto stejných poruch na stroji, aby se prediktivní model naučil rozpoznávat například úroveň vibrací, které dané poruše předcházejí. Shromažďování údajů z více strojů stejného typu tak umožňuje získat potřebné množství dat za kratší dobu. Shromažďování dat z více strojů také zvyšuje přesnost a úspěšnost prediktivního modelu [1].

- **Snížený podíl lidské činnosti:** Monitorovací systémy založené na průmyslovém internetu věcí umožňují vzdálené monitorování stovek průmyslových strojů z jakéhokoli místa a na více zařízeních. Systémy umí automaticky sbírat, agregovat a distribuovat data v reálném čase technikům po celém světě [1].

Obrázek č. 3 znázorňuje tři základní části správně integrovaného průmyslového internetu věcí. Každý systém musí mít přizpůsobená fyzická zařízení, ze kterých pochází data. Dále musí být zajištěna komunikace mezi zařízeními a systémem pomocí vysokorychlostního internetového připojení. V neposlední řadě musí mít systém správně nastavené modely pro analýzu dat a jejich vyhodnocení [8].



Obr. 3: Klíčové části IIoT [8]

2.1.4 Condition monitoring ve spojení s údržbou

Údržba na základě stavu stroje, zkráceně CBM (z anglického *condition-based maintenance*), neboli prediktivní údržba [4], je přístup k údržbě založený na monitorování stavu strojů v reálném čase pomocí technologie condition monitoring. Na rozdíl od běžné preventivní údržby, která spočívá v plánování údržby v předem daných časových intervalech, je údržba na základě kondice stroje prováděna až v okamžik, kdy ukazatele vykazují odchylky od nominálního stavu nebo známky poklesu výkonnosti stroje [9].

Hlavním smyslem údržby na základě stavu stroje je, že díky brzkému odhalení blížící se poruchy a díky nepřetržitému monitorování kritických indikátorů lze proaktivně naplánovat údržbu, než dojde k výraznému poklesu výkonnosti stroje nebo samotnému selhání stroje [9].

Hlavní rozdíly mezi běžnou preventivní a prediktivní údržbou shrnuje dle [9] následující tabulka.


Tab. 1: Srovnání CBM s preventivní údržbou

	Preventivní údržba	CBM
Definice	Údržba je plánována a prováděna v pravidelných předem stanovených intervalech.	Údržba je prováděna, jakmile systém zaznamená anomálie.
Podnět k údržbě	naplánované datum	anomálie v měření
Náklady	střední	střední až vyšší při spuštění systému
Výhody	Údržba je plánována dopředu.	Údržba je prováděna pouze v případě potřeby.
	Je omezen prostoj stroje.	Snižuje počet neplánovaných prostojů.
	Je možná automatizace provádění úkonů údržby.	Zvětšuje produktivitu stroje.
Nevýhody	Je prováděno více údržby, než je třeba.	vysoké počáteční náklady
	časová náročnost	složitost výběru správného monitorovacího systému

P–F křivka

Důležitým pojmem v oblasti údržby a monitorování stavu strojů je takzvaná P–F křivka. Její název je odvozen z anglického *potential failure – functional failure*. Obrázek č. 4 zachycuje P–F křivku. Graf zobrazuje obecně stav aktiva (například výrobního stroje) v průběhu času. Nejdůležitější částí P–F křivky je P–F interval, tedy interval mezi potenciálním selháním (P) a funkčním selháním (F). Potenciální selhání je definováno jako okamžik, ve kterém se aktivum začíná zhoršovat nebo selhávat. Funkční selhání je definováno jako okamžik, ve kterém aktivum přestalo být funkční. P–F interval hraje důležitou roli při stanovování intervalu pro monitorování stavu strojů. Hlavním předpokladem pro bezporuchové fungování stroje je, že interval monitorování stavu stroje musí být kratší než P–F interval [1].

Na P–F křivce jsou znázorněny body, které označují techniku monitorování stavu, která v daný okamžik dokáže odhalit blížící se poruchu. V grafu je také znázorněno, jak s postupem času roste energetická náročnost provozu zařízení a náklady na jeho opravu. Osa x představuje čas a na ose y je znázorněn stav aktiva.



Obr. 4: P–F křivka [10]

2.2 Key performance indicators

Klíčové ukazatele výkonnosti, zkráceně KPI (z anglického *key performance indicators*), jsou indikátory, které se zaměřují na aspekty společnosti, jež jsou kritické pro stávající a budoucí úspěch společnosti. Vedoucí pracovníci využívají klíčových ukazatelů výkonnosti k pochopení, zda je jejich společnost na dobré cestě. Správný výběr klíčových ukazatelů výkonnosti osvětlí výkon společnosti a zvýrazní oblasti, ve kterých je potřeba provést změny za lepším fungováním společnosti [11, 12]. Důležitost klíčových ukazatelů výkonnosti a jejich interpretace při dosahování cílů ve společnosti je znázorněna na obrázku č. 5. Pro klíčové ukazatele výkonnosti platí dle [11] následující charakteristiky:

- **Pravidelné měření:** Klíčové ukazatele výkonnosti jsou monitorovány pravidelně a co nejčastěji tak, aby dokázaly reflektovat skutečný stav a vývoj.
- **Zájem ředitele a managementu společnosti:** Klíčový ukazatel výkonnosti je metrika, která je reportována především řediteli a managementu společnosti. To jsou lidé, kteří dokáží vyhodnotit situaci a reagovat na ni.
- **Jednoduchost:** Klíčové ukazatele výkonnosti jasně poukazují na to, jaké kroky je potřeba podniknout k lepšímu fungování společnosti. Měl by jim porozumět každý zaměstnanec.
- **Týmovost:** Odpovědnost za vývoj klíčových ukazatelů výkonnosti lze svázat s týmem nebo skupinou týmů, které spolu úzce spolupracují.
- **Významný dopad:** Klíčový ukazatel výkonnosti může ovlivnit jeden nebo více kritických faktorů úspěchu. Má zásadní dopad na společnost.

Klíčové ukazatele výkonnosti se dají dle [12] rozdělit podle oblasti zaměření do několika dílčích skupin. Jedná se o zaměření na:

- finance
- zákazníky
- marketing a prodej
- výrobu, provoz a dodavatelský řetězec
- zaměstnance
- sociální odpovědnost

Existuje celá řada klíčových ukazatelů výkonnosti, které jsou považovány za standardní. To ovšem neznamená, že jsou všechny ukazatele použitelné pro všechny společnosti. Může se dokonce stát, že žádný ze „standardních“ ukazatelů pro dané požadavky měření nebude existovat. V takovém případě lze definovat postup stanovení vlastního klíčového ukazatele výkonnosti, je však nutné vzít v úvahu jisté náležitosti, mezi které patří dle [13] zejména:

- **Definice problému:** Každý klíčový ukazatel výkonnosti musí mít jasně definovaný cíl. Předem musí být zodpovězeny otázky: Čeho má být dosaženo? Je to dosažitelné? Cíl musí být číselně vyjádřitelný.
- **Objektivnost:** Je velmi důležité objektivně měřit postup k dosažení cíle. To znamená správně nastavit sběr a interpretaci dat.
- **Sběr dat:** Musí existovat jasně definovaný zdroj dat s jasným postupem měření a shromažďování dat.
- **Interpretace:** Interpretace dat je stejně důležitá jako samotný sběr dat. Různé klíčové ukazatele výkonnosti budou mít různé frekvence hlášení. K hlášením by mělo docházet obvykle týdně, nebo měsíčně.



Obr. 5: Postavení KPI při dosahování cílů ve společnosti [14]

2.2.1 Používané klíčové ukazatele výkonnosti

V této podkapitole budou představeny a vysvětleny základní a v praxi běžně používané klíčové ukazatele výkonnosti se zaměřením na efektivitu výroby a údržbu strojů

Efektivita výroby

Propustnost

Propustnost je jedním ze základních klíčových ukazatelů výkonnosti ve výrobním průmyslu a také jedním z nejdůležitějších. Propustnost měří výrobní kapacitu strojů, výrobní linky nebo celého závodu. Propustnost THP je definována jako celkový počet vyrobených kusů x_{total} za čas t [13].

$$THP = \frac{x_{total}}{t} \quad (1)$$

Zmetkovitost

Zmetkovitost představuje metriku, která sleduje podíl zmetků, vůči celkovému množství vyrobených kusů. Zmetkovitost poskytuje společnosti přehled o poměru zmetků ve výrobním cyklu a pomáhá odhalit neefektivní výrobní proces. Zmetkovitost SCP je definována jako celkový počet zmetků x_{scap} vůči celkovému počtu vyrobených kusů x_{total} [13].

$$SCP = \frac{x_{scap}}{x_{total}} \quad (2)$$

Doba cyklu

Dalším z velmi jednoduchých přitom zásadních klíčových ukazatelů výkonnosti je doba cyklu. Doba cyklu je ve výrobním průmyslu představuje průměrnou dobu výroby jednoho kusu výrobku. Doba cyklu se může měřit jako doba výroby finálního produktu, nebo pouze jako doba výroby části produktu. V krajním případě může zahrnovat až doručení k zákazníkovi. Obecně může být doba cyklu t_{cycle} definována jako rozdíl mezi koncovým časem cyklu t_{finish} a počátečním časem cyklu t_{start} [13].

$$t_{cycle} = t_{finish} - t_{start} \quad (3)$$

Doba přechodu

Tento ukazatel výkonnosti představuje dobu potřebnou k přechodu mezi dvěma úkoly. Ve výrobě typicky představuje dobu potřebnou k přechodu mezi výrobou dvou různých výrobků. Také může představovat čas, k jehož ztrátě dojde při výměně operátorů výrobního stroje. Doba přechodu t_{change} je definována jako rozdíl čistého dostupného času t_{net} a doby výroby $t_{production}$ [13].

$$t_{change} = t_{net} - t_{production} \quad (4)$$

Doba taktu

Doba taktu je velmi důležitá při plánování výrobních zakázek. Doba taktu je maximální přípustná doba na výrobu jednoho výrobku při dodržení stanoveného termínu. Tento ukazatel je velmi podobný době cyklu, nelze je ovšem zaměnit. Doba taktu je definována jako podíl čistého dostupného času t_{net} a poptávaného množství x_{demand} [13].

$$t_{takt} = \frac{t_{net}}{x_{demand}} \quad (5)$$

Celková účinnost zařízení

Celková účinnost zařízení, zkráceně OEE (z anglického *overall equipment effectiveness*) je považována za zlatý standard pro posuzování produktivity výroby. Čím větší je celková účinnost zařízení, tím lepší je produktivita zařízení. OEE se dá vyčíslit jako součin dostupnosti A , výkonu P a kvality Q . Míra je dána v procentech. Stoprocentní celková účinnost zařízení znamená, že zařízení vyrábí 100 % času na 100 % kapacity se stoprocentní jakostí [13]. Frekvence vyhodnocení této metriky by měla být prováděna na týdenní, nebo měsíční bázi [12].

$$OEE = A \cdot P \cdot Q \quad (6)$$

Dostupnost A v rovnici vyjadřuje ztráty ve výrobě způsobené prostojem stroje a je definována jako podíl doby výroby $t_{production}$ a plánované doby výroby $t_{planned}$. Výkon P vyjadřuje ztráty v rychlosti výrobního procesu a je definován jako součin celkového počtu vyrobených kusů x_{total} a podílu ideální doby cyklu t_{ideal} a doby výroby $t_{production}$. Kvalita Q v rovnici vyjadřuje pokles na kvalitě při výrobě a je definována jako podíl počtu vyrobených kusů vhodné jakosti $x_{quality}$ a celkový počet vyrobených kusů x_{total} [12].

$$A = \frac{t_{production}}{t_{planned}} \quad (6a)$$

$$P = \frac{t_{ideal}}{t_{production}} \cdot x_{total} \quad (6b)$$

$$Q = \frac{x_{quality}}{x_{total}} \quad (6c)$$

Výtěžek prvního průchodu

Výtěžek prvního průchodu, zkráceně FPY (z anglického *first pass yield*), je jedním ze základních výrobních KPI, protože vyjadřuje, jak účinný je výrobní proces. Vypočítává procento výrobků vyrobených bezchybně na poprvé v průběhu procesu. To jsou výrobky, které nejsou zmetky a není nutné je přepracovat nebo vyhodit. Výtěžek prvního průchodu kroku n výroby FPY_n je definován jako podíl počtu vyrobených kusů vhodné jakosti $x_{quality}$ a celkového počtu vyrobených kusů x_{total} [13].

Společnosti se snaží o dosažení maximální hodnoty FPY. Ideální případ je dosažení 100 %. Například výrobce automobilů Toyota se pravidelně snaží dosáhnout

období dvanácti měsíců se stoprocentní mírou FPY, což mimo jiné odpovídá hodnotě Six Sigma 5 a větší [12].

$$FPY_n = \frac{x_{quality}}{x_{total}} \quad (7a)$$

Pokud se výrobní proces skládá z několika diskrétních kroků n , pak je metrika pro celý proces $FPY_{process}$ definována následovně:

$$FPY_{process} = \left(\prod_1^n FPY_n \right) \quad (7b)$$

Six Sigma

Metrika Six Sigma byla poprvé použita v 80. letech 20. století americkou společností Motorola. Krátce na to začala být populární mezi společnostmi různých velikostí. Mezi ně patří například Honeywell, General Electric a další.

Tato metrika informuje o stabilitě a předvídatelnosti výsledků procesů. Hodnota Sigma se určuje tabulkově (viz tabulka 2) na základě metriky, která vyjadřuje počet zmetků na milion příležitostí, zkráceně DPMO (z anglického *defects per million opportunities*). Metrika DPMO je definována jako podíl počtu vyrobených zmetků x_{scrap} a součinu celkového počtu vyrobených kusů x_{total} s počtem příležitostí $x_{opportunity}$. Zlomek je vynásoben konstantou 10^6 . Referenčním cílem pro hodnotu DPMO je 3,4. Počet příležitostí v rovnici číslo 8 vyjadřuje, kolika způsoby může dojít k výrobě zmetku [12].

$$DPMO = \frac{x_{scrap}}{x_{total} \cdot x_{opportunity}} \cdot 10^6 \quad (8)$$

Tab. 2: Tabulka převodu DPMO na hodnotu Six Sigma [12]

Six Sigma	DPMO	Zmetkovitost [%]
1	691500	69,15
2	308500	30,85
3	66800	6,68
4	6200	0,62
5	230	0,00023
6	3,4	0,000034

Údržba strojů

Míra prostoje stroje

Tato metrika je hojně využívána, protože přináší obecný přehled o tom, jak výroba na stroji probíhá. Prostoj je obecně doba, po kterou je stroj nedostupný z důvodu poruchy, nebo údržby. Míra prostoje se počítá pouze v době, kdy by stroj měl skutečně fungovat, tedy v takzvané výrobní době. Míra prostoje DT_{rate} je definována jako podíl celkové doby prostoje $t_{downtime}$ a součtu celkové doby prostoje $t_{downtime}$ s celkovou dobou výroby $t_{production}$. Cílem každé společnosti je dosažení 0% míry prostoje na stroji. To může být dosaženo pouze za předpokladu prostojů mimo výrobní dobu [12, 13].

$$DT_{rate} = \frac{t_{downtime}}{t_{downtime} + t_{production}} \quad (9)$$

Doba prostoje na výrobní dobu

Tato výrobní metrika je využívána k měření efektivity strojní údržby a samotného stroje. S efektivní využitím preventivní a prediktivní údržby může být doba prostoje redukována. Doba prostoje na výrobní dobu $DTPR$ je definována jako podíl celkové doby prostoje $t_{downtime}$ a celkové doby výroby $t_{production}$. Doba prostoje na výrobní dobu vyjadřuje, kolik hodin prostoje připadá na hodinu výroby na stroji. Společnosti se snaží tento poměr snížit na minimum [13].

$$DTPR = \frac{t_{downtime}}{t_{production}} \quad (10)$$

Průměrná doba mezi poruchami

Průměrná doba mezi poruchami, zkráceně MTBF (z anglického *mean time between failures*), vyjadřuje schopnost zařízení bezporuchového provozu. Je definována jako průměrná doba mezi poruchami stroje. Na rozdíl od metriky MTTR, která zahrnuje lidský faktor, MTBF vypovídá pouze o kvalitě a spolehlivosti zařízení. Průměrná doba mezi poruchami se vypočítá jako podíl celkové doby výroby $t_{production}$ a počtu poruch $x_{failure}$ v daném časovém intervalu. [15].

$$MTBF = \frac{t_{production}}{x_{failure}} \quad (11)$$

Průměrná doba do detekce poruchy

Průměrná doba do detekce poruchy, zkráceně MTTD (z anglického *mean time to detect*), je metrika, která odpovídá průměrné době od počátku poruchy do odhalení této poruchy personálem, který následně učiní kroky vedoucí k vyřešení problému. Od momentu odhalení problému personálem a nahlášení problému se další čas započítává do průměrné

doby opravy zařízení (MTTR). Průměrná doba do detekce poruchy se vypočítá jako podíl celkové doby do detekce poruchy t_{detect} a počtu poruch $x_{failure}$ v daném časovém intervalu [16].

$$MTTD = \frac{t_{detect}}{x_{failure}} \quad (12)$$

Průměrná doba opravy

Průměrná doba opravy, zkráceně MTTR (z anglického *mean time to repair*), je metrika, která představuje průměrný čas, který společnost potřebuje k zareagování na neplánovanou poruchu a vrácení zařízení zpět ke své činnosti. Mezi tento čas spadá dle [15] několik dílčích činností:

- kontaktování pracovníků údržby
- diagnostika problému
- odstranění poruchy
- znovu zprovoznění zařízení

Průměrná doba opravy se spočítá jako podíl celkové doby trvání údržeb $t_{maintenance}$ a počtu údržeb $x_{maintenance}$ v daném časovém intervalu.

$$MTTR = \frac{t_{maintenance}}{x_{maintenance}} \quad (13)$$

Průměrná doba do poruchy

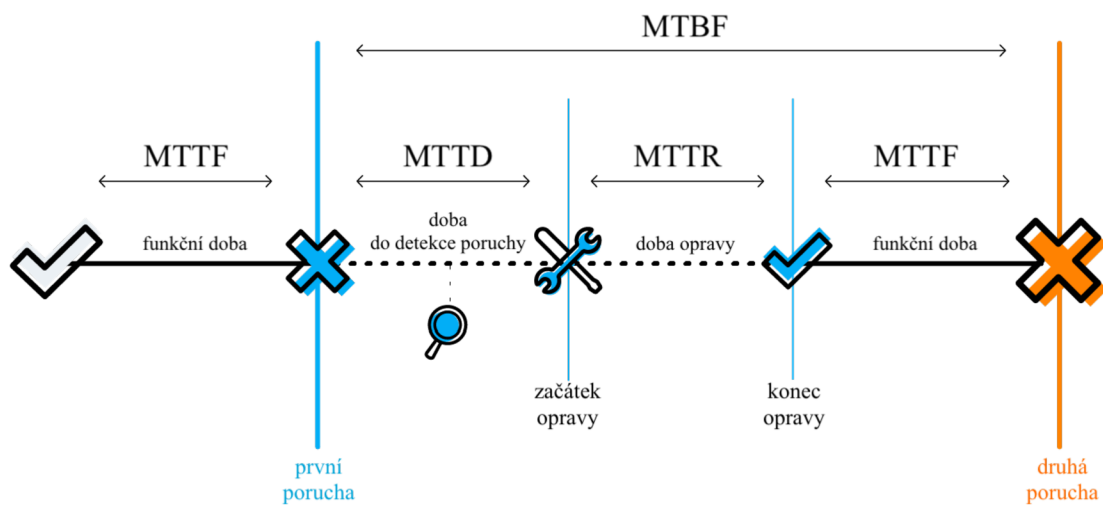
Průměrná doba do poruchy, zkráceně MTTF (z anglického *mean time to failure*), vyjadřuje průměrnou dobu životnosti zařízení. Průměrná doba do poruchy se na rozdíl od průměrné doby mezi poruchami vyjadřuje v případě neopravitelných poruch [15].

Procentuální podíl plánované údržby

Procentuální podíl plánované údržby umožňuje analyzovat poměr plánované údržby k neplánované údržbě. Tento ukazatel se využívá ke stanovení vhodnosti preventivní, nebo prediktivní údržby na strojích. Procentuální podíl plánované údržby *PPM* je definován jako podíl celkové doby trvání plánovaných údržeb $t_{m_planned}$ a celkové doby trvání všech údržeb $t_{maintenance}$ v daném časovém intervalu [13].

$$PPM = \frac{t_{m_planned}}{t_{maintenance}} \cdot 100 \quad (14)$$

Obrázek č. 6 graficky znázorňuje vzájemné postavení metrik MTBF, MTDD, MTTR, MTTF.



Obr. 6: Znázornění metrik MTBF, MTDD, MTTR, MTTF [15]

2.3 Produkty a nástroje pro datovou analýzu

Na trhu se v posledních desetiletích objevilo několik softwarových produktů, které dokáží rychle a efektivně pracovat s daty. Níže je představen programovací jazyk Python, programové prostředí MATLAB a programovací jazyk R.

2.3.1 Python

Python je open source programovacím jazykem, jehož součástí je velká standardní knihovna modulů. Standardní knihovna se zaměřuje na obecné programování a obsahuje moduly specifické pro různé operační systémy [17].

Python byl navržen v roce 1991 holandským programátorem Guido van Rossumem a od té doby se stal jedním z nejpobulárnějších programovacích jazyků. Spadá do kategorie vysokoúrovňových, objektově orientovaných programovacích jazyků. Python čerpá z programovacích jazyků jako je C, C++ a Java. Syntax Pythonu se vyznačuje dobrou čitelností a jednoduchostí. Právě tyto vlastnosti spolu s širokým využitím učinily z Pythonu jeden z nejoblíbenějších programovacích jazyků vůbec [18].

Využití Pythonu pro práci s daty a datovou analýzu je podmíněno využitím několika externích open source knihoven. Mezi ně patří především knihovny pandas, NumPy, SciPy a Matplotlib [19].

pandas

Python Data Analysis Library, zkráceně pandas, je knihovnou, která umožňuje práci s daty a datovou analýzu. Zajišťuje rychlou a jednoduchou práci se strukturovanými daty [19].

NumPy

Numerical Python, zkráceně NumPy, je jednou ze základních knihoven pro vědecké výpočty. Využívá se pro práci s velkými vícerozměrnými poli a maticemi. Umožňuje využití operací lineární algebry, Fourierovy transformace, generování náhodných čísel a dalších [19].

SciPy

Scientific Python, zkráceně SciPy, rozšiřuje knihovnu NumPy o další operace využívané ve vědeckých výpočtech. Mezi ně patří například numerická integrace a řešení diferenciálních rovnic, operace a nástroje pro zpracování signálu, standardní a diskretní rozdělení pravděpodobnosti a mnoho dalších. SciPy spolu s NumPy tvoří pro mnohé kompletní náhradu softwaru MATLAB a některých jeho knihoven v oblasti vědeckých výpočtů [19].

Matplotlib

Matplotlib je základní a velmi rozmanitou knihovnou pro dvoudimenzionální vizualizaci dat [19].

Jupyter Notebook

Jupyter Notebook je open source webová aplikace, která slouží k tvorbě a sdílení dokumentů, které obsahují takzvaný *live code*, rovnice a vizualizace vytvořené nejen pomocí jazyka Python. Jupyter Notebook je využíván primárně pro dokumentaci a prezentaci programů napsaných programovacím jazykem Python, přestože může být používán i pro jiné programovací jazyky, než je Python. Jupyter Notebook je využíván především v oblasti práce s daty a datové analýzy [20, 21].

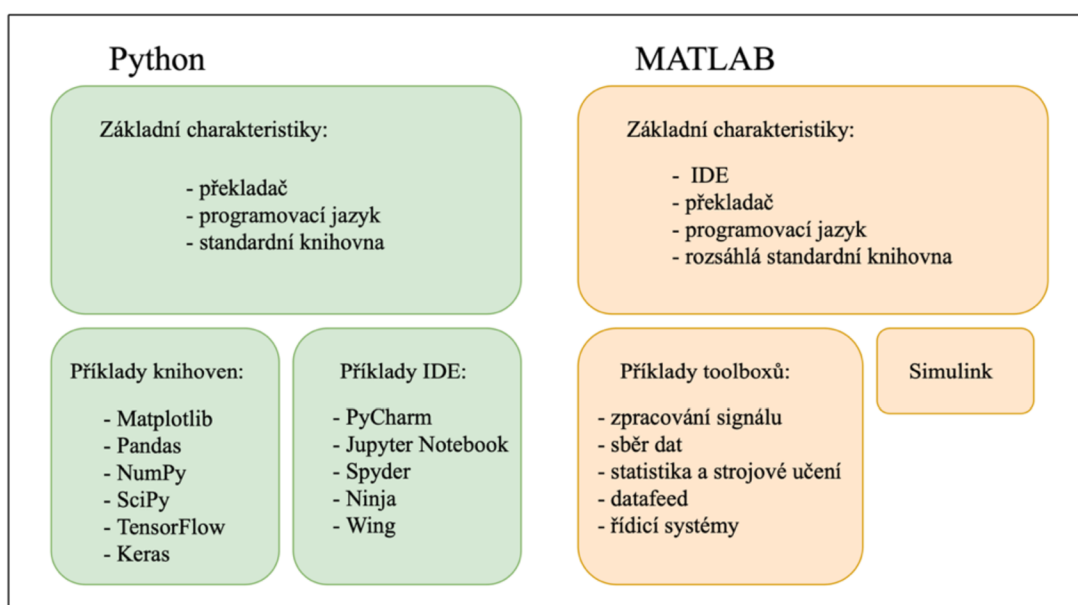
2.3.2 MATLAB

MATLAB, z anglického *matrix laboratory*, představuje interaktivní programové prostředí, jehož součástí je vlastní zabudovaný programovací jazyk. MATLAB je využíván především pro svoji schopnost numerických výpočtů [18].

MATLAB byl poprvé uveden na trh roku 1984 americkou soukromou společností MathWorks a od té doby se stal jedním ze základních inženýrských nástrojů. Na rozdíl od Pythonu nebo programovacího jazyku R není MATLAB open source softwarem a kvůli drahým licencím není natolik využíván jednotlivci, ale spíše inženýrskými společnostmi a na akademické půdě. Jak název napovídá, MATLAB je primárně využíván pro operace lineární algebry, práci s vektory a maticemi. Své využití najde také v modelování, simulaci, vizualizaci a analýze dat v různých odvětvích [18].

Přestože MATLAB disponuje rozmanitou standardní knihovnou, která postačí pro většinu elementárních operací pro práci s daty, lze dokoupit další sady nástrojů, takzvané toolboxy, které jsou určeny pro konkrétní potřeby. MathWorks poskytuje například sadu nástrojů pro prediktivní údržbu, sadu nástrojů pro strojové učení a mnohé další [17].

Porovnání základních vlastností programovacího prostředí MATLAB s programovacím jazykem Python je znázorněno na obrázku č. 7.



Obr. 7: Srovnání prostředí MATLAB a jazyka Python [17]


2.3.3 R

R je open source programovacím jazykem, ale na rozdíl od Pythonu byl vytvořen pouze za účelem statistických výpočtů [18].

Programovací jazyk R byl vyvinut v roce 1993 skupinou, které nese název *The R Foundation for Statistical Computing*. Jazyk R je zdarma ke stažení a instalaci. Standardně neobsahuje žádné grafické uživatelské rozhraní a je ovládán pouze pomocí příkazového řádku, nicméně v dnešní době existuje množství grafických rozhraní od vývojářů třetích stran. Jazyk R pokrývá širokou škálu statistických operací od testování statistických hypotéz až po nelineární modelování [18].

2.3.4 Vývoj popularity zmíněných softwarových produktů

Graf na obrázku č. 8 znázorňuje měsíční procentuální podíl aktivních uživatelů výše uvedených vědeckých softwarových produktů. Z grafu vyplývá, že Jupyter Notebook, který je využíván primárně pro programování v jazyce Python, dosahuje obrovské popularity v posledních letech oproti klesající popularitě jazyka R a téměř stagnující popularitě prostředí MATLAB.



Obr. 8: Měsíční procentuální podíl aktivních uživatelů [20]

3 VLASTNÍ ŘEŠENÍ

Společnost, která poskytla data k realizaci této bakalářské práce, monitoruje stav svých výrobních strojů pomocí technik uvedených v teoretické části bakalářské práce. V rámci monitorování jsou sbírána data dvojího druhu: primární a sekundární. Data primární slouží k určení stavu stroje. Data sekundární jsou úzce spojená se stavem stroje, protože se v nich stav stroje reflektuje. Jedná se o data, která vypovídají o efektivitě výroby a údržbě strojů.

Cílem této kapitoly bylo zpracovat sekundární data z technologie condition monitoring výrobních strojů a vyhodnotit je za účelem stanovení klíčových ukazatelů výkonnosti v oblasti údržby a efektivity výroby. Tím bylo ve společnosti zajištěno využití sekundárních dat, přičemž primární data si společnost analyzovala sama. Systém condition monitoring byl v této společnosti nasměrován tak, aby představoval komplexní analýzu výrobního stroje z pohledu jeho stavu, efektivity a údržby.

3.1 Představení výrobních strojů a vyráběných součástí


Sbíraná data pochází ze dvou totožných CNC obráběcích center Liechti Turbomill 800g (viz obrázek č. 9). Společnost Liechti pochází ze Švýcarska a je světovým lídrem ve výrobě pětiosých obráběcích strojů pro obrábění aerodynamických profilů, jejichž využití spadá převážně do leteckého a energetického průmyslu. Obráběcí stroje Liechti zkracují dobu obrábění až o 30 % oproti strojům jiných výrobců [22].

Řada Turbomill je určena primárně k výrobě lopatek specifického průřezu pomocí technologie pětiosého simultánního obrábění. Tyto stroje zajišťují maximální přesnost profilu a kvalitu hrany lopatek za co nejkratší dobu obrábění. Stroje zajišťují všechny potřebné operace, mezi které patří: podávání tyče, pětiosé frézování, soustružení, obrábění kořenu lopatky, závitování, srážení hran, gravírování a kartáčování. Stroj dokáže obrobit materiál o rozměrech až 800 x 450 x 450 mm [22].



Obr. 9: Liechti Turbomill 800g [23]

Vyráběnými součástmi na stroji v období od září 2019 do září 2020 (tedy v období, pro které byly poskytnuty data) byly lopatky parních turbín o délce 95 mm, šířce 17 mm a výšce 12 mm (viz obrázek č. 10). Lopatky nacházejí své využití v parních turbínách s výkonem až 150 MW.



Obr. 10: Vyráběné lopatky parních turbín

3.2 Výběr nástrojů

3.2.1 Pro práci s daty a analýzu dat

K přípravě, zpracování a analýze dat v této bakalářské práci byl využit programovací jazyk Python a několik jeho knihoven. Python byl zvolen především díky své rostoucí popularitě napříč odvětvími, obrovské komunitě a také díky tomu, že se jedná o open-source software, který je dostupný zdarma na všechny platformy. Python byl využit ve spojení s interaktivním prostředím Jupyter Notebook.

Instalace Pythonu a jeho knihoven

Příprava, zpracování a část analýzy dat v této bakalářské práci byla provedena v operačním systému MacOS, od toho se odvíjela instalace Pythonu a jeho knihoven. Instalace Pythonu proběhla pomocí příkazů v terminálu, kde bylo využito nástroje Homebrew. Pro instalaci stačilo provést následující příkaz.

```
brew install python
```

Po provedení příkazu byla nainstalována poslední verze Pythonu, přičemž v době psaní této práce šlo o verzi Python 3.9.1.

Dále byla provedena instalace knihoven potřebných pro práci s daty a analýzu dat. Za tímto účelem byly nainstalovány knihovny pandas, Matplotlib a NumPy. Knihovny byly nainstalovány v terminálu pomocí příkazu *pip install*. Instalace byla provedena následovně:

```
pip install pandas
pip install matplotlib
pip install numpy
```

Instalace a spuštění Jupyter Notebooku

Instalace Jupyter Notebooku proběhla pomocí příkazu *pip install* v terminálu, viz níže uvedený příkaz.

```
pip install notebook
```

Spuštění prostředí Jupyter Notebook proběhlo v terminálu pomocí příkazu následovně:

```
jupyter notebook
```

3.2.2 Pro vizualizaci dat

Přestože Python a výše zmíněné knihovny umožňují vykreslovat data, pro tvorbu vizualizací v této bakalářské práci byl upřednostněn software Microsoft Power BI.

Power BI (BI je zkratkou pro anglické *business intelligence*) je software z dílny Microsoft, který je využíván pro tvorbu reportních dashboardů. Ty slouží k vizualizaci několika klíčových ukazatelů výkonnosti vedle sebe. Microsoft Power BI disponuje intuitivním uživatelským prostředím a jednotlivé prvky dashboardů jsou tvořeny na principu *drag & drop*. Uživatel si může veškeré grafy a jejich umístění přizpůsobit dle potřeby. Mezi pokročilejší funkce softwaru patří napojení na firemní databázi, automatické vyhodnocování dat, pravidelné reportování a aktualizace vizuálů v reálném čase. Power BI lze také propojit s prostředím Jupyter Notebook. Software Power BI mimo jiné umožňuje samotné zpracování a analýzu dat (pomocí jazyků M a DAX) [24].

Tento software byl upřednostněn z několika důvodů. Mezi ně patří zejména jednoduchost ovládání, intuitivní uživatelské prostředí, tvorba dashboardů ve formátu, který je vhodný pro prezentování výsledků. Jedinou nevýhodou byla podpora pouze operačního systému Windows.

3.3 Rozbor dostupných dat

Protože data pocházela ze dvou obráběcích center a jednotlivé záznamy byly pro oba stroje uloženy v jediném datovém souboru, byly od sebe stroje odlišeny různými identifikačními čísly. V této práci byly stroje obecně identifikovány jako Liechti 1 a Liechti 2. Všechna data byla uložena v souborech formátu CSV (*comma-separated values*). Znaky v datových souborech byly kódovány ve standardu UTF-8. Níže uvedený rozbor vycházel z firemní příručky viz [25]. Podoba dat je znázorněna pouze u dat *alarms.csv* (viz obrázek č. 11). Podoba všech dat je k nalezení v příloze bakalářské práce.

Data alarms

Tato data obsahují záznamy všech PLC a NC Sinumerik hlášení na stroji a je v nich zaznamenána aktivní doba těchto hlášení. Hlášení vzniklo při vzniku problému a zaniklo vyřešením problému, nebo pokud to charakter hlášení umožňoval, zrušením hlášení na ovládacím panelu.

	AlarmId	MachineId	AlarmNumber	DateFrom	DateTo	DateDuration	FieldText1	FieldText2	IsNCAAlarm	LanguageId	ShortText	Priority
0	10000017	15	700049	2019-10-18 21:44:43.007	2019-10-18 21:45:40.020	57	<undefined>	<undefined>	False	1	Drzak nastroju není v základní pozici DB2.DBX...	3
1	10000050	15	700049	2019-10-18 21:45:42.037	2019-10-18 21:45:46.060	4	<undefined>	<undefined>	False	1	Drzak nastroju není v základní pozici DB2.DBX...	3
2	10000053	15	510009	2019-10-18 21:45:46.060	2019-10-18 21:49:50.043	244	<undefined>	<undefined>	False	1	Zastaveni posuvu / Vreteno není ve spravne pol...	3

Obr. 11: Podoba dat *alarms.csv*

Data operationState

Jedná se o záznam výrobních stavů na strojích. Stavy se dělí do dvou kategorií: prostoj a produkce. Mezi prostoj patří vypnutý stroj, zahřívání stroje, údržba a další. Mezi produkci patří měření nástroje, měření obrobku, výroba v automatickém režimu, výroba v manuálním režimu a jiné. Každý stav má své vlastní identifikační číslo. Číselné označení výrobního stavu stroje odpovídá konkrétní činnosti stroje.

Data signals

Tato data obsahují informace o provozních veličinách jednotlivých os stroje. Jedná se o osy x, y, z a o frézovací vřeteno stroje. Zbývající osy nebyly ve chvíli psaní bakalářské práce monitorovány. Zaznamenávány jsou veličiny jako je rychlost, teplota ložisek, poloha. Toto jsou primární data technologie condition monitoring.

Data pppe

Jde o data, která vznikla záznamem průběhu zpracování výrobní zakázky. Jedná se například o počet odpracovaných minut při výrobě zakázky, počet vyrobených kusů, stroj,

který byl použit pro výrobu zakázky, identifikační číslo zakázky a výrobní operace. V tomto případě bylo nutné brát v potaz chybu lidského faktoru. Mohlo se například stát, že operátor výroby aktivoval dvě přerušení po sobě, vyráběl i přes aktivní přerušení atd.

Data údržba

Jedná se o záznam všech zakázek údržby. Při poruše stroje operátor výroby aktivoval stav „přerušení výroby – volání na údržbu“. Při převzetí stroje pracovníkem údržby se zrušilo přerušení výroby a aktivovala se oprava v datech *pppe.csv*. Soubor dat obsahuje informace o specifikaci problému, termínu a času zahájení opravy a ukončení opravy.

3.4 Výběr vhodných klíčových ukazatelů výkonnosti

V důsledku omezeného rozsahu dat nebylo možné stanovit všechny klíčové ukazatele výkonnosti představené v kapitole 2.2.1. Vybrané klíčové ukazatele výkonnosti, které bylo možné stanovit, jsou sepsány níže.

Efektivita výroby

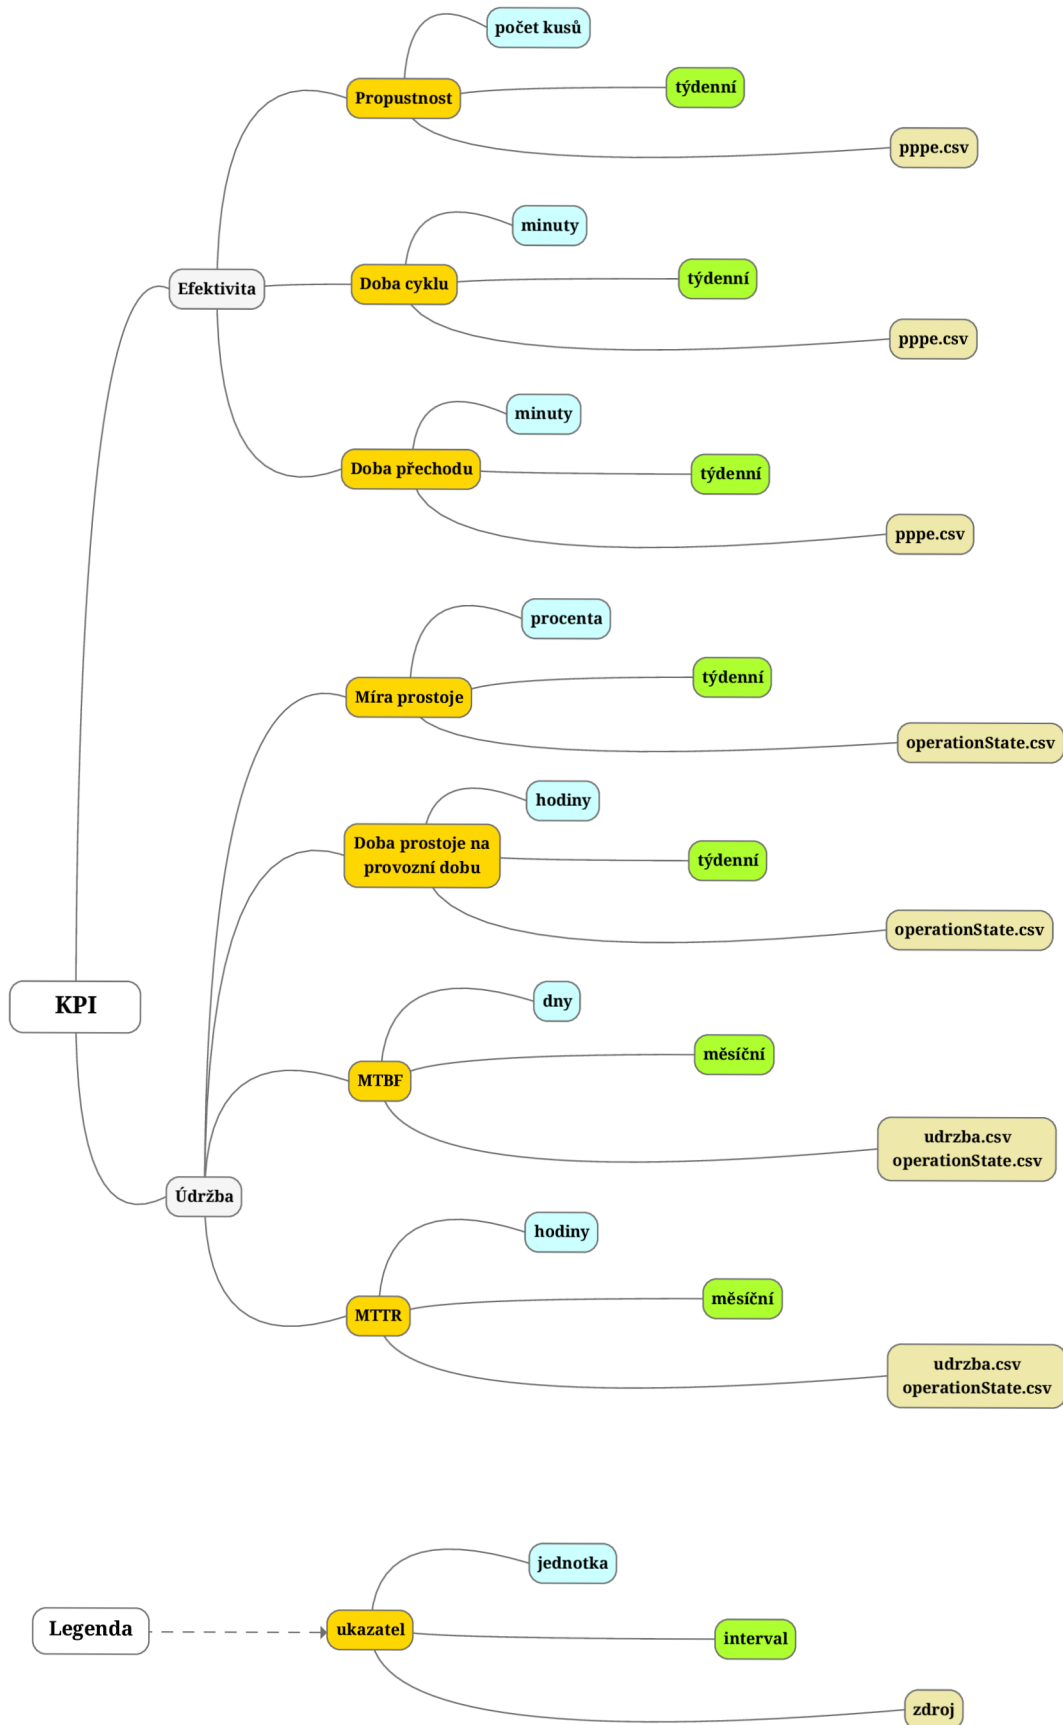
- **Propustnost** byla prvním klíčovým ukazatelem výkonnosti, který bylo možné vyhodnotit. Data potřebná k učení propustnosti vyplývají z definice propustnosti (viz kapitola 2.2.1). Mezi ně patří počet vyrobených kusů a časový záznam výroby každého kusu. Tyto informace bylo možné získat z dat *pppe.csv*. Propustnost je možné počítat v celém časovém intervalu, protože se na strojích v čase nemění vyráběné dílce. Propustnost byla vyhodnocena na týdenní bázi.
- **Dobu cyklu** bylo možné určit na základě dostupných dat. V tomto případě šlo o průměrnou dobu výroby jednoho kusu výrobku. Pro určení doby cyklu bylo nutné znát začátek a konec výroby jednoho kusu. V datech *pppe.csv* bylo zaznamenáno celkové trvání zakázky a počet vyrobených kusů v rámci zakázky. Stroj zaznamenával pouze celkovou dobu zakázky, nikoliv dobu výroby jednotlivých kusů. Bylo tak nutné stanovit průměrnou dobu výroby jednoho kusu v rámci jedné zakázky pro všechny zakázky a na základě toho stanovit dobu cyklu. Doba cyklu byla vyhodnocována na týdenní bázi.
- **Doba přechodu** je dalším ukazatelem výkonnosti vzhledem k efektivitě výroby, který bylo možné určit. S ohledem na charakter dostupných dat bude doba přechodu stanovena jako doba potřebná k přechodu mezi dvěma zakázkami. Pro stanovení doby přechodu bylo nutné určit čistý dostupný čas, výrobní čas a také počet změn mezi zakázkami v daném dni. Výrobní čas v daném dni představoval celkový čas, který byl spotřebován na výrobu zakázek. Čistý dostupný čas může být ovlivněn faktory jako jsou: doba potřebná k výměně směny, neplánovaná porucha a další. V tomto případě byl čistý dostupný čas zjednodušen a stanoven jako celková pracovní doba, která činí 24 hodin denně.

Ke stanovení doby přechodu se vycházelo z dat *pppe.csv*, protože v nich bylo zaznamenáno vše potřebné, tedy: číslo zakázky, doba trvání zakázky, časové zařazení zakázky. Doba přechodu byla vyhodnocována na týdenní bázi.

Údržba strojů

- **Míra prostoje stroje** je ukazatelem, se který se analýza přesunula k samotným strojům a jejich údržbě. K určení míry prostoje stroje bylo potřeba znát dobu prostoje stroje a výrobní dobu stroje v daném časovém intervalu. Vhodným intervalem pro vyhodnocení této metriky byl jeden týden. K určení míry prostoje stroje bylo využito dat *operationState.csv*. Stroj do databáze zaznamenával svůj provozní stav včetně začátku vzniku a konce tohoto stavu. Koncem jednoho stavu stroj přešel do dalšího stavu. Také bylo automaticky vyhodnocováno celkové trvání daného provozního stavu. Každý stav měl své číselné označení. Pro určení této metriky bylo nutné rozlišit jednotlivé provozní stavy na základě číselného označení a rozčlenit je na prostoj a provoz stroje.
- **Doba prostoje na výrobní dobu** byla dalším ukazatelem, který souvisel s prostojem a bylo možné jej vyhodnotit. Postup vyhodnocení této metriky byl podobný jako u míry prostoje stroje a vycházelo se ze stejných dat.
- **Průměrná doba mezi poruchami** byla další vyhodnocenou metrikou vzhledem k údržbě. Ke stanovení této metriky byl potřeba záznam všech údržeb. Z charakteru provozu výrobních strojů, je prakticky nemožné plánovat údržbu mimo výrobní dobu strojů, a tak bylo vhodné uvažovat všechny údržby na stroji. Stroj navíc nerozeznával plánovanou údržbu od neplánované. K určení MTBF se vycházelo z dat *udrzba.csv* a *operationState.csv*. Při výpočtu této metriky byl brán v potaz pouze čas, po který byl stroj aktivní. Proto bylo nutné rozdělit data na dobu prostoje a dobu provozu stroje. Položky označující dobu prostoje stroje byly vyraženy.
- **Průměrná doba opravy** přímo navazovala na průměrnou dobu mezi poruchami stroje. Pro stanovení průměrné doby opravy se vycházelo ze stejných dat jako u průměrné doby mezi poruchami. Doba opravy zahrnovala dobu od kontaktování technika údržby až po dokončení údržby. Tato metrika dotvořila obrázek o údržbě strojů.

Následující schéma shrnuje důležité informace o zvolených klíčových ukazatelích výkonnosti. Příprava, zpracování a vyhodnocení dat za účelem stanovení vybraných ukazatelů v další části bakalářské práce bude vycházet primárně z tohoto schématu.



Obr. 12: Schéma znázorňující jednotlivé KPI a jejich parametry

3.5 Příprava dat vzhledem k vybraným klíčovým ukazatelům výkonnosti

Příprava a zpracování dat probíhala v prostředí Jupyter Notebook. Veškeré notebooky, které vznikly při zpracování dat jsou k nalezení v příloze této bakalářské práce. Notebooky obsahují detailní komentovaný postup přípravy, zpracování a vyhodnocení dat. Struktura notebooků je zřejmá z následujícího obrázku. Konkrétně se jedná o část přípravy a zpracování dat za účelem stanovení propustnosti výrobních strojů.

KPI: Propustnost

Výpočet klíčového ukazatele výkonnosti "propustnost" z dat pppe.csv. Propustnost představuje počet vyrobených kusů v předem stanoveném časovém intervalu. Propustnost byla vyhodnocena na týdenní bázi v období září 2019 až září 2020.

Import knihoven

```
In [1]: import pandas as pd
```

Import dat

```
In [2]: data = pd.read_csv('/Users/Jan/Dropbox/Bakalářská práce/Data/pppe.csv', sep=';')
```

Výběr potřebných informací

Vymazat nepotřebné sloupce:

```
In [3]: data = data.drop(columns = [
    'Vyrobni_operace', 'Zakazka', 'Doba_min', 'Pracoviste',
    'Zpetne_hlaseni', 'Operator', 'Poradove_cislo', 'ZpracovaniJOBem',
    'Status', 'Duvod_preruseni', 'Zakladni_merna_jednotka',
    'Hlaseni_udrzby', 'Zakazka_udrzby', 'Skupina_kodu', 'Kod_priciny'
    ])
```

Ve sloupci "Mnozstvi" budou ponechány pouze řádky s nenulovou hodnotou:

```
In [4]: data = data.loc[data['Mnozstvi']!=0]
```

Konverze informací do vhodného formátu

Sloupec 'Datum' jsou časové údaje:

```
In [5]: pd.options.mode.chained_assignment=None
data['Datum'] = pd.to_datetime(data['Datum'])
```

Rozčlenění datového rámce dle výrobního stroje

Rozdělení původního datového rámce na dva podle výrobního stroje (Liechti 1 a Liechti 2):

```
In [6]: data15 = data.groupby('Vybaveni').get_group('BRQ100251')
data16 = data.groupby('Vybaveni').get_group('BRQ100237')
```

Obr. 13: Ukázka části notebooku pro výpočet propustnosti

3.5.1 Postup při přípravě a zpracování dat

Postup přípravy a zpracování dat za účelem stanovení jednotlivých klíčových ukazatelů výkonnosti byl ve všech případech velmi podobný, a proto bylo možné určit obecnou strategii řešení. Konkrétně šlo postup rozčlenit do několika dílčích kroků.

- a) import knihoven potřebných pro práci s daty
- b) import vhodných dat
- c) výběr potřebných informací
- d) konverze informací v datovém rámci do vhodného formátu
- e) rozčlenění datového rámce dle výrobního stroje
- f) seskupení informací potřebných pro výpočet KPI
- g) výpočet klíčových ukazatelů výkonnosti
- h) export do požadovaného formátu

Níže jsou uvedeny základní funkce a postupy, kterých bylo při přípravě a zpracování dat využito. Je nutné brát v potaz, že využití každé funkce se lišilo případ od případu a že výčet funkcí není kompletní. Kompletní řešení je k nalezení v příloze bakalářské práce. Důraz byl kladen na problematiku části přípravy a zpracování dat.

Import knihoven potřebných pro práci s daty

Pro práci s daty v této praktické části bylo využito knihoven pandas a NumPy. Import byl proveden pomocí následujících příkazů:

```
import pandas as pd
import numpy as np
```

Import vhodných dat

Pro import dat bylo použito funkce „read_csv()“ z knihovny pandas. Data byla načtena do takzvaného datového rámce. Při importu dat byl brán zřetel na formát dat, kterým byl CSV. Data jsou oddělena středníkem, což bylo nutné ve funkci upřesnit.

```
df = pd.read_csv('/Users/User/Data/nazev.csv', sep=',')
```

Výběr potřebných informací

Na základě znalostí z rozboru dat proběhlo vyřazení nepotřebných informací za účelem zredukování a zpřehlednění datového rámce. Většinou se jednalo o vyřazení konkrétních sloupců, v nichž jsou obsaženy informace, které nevedly ke stanovení daných klíčových ukazatelů výkonnosti. Sloupce byly odstraněny pomocí následující funkce:

```
df.drop(columns = ['název sloupce'])
```

Dále bylo využito funkce pro výběr konkrétních řádků v daném sloupci. Bylo využito funkce „.loc[]“:

```
df.loc[df['název sloupce']=='požadovaný výraz']
```

Konverze informací v datovém rámci do vhodného formátu

Protože byla potřeba všechny klíčové ukazatele výkonnosti časově zařadit, musely být sloupce označující čas a datum v datovém rámci převedeny na datový formát kompatibilní s knihovnou pandas. Původně načtené sloupce byly typu string. Bylo využito funkce „to_datetime()“ z knihovny pandas.

```
df['Datum'] = pd.to_datetime(df['Datum'])
```

V případě, že doba trvání stavu nebyla zaznamenána strojem automaticky, bylo nutné přidat sloupec, který obsahoval dobu trvání stavu. To bylo provedeno jako rozdíl hodnoty sloupce s termínem ukončení a sloupce s termínem zahájení stavu. Provedením následujícího příkazu vznikl sloupec, ve kterém byla zaznamenána doba trvání stavu ve formátu: „dny hodiny:minuty:sekundy“.

```
df['čas'] = df['Ukonceni'] - df['Zahajeni']
```

Dále bylo vhodné převést dobu trvání stavu na konkrétní jednotku. To umožnilo sjednocení formátu jednotlivých řádků a jednodušší práci s časovým údajem. Bylo využito funkce z knihovny NumPy. Převod hodnot ve sloupci „čas“ na minuty byl proveden následujícím způsobem:

```
df['čas'] = df['čas'] / np.timedelta64(1, 'm')
```

Rozčlenění datového rámce dle výrobního stroje

Protože se v datech nacházela data z dvou výrobních strojů, byla potřeba tyto výrobní stroje rozlišovat. Za tímto účelem byla na sloupce označující ID stroje aplikována funkce „groupby()“ a pomocí funkce „get_group()“ byly vybrány konkrétní řádky v daných sloupcích.

```
df1 = df.groupby('stroj').get_group('ID stroje')  
df2 = df.groupby('stroj').get_group('ID stroje')
```

Seskupení informací potřebných pro výpočet KPI

Tato část byla velmi individuální, protože pro různé KPI bylo potřeba jiného seskupení dat. Obecně lze tvrdit, že bylo potřeba seskupit informace po časových intervalech (týdnech, nebo měsících). Bylo využito funkce „resample()“. Po provedení této funkce se časové rozdělení stalo indexem datového rámce.

```
df1.resample('W-MON', on='Datum').agg({'Mnozstvi':'sum'})
```

Výše uvedený příklad seskupil data na týdenní bázi podle sloupce „Datum“. Dále bylo v příkazu specifikováno, že každý týden začínal pondělím. Všechna data ve sloupci „Mnozstvi“ v daném časovém intervalu sčítala. Po provedení příkazu se sloupec „Datum“ stal indexovým sloupcem datového rámce.

Problémem bylo, že první a poslední sečtené týdny byly neúplné. Sběr dat začínal a končil v den, kterým nebylo pondělí, přičemž jeden úplný týden tvoří dny od pondělí do neděle včetně. Aby klíčové ukazatele výkonnosti nebyly zkreslené, bylo nutné neúplné týdny odstranit. Toho bylo dosaženo odstraněním prvního a posledního řádku datového rámce.

```
df1.drop(df1.head(1).index, inplace=True)  
df1.drop(df1.tail(1).index, inplace=True)
```

Dalším problémem bylo, že datum, které bylo následně zobrazeno v datovém rámci, odpovídalo dni, do kterého bylo předchozích 7 dní sečteno. Tedy například když se v datovém rámci objevilo datum 7.1. 2020, znamenalo to, že byly sečteny dny od 1.1. do 6.1. včetně. Žádoucí bylo, aby zobrazené datum odpovídalo prvnímu dni ve sčítaném týdnu. Protože bylo datum po provedení předchozích příkazů indexem datového rámce, bylo potřeba obnovit původní indexování datového rámce, aby bylo možné se sloupcem pracovat. To bylo provedeno pomocí funkce `reset_index()`. Dále bylo od všech údajů ve sloupci „Datum“ odečteno sedm dní.

```
df1 = df1.reset_index()  
df1['Datum'] = df1['Datum'] - pd.DateOffset(days=7)
```

Výpočet klíčových ukazatelů výkonnosti

Jakmile byla data v datovém rámci seříděná, byl výpočet klíčových ukazatelů výkonnosti velmi jednoduchý a ve všech případech postačily základní matematické operace. Následující příklad ukazuje, jak bylo možné do datového rámce přidat sloupec, který vznikl vydělením jiných sloupců. Vypočtené hodnoty byly vhodně zaokrouhleny.

```
df1['Doba cyklu'] = df1['Doba_min'] / df1['Mnozstvi']  
df1['Doba cyklu'] = df1['Doba cyklu'].round(decimals=1)
```

Export do požadovaného formátu

Datové rámce byly exportovány do formátu XLSX, protože se jednalo o formát vhodný pro práci v softwaru Power BI, a do formátu CSV kvůli kompaktnosti při archivaci dat.

```
with pd.ExcelWriter('název.xlsx') as writer:
```

```
df1.to_excel(writer, sheet_name='Liechti 1')
df2.to_excel(writer, sheet_name='Liechti 2')
```

Výše uvedené řádky kódu vytvořily XLSX soubor, který nesl název „název.xlsx“ a který se skládal ze dvou listů. Do prvního listu byl zaznamenán datový rámec „df1“ a do druhého „df2“.

```
df1.to_csv(název1.csv', index = False)
df2.to_csv(název2.csv', index = False)
```

Výše uvedené řádky sloužily k vytvoření dvou CSV souborů (pro každý datový rámec jeden soubor), přičemž byl ignorován index datových rámců.

3.6 Vizualizace a stanovení trendů

Klíčové ukazatelé výkonnosti byly stanoveny v jednotlivých tabulkách, což činilo 7 tabulek pro každý stroj, dohromady tedy 14 tabulek. Pro další práci s klíčovými ukazateli výkonnosti bylo vhodné tabulky sjednotit. Komentovaný postup sjednocování klíčových ukazatelů výkonnosti do finální podoby je k nalezení v příloze bakalářské práce. Finální podoba je následující. Jedná se o jeden XLSX soubor o čtyřech listech (a ekvivalentně čtyři CSV soubory), přičemž na každý list připadá jedna tabulka. Jde tedy o 4 tabulky klíčových ukazatelů výkonnosti:

- na týdenní bázi pro stroj Liechti 1
- na týdenní bázi pro stroj Liechti 2
- na měsíční bázi pro stroj Liechti 1
- na měsíční bázi pro stroj Liechti 2

	Týden od	Propustnost [ks]	Doba cyklu [min]	Doba přechodu [min]	Míra prostoje [%]	Doba prostoje na výrobní dobu [hod]
0	2019-09-02	147	45.7	420.9	39.9	0.66
1	2019-09-09	187	35.8	337.9	43.9	0.78
2	2019-09-16	210	39.3	303.7	31.6	0.46
3	2019-09-23	103	47.9	857.5	53.7	1.16
4	2019-09-30	176	51.4	44.8	20.7	0.26
5	2019-10-07	281	32.5	104.4	20.3	0.26

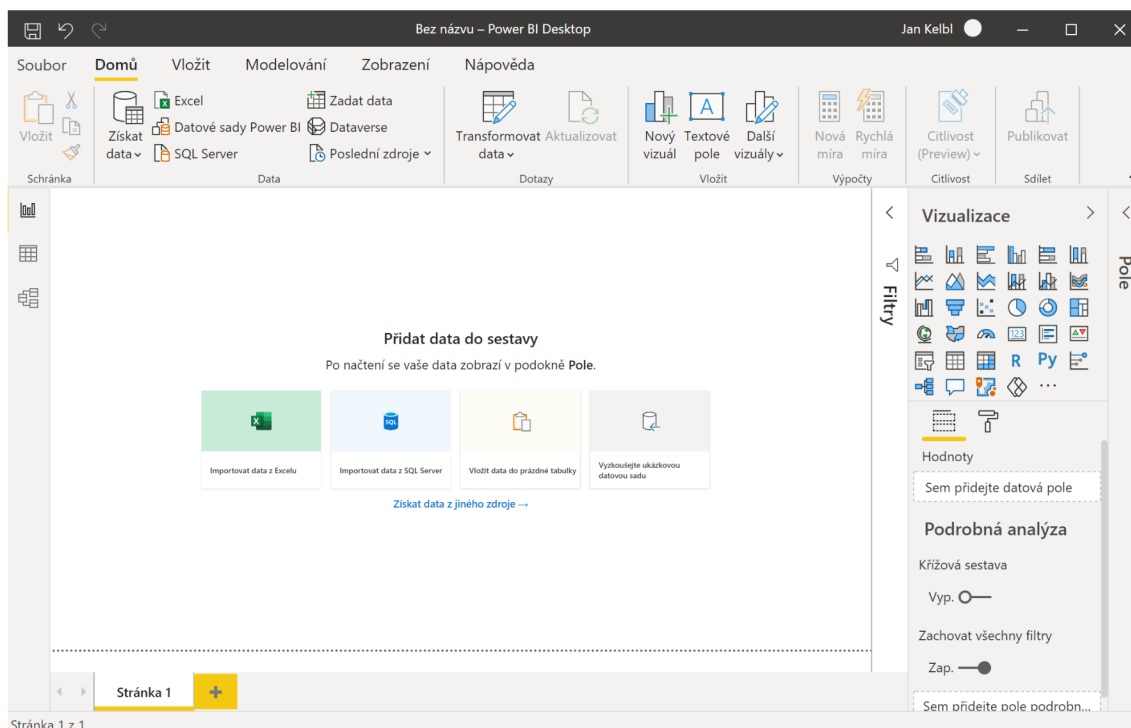
Obr. 14: Ukázka datového rámce týdenních KPI v prostředí Jupyter Notebook

3.6.1 Vizualizace klíčových ukazatelů výkonnosti

Výše uvedené tabulky sloužily jako vstupní soubory do softwaru Power BI. Cílem vizualizace bylo vytvoření čtyř takzvaných reportních dashboardů, které se skládaly z interaktivních vizualizací několika klíčových ukazatelů výkonnosti. Jednalo se o následující dashboardy:

- efektivita výroby pro stoj Liechti 1
- efektivita výroby pro stoj Liechti 2
- údržba pro stoj Liechti 1
- údržba pro stroj Liechti 2

Prostředí Power BI je zobrazeno na obrázku č. 15. Uživatelsky orientované prostředí přenáší charakteristické rysy známé například z kancelářského balíku Microsoft Office, proto nebyla orientace v tomto softwaru nikterak složitá. Software nabízí načtení dat z různých zdrojů. V této práci bylo využito importu dat z Excelu. V horní části okna se nacházejí především nástroje pro práci s daty, v pravé části okna se nacházejí nástroje pro tvorbu a úpravu samotných dashboardů. Z části „Vizualizace“ byly voleny požadované grafické výstupy, které se vkládaly do sestavy.



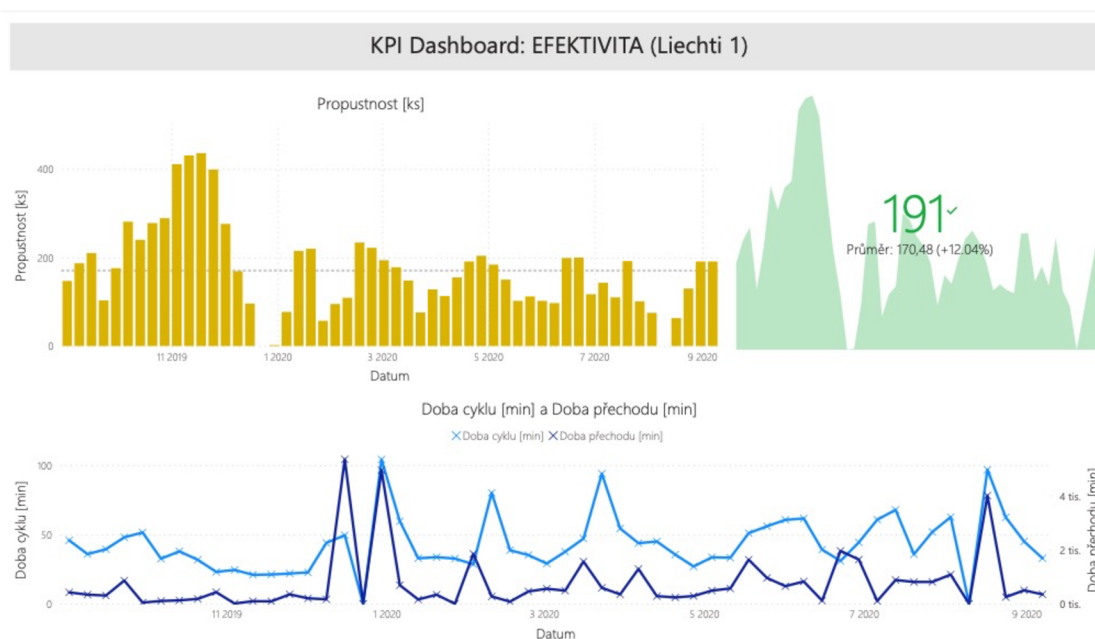
Obr. 15: Úvodní prostředí Power BI

Po importu dat z Excelu se prostředí rozšířilo o sloupec „pole“, který obsahoval načtený soubor. V poli byly zobrazeny jednotlivé listy XLSX souboru a sloupce jednotlivých tabulek. Z pole byly přetahovány jednotlivé sloupce do vizualizací.


KPI dashboard: Efektivita

První dvojice dashboardů obsahuje vizualizace klíčových ukazatelů výkonnosti vzhledem k efektivitě výroby. Dashboard pro stroj Liechti 1 je znázorněn na obrázku č. 16. Pro vytvoření takového dashboardu bylo využito třech prvků:


- Propustnost je znázorněna pomocí sloupcového grafu. Na ose x se nacházejí jednotlivé týdny v daném časovém intervalu a na ose y propustnost. Součástí grafu je horizontální čára, která znázorňuje aritmetický průměr propustnosti. Sloupcový graf je interaktivní. Po přesunu kurzoru na konkrétní sloupec jsou uživateli zobrazeny podrobnosti (viz obrázek č. 17).
- Na sloupcový graf propustnosti dále navazuje prvek, který nese název „klíčový ukazatel výkonu“. Klíčový ukazatel výkonu je vizuál, který zobrazuje propustnost ve vybraném týdnu (jako výchozí je vždy poslední zaznamenaný týden, přičemž týdny se dají měnit rozkliknutím konkrétního týden ve sloupcovém grafu) a procentuální změnu oproti referenční hodnotě. Referenční hodnotou byl nastaven aritmetický průměr propustnosti za dané období. Pokud byla propustnost v daném týdnu větší než referenční hodnota, byl ukazatel zelený, naopak pokud byla menší, byl ukazatel červený.
- Třetím prvkem dashboardu je spojnicový graf se dvěma datovými osami. Na ose x se nacházejí jednotlivé týdny. Na primární ose y se nachází doba cyklu v minutách a na sekundární ose y se nachází doba přechodu v minutách. Graf je interaktivní (viz obrázek č. 18). Po přesunu kurzoru na jednotlivé body se uživateli zobrazí hodnoty klíčových ukazatelů výkonnosti.



Obr. 16: Dashboard: Efektivita (stroj Liechti 1)



Obr. 17: Ukázka interaktivní vizualizace propustnosti

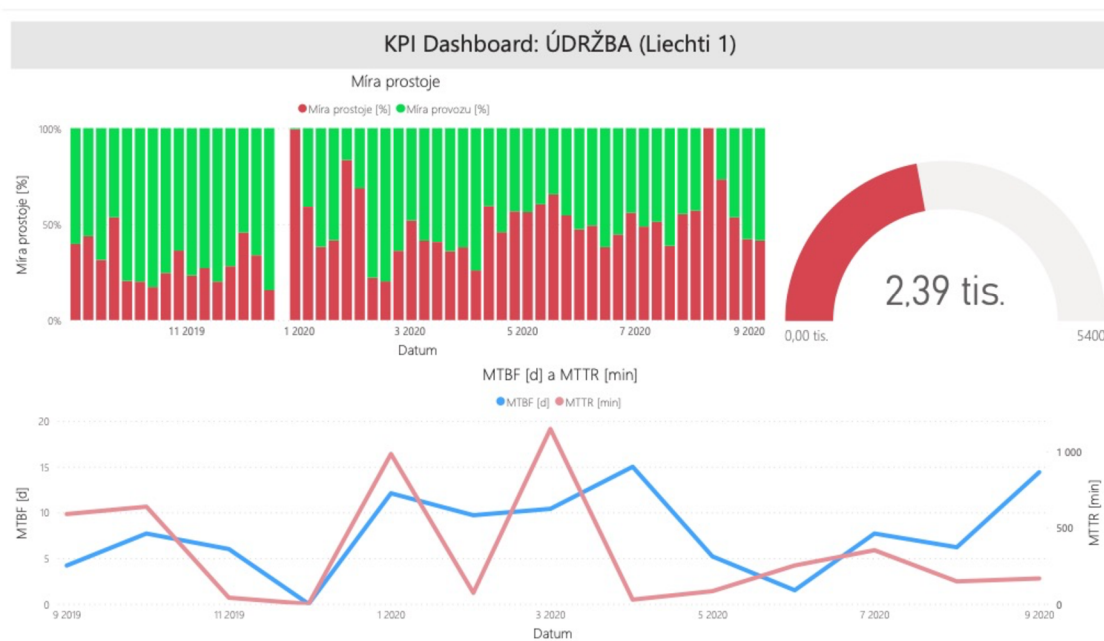


Obr. 18: Ukázka interaktivní vizualizace doby cyklu a doby přechodu

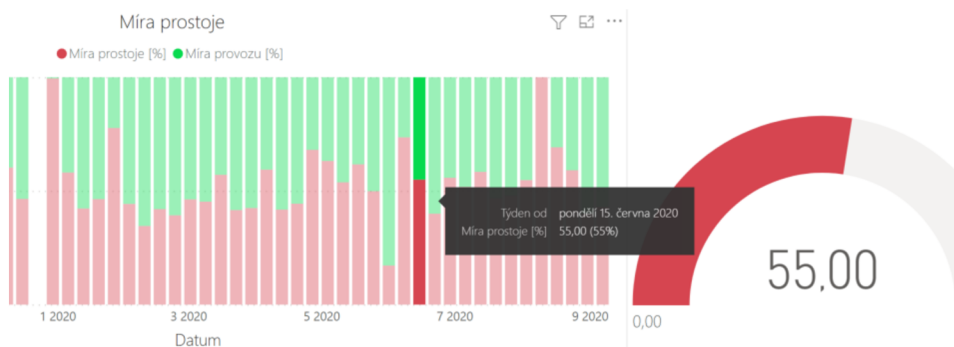
KPI dashboard: Údržba

Druhá dvojice dashboardů se zaměřuje na klíčové ukazatele výkonnosti vzhledem k údržbě. Dashboard pro stroj Liechti 1 je znázorněn na obrázku č. 19. Tyto dashboardy obsahují 3 prvky:


- Pro vizualizaci míry prostoje byl zvolen 100% skládaný sloupcový graf, ve kterém je červenou barvou znázorněna míra prostoje a zelenou barvou je do 100 % doplněna míra výroby stroje. Prázdné sloupce v grafu vznikly vyřazením týdnů, ve kterých byl celý provoz zastaven. Tato doba se nepočítala do prostoje strojů. Po přesunu kurzoru na konkrétní sloupec jsou uživatelům zobrazeny podrobnosti (viz obrázek č. 20).
- Na sloupcový graf navazuje prvek, který se jmenuje „měřidlo“. Tento prvek znázorňuje také míru prostoje a reaguje na vybrané sloupce ve sloupcovém grafu. V případě, že není žádný sloupec vybrán, měřidlo zobrazuje míru prostoje od 0 % do 5400 %, protože se ve sloupcovém grafu nachází 54 sloupců. Pokud je nějaký sloupec vybrán, poté měřidlo zobrazuje míru prostoje od 0 % do 100 %.
- Jako poslední prvek byl zvolen spojnicový graf se dvěma datovými osami y. Na ose x jsou znázorněny jednotlivé měsíce. Na primární ose y je znázorněna metrika MTBF ve dnech a na sekundární ose y je znázorněna metrika MTTR v minutách. Graf je také interaktivní (viz obrázek č. 21). Po přesunu kurzoru na jednotlivé body se uživatelům zobrazí hodnoty klíčových ukazatelů výkonnosti.



Obr. 19: Dashboard: Údržba (stroj Liechti 1)



Obr. 20: Ukázka interaktivní vizualizace míry prostoje



Obr. 21: Ukázka interaktivní vizualizace metrik MTBF a MTTR

3.6.2 Stanovení trendů klíčových ukazatelů výkonnosti a vztahů mezi nimi

Trendy klíčových ukazatelů výkonnosti byly stanoveny za období od září 2019 do září 2020. Stanovení trendů klíčových ukazatelů výkonnosti proběhlo v prostředí Jupyter Notebook a byl vytvořen komentovaný postup, který je k nalezení v příloze bakalářské práce. Trendy jsou vyjádřeny číselně, přičemž číslo odpovídá směrnici přímky, kterou jsou data proloženy. Záporné číslo vyjadřuje klesající trend, kladné číslo vyjadřuje rostoucí trend. Čím je číslo větší, tím byl trend silnější. Trendy jsou uvedeny v tabulce číslo 3.

Tab. 3: Trendy klíčových ukazatelů výkonnosti

KPI	Liechti 1	Liechti 2
Propustnost	-2,60	-1,21
Doba cyklu	0,33	0,47
Doba přechodu	9,30	7,16
Míra prostoje	0,55	0,51
Doba prostoje na výrobní dobu	-0,13	-0,13
MTBF	0,29	-0,90
MTTR	-26,52	-34,82

Pro stanovení vztahů mezi jednotlivými ukazateli bylo využito Pearsonova korelačního koeficientu dle [26]. Stanovení korelačního koeficientu a testování korelace jednotlivých ukazatelů bylo provedeno v prostředí Jupyter Notebook pomocí jazyka Python a knihovny pandas. Komentovaný postup je k nalezení v příloze bakalářské práce. V tabulkách číslo 4 a 5 jsou zobrazeny korelační koeficienty měsíčních KPI pro stroje Liechti 1 a Liechti 2. Čím je absolutní hodnota korelačního koeficientu větší, tím je vztah mezi jednotlivými klíčovými ukazateli výkonnosti zřejmější. Kladná hodnota značí, že s rostoucím jevem x roste jev y , záporná hodnota naopak značí, že s rostoucím jevem x klesá jev y . Významnost těchto vztahů byla ověřena statistickým testem. Test významnosti korelačního koeficientu byl proveden na hladině významnosti 5 %. S rostoucím množstvím ukončených týdnů by rostla přesnost statistického testu.

Tab. 4: Korelační koeficienty týdenních klíčových ukazatelů výkonnosti pro Liechti 1

	Propustnost	Doba cyklu	Doba přechodu	Míra prostoje	Doba prostoje na výrobní dobu
Propustnost	1,00	-0,47	-0,40	-0,52	-0,25
Doba cyklu	-0,47	1,00	0,50	0,27	0,42
Doba přechodu	-0,40	0,50	1,00	0,31	0,53
Míra prostoje	-0,52	0,27	0,31	1,00	0,41
Doba prostoje na výrobní dobu	-0,25	0,42	0,53	0,41	1,00

Tab. 5: Korelační koeficienty týdenních klíčových ukazatelů výkonnosti pro Liechti 2

	Propustnost	Doba cyklu	Doba přechodu	Míra prostoje	Doba prostoje na výrobní dobu
Propustnost	1,00	-0,31	-0,43	-0,33	-0,25
Doba cyklu	-0,31	1,00	0,14	-0,08	0,24
Doba přechodu	-0,43	0,14	1,00	0,30	0,66
Míra prostoje	-0,33	-0,07	0,30	1,00	0,42
Doba prostoje na výrobní dobu	-0,25	0,24	0,66	0,42	1,00

3.7 Vyhodnocení výsledků

3.7.1 Vyhodnocení trendů klíčových ukazatelů výkonnosti

Propustnost

Z tabulky č. 3 vyplývá, že propustnost měla u obou strojů v daném časovém období klesající trend. Trend mohl být způsoben například klesající poptávkou. Tento trend bude důležité sledovat do budoucna.

Doba cyklu

Trend doby cyklu byl v daném období na obou strojích velmi podobný. Protože se jedná o mírný trend v řádech desetin, je považován za zanedbatelný.

Doba přechodu

Výraznějším byl stoupající trend doby přechodu, který byl na obou strojích opět podobný. Obecně by mělo docházet ke snižování doby přechodu, proto bude nutné se blíže zaměřit na dobu potřebnou k přechodu mezi dvěma zakázkami a aplikovat například některý z přístupů štihlé výroby pro za účelem snížení doby přechodu.

Míra prostoje

Dále byl zaznamenán mírný rostoucí trend míry prostoje. Míra prostoje by měla v ideálním případě klesat. Rostoucí trend míry prostoje může souviset právě s rostoucím trendem doby přechodu.

Doba prostoje na výrobní dobu

U tohoto ukazatele byl zaznamenán v daném časovém období identický trend u obou strojů. Protože se jedná o velmi mírný trend, může být zanedbán.

MTBF

Jedná se o jediný ukazatel, u kterého je liší smysl trendu mezi stroji. Zatímco u stroje Liechti 1 je trend rostoucí, u stroje Liechti 2 je trend klesající. Protože se jedná o mírné trendy, není nutné se jimi v tuto chvíli zabývat.

MTTR

Nejvýraznější položkou tabulky číslo 3 je klesající trend průměrné doby do opravy stroje, což je velmi pozitivní a mohlo být zapříčiněno zavedením systému condition monitoring.

Důležitým poznatkem je, že trendy jednotlivých klíčových ukazatelů výkonnosti mezi oběma stroji byly řádově velmi podobné. To svědčí o vyváženosti obou strojů a lze tak usuzovat, že trendy v tomto období byly ovlivňovány převážně globálními událostmi, tedy událostmi zasahujícími celou výrobu.

3.7.2 Vyhodnocení vztahů mezi klíčovými ukazateli výkonnosti

U obou strojů se v daném časovém intervalu projevila závislost mezi propustností a mírou prostoje stroje, přičemž platilo, že s rostoucí mírou prostoje klesá propustnost stroje. Stejná závislost platila mezi propustností a dobou cyklu, tedy čím déle trvala výroba jednoho kusu výrobky, tím menší byla propustnost. Dále bylo možné vypočítat závislost mezi dobou přechodu a dobou prostoje na výrobní dobu u obou strojů tak, že s rostoucí dobou přechodu roste doba prostoje na výrobní dobu. Také platí, že s rostoucí mírou prostoje roste doba prostoje na výrobní dobu.

3.7.3 Porovnání klíčových ukazatelů výkonnosti mezi stroji

Při srovnání dashboardů mezi stroji Liechti 1 a Liechti 2 je vidět, že stroj 2 vykazoval menší propustnost za monitorované období. Jde o průměrně 12% pokles propustnosti na stroji 2 oproti stroji 1. S propustností úzce souvisí míra prostoje. Stroj 2 vykazuje větší míru prostoje než stroj 1. To může být způsobeno například tím, že u stroje 2 je ve dvou měsících zaznamenán vysoký nárůst průměrné doby do opravy stroje. Lze tedy usuzovat, že dva z dvanácti měsíců byly problematické pro stroj 2, čímž byla způsobena nižší efektivita stroje.

3.8 Doporučení vyplývající z analýzy

Soubor klíčových ukazatelů výkonnosti byl vhodně vybrán, protože reflektuje vývoj stroje z pohledu efektivity a údržby strojů a protože lze jednotlivé klíčové ukazatele výkonnosti vzájemně porovnat a najít v nich souvislosti. Doporučuje se tyto ukazatele dále vyhodnocovat.

Za dosažením lepší efektivity bude nutné snížit prostoj strojů. To bude mít za následek mimo jiné snížení doby přechodu, doby cyklu a zvýšení propustnosti. Za tímto účelem bude vhodné analyzovat celý výrobní proces a aplikovat například některý z nástrojů metodiky štíhlé výroby. Z pohledu údržby by mělo být dosaženo optimálního plánování především díky technologii condition monitoring. Vliv této technologie na všechny klíčové ukazatele výkonnosti prozatím nelze přímo prokázat, bude nutné sledovat vývoj ukazatelů v dalších letech. Předpokládá se, že čím déle bude condition monitoring zavedený, tím lépe bude vidět vliv této technologie na výrobu.

Také by bylo vhodné provádět vyhodnocení a analýzu klíčových ukazatelů výkonnosti častěji, v ideálním případě okamžitě po uzavření týdne nebo měsíce.

Další doporučení jsou mířená na sběr konkrétních dat. V rámci rozšíření množství vyhodnotitelných ukazatelů je doporučeno sbírat následující data:

- záznam počtu zmetků pro určení zmetkovitosti, celkové účinnosti zařízení a hodnoty Six Sigma
- záznam o tom, proč se v případě zmetku jedná o zmetek pro určení počtu příležitostí (kolika způsoby může být vyroben zmetek) k výpočtu Six Sigma

- určení ideální doby výroby jednoho kusu výrobku pro stanovení celkové účinnosti zařízení
- rozdělení údržby na plánovanou a neplánovanou pro zpřesnění údržbových ukazatelů

Další možnosti rozvoje v praxi se nachází především ve vyhodnocování a aktualizaci ukazatelů v reálném čase. Za tímto účelem by bylo vhodné sjednotit přípravu, zpracování, analýzu a vizualizaci dat do jednoho prostředí (například právě integrací Jupyter Notebooku a Power BI). Dále by bylo vhodné spojení s firemní databází. Také by byly vytvořeny týdenní a měsíční dashboardy, které by byly v reálném čase aktualizovány, přičemž na konci týdne by se vizualizace archivovaly a vznikly by nové pro další týden. Data z ukončeného týdne by byla přenesena do vizualizací vytvořených v této práci.

4 ZHODNOCENÍ A DISKUZE

Condition monitoring je silným nástrojem napříč odvětvími. Každodenně rostou nároky na kvalitu, rychlost a spolehlivost výroby, a tak je jeho využití stále důležitější. Neočekávaný výpadek stroje může být v dnešní rychlé době kritický. Proto chtějí mít společnosti jasné informace o stavech svých aktiv. Smysluplné využití co největšího množství dat je žádoucí. Tato práce přispěla transformováním nevyužívaných dat technologie condition monitoring v klíčové ukazatele výkonnosti.

4.1 Použité nástroje

Použité nástroje v této bakalářské práci, tedy Python, Jupyter Notebook a Microsoft Power BI, se projevily jako vhodné, protože bylo pomocí nich dosaženo požadovaných výstupů. Kombinace Pythonu a Jupyter Notebooku naplnila veškerá očekávání. Za pomoci Jupyter Notebooku byly vytvořeny komentované, přehledné a graficky upravené postupy zpracování dat, které mohou dále sloužit jako návody a ukázky základní práce s daty pomocí jazyka Python.

Použití softwaru Power BI pro vizualizaci výsledků bylo jednoduché a intuitivní. Jedinou nevýhodou byla absence podpory operačního systému MacOS, v němž byla prováděna samotná práce s daty, a tak muselo být při řešení přepínáno mezi dvěma systémy, což s dnešními softwarovými nástroji nebyl problém.

Další rozvoj práce s těmito nástroji může spočívat například v propojení softwaru Power BI s Jupyter Notebookem a programovacím jazykem Python.

4.2 Použité metody

V rámci praktické části byly vyhodnoceny trendy jednotlivých klíčových ukazatelů výkonnosti. Dále byly vyhodnoceny a ověřeny vztahy mezi ukazateli pomocí Pearsonova korelačního koeficientu. Z výsledků vyplývá, že vyhodnocení trendů klíčových ukazatelů výkonnosti a vztahů mezi jednotlivými ukazateli určenými na základě Pearsonova korelačního koeficientu spolu koresponduje a vzájemně se doplňuje. Tím je prokázána správnost použitých metod.

Pro zpřesnění výsledků by bylo možné nahradit lineární trendy polynomy vyšších stupňů. V takovém případě by bylo nutné vyhodnocovat trendy v kratším časovém období. Protože požadavkem ze strany zadavatelské společnosti bylo vyhodnotit trendy globálně v období od září 2019 do září 2020, bylo přistoupeno k lineárním trendům. Další zpřesnění by mohlo přinést testování Pearsonova korelačního koeficientu na nižší hladině významnosti. V této práci byla zvolena standardní hladina 5 %.

5 ZÁVĚR

Předmětem bakalářské práce byla analýza sekundárních dat z technologie condition monitoring. Jednalo se o data z dvou výrobních strojů za období od září 2019 do září 2020. Cíle práce se odvíjely od požadavků ze strany brněnské energetické společnosti, se kterou bylo zadání práce vytvořeno, přičemž hlavním cílem bylo analyzovat data za účelem stanovení a vyhodnocení klíčových ukazatelů výkonnosti a jejich trendů v daném období.

V teoretické části práce byla provedena rešerše v oblasti technologie condition monitoring, byly vyzdviženy základní principy technologie a byl kladen důraz na rozvoj technologie v posledních letech, především ve spojení s průmyslovým internetem věcí. Dále byla provedena rešerše v oblasti klíčových ukazatelů výkonnosti a v oblasti dostupných softwarových produktů, která se zabývala programovacími jazyky Python a R a programovým prostředím MATLAB.

Praktická část se zabývala nejdříve výběrem vhodného softwarového produktu pro zpracování dat. Tím se stal programovací jazyk Python ve spojení s prostředím Jupyter Notebook. Tato kombinace byla zvolena na základě rostoucí popularity oproti ostatním nástrojům pro práci s daty v posledních letech. Pro vizualizaci dat byl zvolen software Microsoft Power BI, který přímo umožňuje tvorbu takzvaných reportních dashboardů.

Následoval rozbor dostupných dat. Z důvodu omezeného rozsahu dat nebylo možné stanovit všechny klíčové ukazatele výkonnosti představené v kapitole 2.2.1, a tak byly na základě rozboru dat vybrány klíčové ukazatele výkonnosti, které bylo možné stanovit. Dále proběhla samotná příprava, rozbor, analýza dat a stanovení klíčových ukazatelů výkonnosti. Po celou dobu přípravy a zpracování dat byl kladen důraz na čitelnost kódu a grafickou úpravu v prostředí Jupyter Notebook tak, aby čtenář jasně věděl, jak bylo s daty nakládáno, jaké funkce byly využity a co dané řádky kódu znamenají.

Nad rámec zadání bakalářské práce byly vytvořeny vizualizace klíčových ukazatelů výkonnosti formou dashboardů. Celkem byly vytvořeny čtyři dashboardy. Ke každému stroji jeden pro efektivitu a jeden pro údržbu. Vizualizace touto formou byla zvolena především pro možnosti prezentace několika klíčových ukazatelů výkonnosti vedle sebe.

Také byly stanoveny trendy klíčových ukazatelů výkonnosti. Trendy byly stanoveny proložení dat lineární křivkou. Tento přístup byl zvolen, protože nebylo ze strany zadavatelské společnosti žádáno reflektovat výchyly v dílčích časových úsecích, ale pouze stanovit globální trend za celé období. Dále byly stanoveny vztahy mezi jednotlivými ukazateli pomocí Pearsonova korelačního koeficientu. Významnost vztahů byla testována na hladině významnosti 5 %. Stanovené trendy jednotlivých ukazatelů mezi oběma stroji byly ve většině případech řádově stejné. Šlo tedy usoudit, že změny klíčových ukazatelů výkonnosti byly způsobeny globálními událostmi, nikoliv změnami

v efektivitě jednotlivých strojů. Vyhodnocení trendů klíčových ukazatelů výkonnosti a vztahů mezi ukazateli pomocí Pearsonova korelačního koeficientu vzájemně korespondovalo. Na základě toho lze považovat použité metody za správné.

Na závěr praktické části byla vyvozena doporučení plynoucí z analýzy dat. Bylo doporučeno provádět stanovení a vyhodnocení ukazatelů pravidelněji, ideálně okamžitě po uzavření týdnu a měsíce. V rámci rozšíření souboru stanovitelných klíčových ukazatelů výkonnosti byl doporučen sběr konkrétních dat. Také byl představen pohled na další rozvoj v praxi, který spočívá především v aktualizaci klíčových ukazatelů výkonnosti v reálném čase.

6 SEZNAM POUŽITÉ LITERATURY

- [1] TROUT, Jonathan. Breaking Down Condition Monitoring. *Reliable Plant* [online]. Tulsa: Noria Corporation, 2020 [cit. 2021-01-21]. Dostupné z: <https://www.reliableplant.com/condition-monitoring-31760>
- [2] *The condition monitoring comparison guide* [online]. 2020. Leiden: Semiotic Labs, 2020 [cit. 2021-01-21]. Dostupné z: <https://www.semioticlabs.com/app/uploads/2020/04/Condition-monitoring-comparison-guide-april-2020-edition.pdf>
- [3] MOHANTY, Amiya R. *Machinery Condition Monitoring: Principles and Practices*. Boca Raton: CRC Press, 2015. ISBN 978-1-4665-9305-3.
- [4] RANDALL, Robert Bond. *Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications*. Chichester: John Wiley, 2010. ISBN 978-0-470-74785-8.
- [5] RAO, B.K.N. a A. DAVIES. *Handbook of Condition Monitoring*. Cardiff: Springer Science+Business Media, 1998. ISBN 978-94-010-6065-3.
- [6] JAGERS, Simon. How is oil analysis used for condition monitoring? *Semiotic Labs* [online]. Leiden, 2020, 16 April 2020 [cit. 2021-01-28]. Dostupné z: <https://www.semioticlabs.com/resources/oil-analysis-condition-monitoring>
- [7] Bearing-Thermal. In: *Viper Imaging* [online]. [cit. 2021-01-23]. Dostupné z: <https://www.viperimaging.com/critical-asset-monitoring>
- [8] LLOYD REGISTER FOUNDATION. Key parts of the IIoT. In: *Bank Info Security* [online]. Princeton, July 24, 2020 [cit. 2021-03-05]. Dostupné z: https://dd80b675424c132b90b3-e48385e382d2e5d17821a5e1d8e4c86b.ssl.cf1.rackcdn.com/files/images_articles/iiotgraph-1.jpg
- [9] TROUT, Jonathan. Condition-based Maintenance: A Complete Guide. *Reliable Plant* [online]. Tulsa: Noria, 3. 6. 2020 [cit. 2021-03-16]. Dostupné z: <https://www.reliableplant.com/condition-based-maintenance-31823>
- [10] BERNET, John. P-F curve. In: *Fluke* [online]. Everett: Fluke Corporation, 2020 [cit. 2021-01-28]. Dostupné z: <https://dam-assets.fluke.com/s3fs-public/PF-Curve-1.png>
- [11] PARMENTER, David. *Key performance indicators : developing, implementing, and using winning KPIs*. 3rd edition. New Jersey: John Wiley, 2015. ISBN 978-1-118-92510-2.
- [12] MARR, Bernard. *Key Performance Indicators: The 75 measures every manager needs to know*. Harlow: Pearson Education, 2012. ISBN 978-0-273-75011-6.
- [13] 30 Best Manufacturing KPIs and Metric Examples for 2021 Reporting. *Insight Software* [online]. Insight Software, 2 January 2021 [cit. 2021-02-01]. Dostupné z: <https://insightsoftware.com/blog/30-manufacturing-kpis-and-metric-examples/>
- [14] SALONISH, Michael J. a Swati D. ALLEN. Key Performance Indicators: Where Do We Start? In: *JEMS* [online]. JEMS, 21. 2. 2018 [cit. 2021-02-02]. Dostupné z: <https://d3vik3nb0t4obe.cloudfront.net/wp-content/uploads/content/dam/jems/ems-insider/2018/02/1802jemsei.png>
- [15] SCHULTS, Carlos. Failure Metrics in Depth: MTTR vs. MTBF vs. MTTF. *Plutora* [online]. Santa Clara: Plutora, 12 November 2020 [cit. 2021-02-04]. Dostupné z: <https://www.plutora.com/blog/failure-metrics-mttr-vs-mtbf-vs-mttf>
- [16] PAINE, Steve. Mean Time To Detect (MTTD). In: *KPI Library* [online]. [cit. 2021-02-04]. Dostupné z: <https://kpilibrary.com/kpis/mean-time-to-detect-mtttd-2>

- [17] OZGUR, Ceyhun, Taylor COLLIAU, Grace ROGERS, Zachariah HUGHES a Elyse MYER-TYSON. MatLab vs. Python vs. R. *Journal of Data Science* [online]. Peking, 2017, (15), 355-372 [cit. 2020-12-28]. Dostupné z: <http://www.jds-online.com/files/150完成V.pdf>
- [18] Programming Languages for Data Science: Python vs R vs MATLAB. *Medium* [online]. Great Learning, 2020, Feb 24, 2020 [cit. 2020-12-28]. Dostupné z: <https://medium.com/@mygreatlearning/programming-languages-for-data-science-python-vs-r-vs-matlab-d3bfd04c991e>
- [19] MCKINNEY, Wes. *Python for data analysis*. Beijing: O'Reilly Media, 2012, xiii, 452 s. : il. + 1 CD-ROM. ISBN 978-1449319793.
- [20] KAN, Enoch. Data Science 101: Is Python better than R? *Towards Data Science* [online]. Aug 22, 2018 [cit. 2020-12-28]. Dostupné z: <https://towardsdatascience.com/data-science-101-is-python-better-than-r-b8f258f57b0f>
- [21] *Jupyter* [online]. [cit. 2020-12-28]. Dostupné z: <https://jupyter.org/>
- [22] Liechti Engineering. *GF Machining Solutions* [online]. [cit. 2021-02-19]. Dostupné z: <https://www.gfms.com/com/en/machines/milling/liechti-engineering.html>
- [23] Processing Equipment. In: *Changzhou 3D* [online]. Shanghai: Changzhou 3D Technological Complete Set Equipment Co. [cit. 2021-02-19]. Dostupné z: http://en.cz-3d.com/case_category/classid/220.html
- [24] ISEMINGER, David. *What is Power BI Desktop?* [online]. 10. 03. 2021 [cit. 2021-04-04]. Dostupné z: <https://docs.microsoft.com/cs-cz/power-bi/fundamentals/desktop-what-is-desktop>
- [25] SEMOTAM, Petr. *Data description*. Brno, 2020.
- [26] FÍRTOVÁ, Lenka. Korelace: co to je korelace a co znamená korelační koeficient. *Excel Town* [online]. [cit. 2021-5-6]. Dostupné z: https://exceltown.com/navody/pokrocila-analyza-regrese-korelace/korelace-co-to-vlastne-je/#pll_switcher

7 SEZNAM ZKRATEK, SYMBOLŮ, OBRÁZKŮ A TABULEK

Seznam zkratk a symbolů

AI	umělá inteligence	artificial intelligence
BI		business intelligence
CBM	údržba na základě stavu	condition-based maintenance
CM	monitorování stavu	condition monitoring
CNC	číslicové řízení počítačem	Computer Numerical Control
CSV	hodnoty oddělené čárkami	comma-separated values
DPMO	počet zmetků na milion příležitostí	defects per million opportunities
FPY	výtěžek prvního průchodu	First Pass Yield
FTIR	infračervená spektroskopie s Fourierovou transformací	Fourier-transform infrared spectroscopy
IIoT	industriální internet věcí	industrial internet of things
IR	infračervená termografie	infrared thermography
ISO	Mezinárodní organizace pro normalizaci	International Organization for Standardization
KPI	klíčový ukazatel výkonnosti	key performance indicator
MATLAB		matrix laboratory
MCSA	analýza proudového podpisu motoru	motor current signature analysis
MTBF	průměrná doba mezi poruchami	mean time between failures
MTTD	průměrná doba do detekce	mean time to detect
MTTF	průměrná doba do poruchy	mean time to failure
MTTR	průměrná doba do opravy	mean time to repair
NC	číslicové řízení	Numerical Control
NumPy		Numerical Python
OA	analýza maziv	oil analysis
OEE	celková efektivnost zařízení	Overall Equipment Effectiveness
pandas		Python Data Analysis Library
SciPy		Scientific Python
SOAP	Program spektrometrické analýzy maziva	Spectrometric Oil Analysis Program
SPM	metoda rázových pulzů	shock pulse method
VA	vibrační analýza	vibration analysis

A	dostupnost [-]
P	výkon [-]
Q	kvalita [-]
t	čas [s]
t _{cycle}	doba cyklu [s]
t _{detect}	doba do detekce [s]
t _{downtime}	doba prostoje [s]
t _{finish}	koncový čas [s]
t _{change}	doba přechodu [s]
t _{ideal}	ideální doba cyklu [s]
t _{m_planned}	plánovaná doba údržby [s]
t _{maintenance}	doba údržby [s]
t _{net}	čistý dostupný čas [s]
t _{planned}	plánovaná doba [s]
t _{production}	doba výroby [s]
t _{start}	počáteční čas [s]
t _{takt}	doba taktu [s]
X _{demand}	poptávané množství [ks]
X _{failure}	počet poruch [-]
X _{maintenance}	počet údržeb [-]
X _{opportunity}	počet příležitostí [-]
X _{quality}	počet kusů vhodné jakosti [ks]
X _{scrap}	počet zmetků [ks]
X _{total}	celkový počet [ks]

Seznam obrázků

- Obr. 1: Vývoj technik monitorování stavu
- Obr. 2: Příklad využití termální kamery pro monitorování ložisek
- Obr. 3: Klíčové části IIoT
- Obr. 4: P–F křivka
- Obr. 5: Postavení KPI při dosahování cílů ve společnosti
- Obr. 6: Znázornění metrik MTBF, MTTD, MTTR, MTTF
- Obr. 7: Srovnání prostředí MATLAB a jazyka Python
- Obr. 8: Měsíční procentuální podíl aktivních uživatelů
- Obr. 9: Liechti Turbomill 800g
- Obr. 10: Vyráběné lopatky parních turbín
- Obr. 11: Podoba dat *alarms.csv*
- Obr. 12: Schéma znázorňující jednotlivé KPI a jejich parametry

- Obr. 13: Ukázka části notebooku pro výpočet propustnosti
- Obr. 14: Ukázka datového rámce týdních KPI v prostředí Jupyter Notebook
- Obr. 15: Úvodní prostředí Power BI
- Obr. 16: Dashboard: Efektivita (stroj Liechti 1)
- Obr. 17: Ukázka interaktivní vizualizace propustnosti
- Obr. 18: Ukázka interaktivní vizualizace doby cyklu a doby přechodu
- Obr. 19: Dashboard: Údržba (stroj Liechti 1)
- Obr. 20: Ukázka interaktivní vizualizace míry prostoje
- Obr. 21: Ukázka interaktivní vizualizace metrik MTBF a MTTR

Seznam tabulek

- Tab. 1: Srovnání CBM s preventivní údržbou
- Tab. 2: Tabulka převodu DPMO na hodnotu Six Sigma
- Tab. 3: Trendy klíčových ukazatelů výkonnosti
- Tab. 4: Korelační koeficienty klíčových ukazatelů výkonnosti pro Liechti 1
- Tab. 5: Korelační koeficienty klíčových ukazatelů výkonnosti pro Liechti 2

8 SEZNAM PŘÍLOH

Příloha 1: 2021_BP_Kelbl_Jan_208722_PRILOHA.zip