



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

ÚSTAV VÝROBNÍCH STROJŮ, SYSTÉMŮ A ROBOTIKY

INSTITUTE OF PRODUCTION MACHINES, SYSTEMS AND ROBOTICS

**VYUŽITÍ PODNIKOVÝCH DAT K ZABEZPEČOVÁNÍ
KVALITY VÝROBKU**

USE OF COMPANY DATA TO ENSURE PRODUCT QUALITY

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jakub Gruber

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jana Rozehnalová, M.Sc.

BRNO 2021

Zadání diplomové práce

Ústav: Ústav výrobních strojů, systémů a robotiky
Student: **Bc. Jakub Gruber**
Studijní program: Strojní inženýrství
Studijní obor: Kvalita, spolehlivost a bezpečnost
Vedoucí práce: **Ing. Jana Rozehnalová, M.Sc.**
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 diplomové práce:

Využití podnikových dat k zabezpečování kvality výrobku

Stručná charakteristika problematiky úkolu:

S rozvojem technologií u výrobních linek dochází k novým možnostem sběru relevantních dat a údajů v rámci produkce ve vztahu k průběžné kontrole jakosti produktů. Práce se zaměřuje na technologie výroby a využití generovaných dat výrobních strojů v rámci podnikové praxe v kontextu znalostního managementu.

Cíle diplomové práce:

Rozbor a popis současného stavu vědy u řešené problematiky.
Systémový rozbor řešené problematiky, návrh a zdůvodnění zvoleného způsobu řešení zadaného úkolu.
Popis vybraného výrobního procesu a dostupných výrobních dat.
Návrh a aplikace zvoleného přístupu využití výrobních dat k řízení kvality výrobku.
Možnosti technicko–ekonomického posouzení dosaženého výsledku.
Vlastní závěr a/nebo doporučení pro další rozvoj řešené problematiky.

Seznam doporučené literatury:

PETRŮKOVÁ, Růžena. Moderní management znalostí: (principy, procesy, příklady dobré praxe). Praha: Professional Publishing, 2010, 323 s. ISBN 978-80-7431-011-9.
ČSN online [online]. Praha: Úřad pro technickou normalizaci, metrologii a státní zkušebnictví, 2016 [cit. 2016-11-04]. Dostupné z: <https://csnonline.agentura-cas.cz/>
NOVOTNÝ, Ota. Business intelligence: jak využít bohatství ve vašich datech. Praha: Grada, 2005, 254 s. ISBN 80-247-1094-3.

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

V Brně, dne

L. S.

doc. Ing. Petr Blecha, Ph.D.
ředitel ústavu

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

ABSTRAKT

Předmětem této práce je teoretický rozbor a popis využití podnikových dat. Důraz je kladen na systémový rozbor řešené problematiky. Hodnocen je konkrétní výrobní proces a z něho dostupná data, která pomáhají k nalezení technického a ekonomického vyhodnocení.

ABSTRACT

The task of the thesis is a theoretical analysis and description of the use of company data. Emphasis is placed on the system analysis of the problem. The specific production process and the data available from it are evaluated, which help to find a technical and economic evaluation.

KLÍČOVÁ SLOVA

Kvalita dat, hodnocení dat, MES systém, SCADA systém, přetrh tkaniny

KEYWORDS

Data quality, data evaluation, MES system, SCADA system, fabric break

BIBLIOGRAFICKÁ CITACE

GRUBER, Jakub. *Využití podnikových dat k zabezpečování kvality výrobku*. Brno, 2021. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/135177>. Diplomová práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav výrobních strojů, systémů a robotiky. Vedoucí práce Jana Rozehnalová.

ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že tato práce je mým původním dílem, zpracoval jsem ji samostatně pod vedením Ing. Jany Rozehnalové, M.Sc. a s použitím literatury uvedené v seznamu.

V Brně dne 21.5.2021

.....

Bc. Jakub Gruber

PODĚKOVÁNÍ

Tímto bych rád poděkoval vedoucí mé práce Ing. Janě Rozehnalové, M.Sc. za trpělivost a cenné rady poskytnuté při jejím vypracování. Dále bych rád poděkoval rodině za motivaci a podporu při studiu vysoké školy.

OBSAH

1	ÚVOD	10
2	FIREMNÍ DATA.....	11
2.1	Data a management znalostí	11
2.1.1	Analýza rizik.....	13
2.2	Kvalita dat.....	13
2.2.1	Přísné profilování a kontrola příchozích dat.....	14
2.2.2	Návrh datového kanálu	14
2.2.3	Přesné požadavky na data	15
2.2.4	Prosazování integrity dat	15
2.2.5	Integrace sledovatelnosti datové linie do datových kanálů	16
2.2.6	Automatizované regresní testování jako součást řízení změn	16
2.2.7	Výkonné týmy pro kontrolu kvality dat	16
2.2.8	Řízení kvality dat COBIT	17
3	MANAGEMENT DAT (PRÁCE S DATY)	19
3.1	Kroky v procesu analýzy dat	19
3.1.1	Definování otázky.....	19
3.1.2	Získání dat	19
3.1.3	Čištění dat	20
3.1.4	Analýza dat	20
3.1.5	Sdílení výsledků	21
3.2	SQL	21
3.2.1	Úlohy jazyka SQL	22
3.2.2	Funkce SQL	23
3.2.3	MySQL vs. MSSQL	23
4	SCADA	25
4.1	Části SCADA systémů.....	25
4.1.1	Dozorčí počítače	25
4.1.2	RTU	25
4.1.3	PLC.....	26
4.1.4	Komunikační infrastruktura.....	27
4.1.5	HMI	28
4.2	Příklad použití SCADA	28
5	MES SYSTÉM.....	29
5.1	Základní funkce MES	29
5.1.1	Správa zdrojů ve výrobě	29
5.1.2	Správa postupů ve výrobě.....	29
5.1.3	Plánování a rozvržení výroby	29
5.1.4	Řízení a sledování výroby	30
5.1.5	Sběr dat	30
5.1.6	Sledování výrobků a jejich původ	30
5.1.7	Výkonnostní analýzy KPI.....	30
5.2	Průmysl 4.0 a změny řídicích systémů	30
5.3	Vliv COVID-19 na automatizaci a robotizaci	32
5.3.1	Trendy v robotice pro rok 2021	32
5.4	OEE.....	33

5.4.1	Výpočet OEE	34
6	STROJOVÉ UČENÍ.....	35
6.1	Supervised learning (učení s učitelem)	35
6.1.1	Regression	36
6.1.2	Classification	36
6.2	Unsupervised Learning	37
6.2.1	Clustering.....	37
6.2.2	Dimensionality Reduction	38
6.3	Reinforcement Learning	38
6.3.1	Q-Learning.....	38
6.4	Semi-Supervised Learning.....	38
7	VYHODNOCENÍ DAT.....	39
7.1	Proces výroby	39
7.2	Sběr dat	41
7.3	Zpracování dat skaní	44
7.3.1	Týdenní přetřhy podle technologií pro všechny materiály.....	44
7.3.2	Týdenní přetřhy podle materiálů	45
7.3.3	Denní přetřhovost materiálu SLK 220x 1x 2 320/320s 259NA	46
7.3.4	Přetřhovost materiálu SLK 144x 1x 2 380/380s 259NA NOC	46
7.3.5	Využití technologií a strojů při skaní	47
7.3.6	Rozdělení prostoje při skaní	48
7.4	Zpracování dat tkaní	49
7.4.1	Příklad využití stroje 6701	49
7.4.2	Chod a prostoje stroje 6701	51
7.4.3	Prostoje „ruční stop“	51
7.5	Příklad úspor při snížení přetřhovosti	52
8	ZÁVĚR.....	54
9	SEZNAM POUŽITÝCH ZDROJŮ	55
10	SEZNAM ZKRATEK, TABULEK A OBRÁZKŮ	58
10.1	Seznam zkratk	58
10.2	Seznam tabulek	58
10.3	Seznam obrázků	59

1 ÚVOD

Sběr dat a jejich využití jsou velmi aktuálním tématem. Dá se říci, že data jsou v dnešní době sbírána neustále a o všem. Společensky nejdiskutovanějším je pravděpodobně sběr dat na internetu, kde tato data slouží pro zpřesnění cílových reklam.

S rozmachem průmyslu 4.0 se dá do budoucna v podnicích očekávat stále vyšší zájem o data. A ten je už nyní velmi vysoký. Průmyslové podniky se snaží získat z výrobního procesu co největší množství dat, která následně slouží ke zkvalitnění a zpřesnění výroby. Firmy používají sbíraná data k upevnění či zlepšení své pozice na trhu. Využívány jsou stále častěji nové techniky jako je strojové učení či umělá inteligence.

První část práce se věnuje teoretickým východiskům podnikových dat a v druhé části práce jsou zpracována data, která byla pro účely diplomové práce poskytnuta firmou zabývající se výrobou tkanin.

2 FIREMNÍ DATA


2.1 Data a management znalostí

Pro některé podniky je typické zahlcení daty a informacemi, přitom požadovaných důležitých informací je k dispozici málo, často chybí zcela úplně. Dnes jsou to převážně globálně konkurenční podniky, které se vyznačují mobilizací svých znalostních zdrojů. Rozvoj v této oblasti a péče o zdroje se v současné době stávají důležitými determinanty vysoké výkonnosti. Nestačí mít pouze dostatek informací, je zapotřebí tato data třídit a zpracovávat s ohledem na jejich obsah a využití v podnikovém řízení. V dnešní době se znalosti stávají jedním z nejvýznamnějších faktorů konkurenční výhody organizace [1].

Úspěšné podniky dnes přesunují svoji maximální pozornost právě na znalosti: jejich vznik, transformaci, způsob uložení do paměti, výběr, zpracování, využití a hodnocení vynaložených nákladů na jejich efektivitu a další rozvoj. Nejde jen o pouhé hromadění informací, ale o pokrytí konkrétních potřeb podniku. Komplexní poznání je možno považovat za množinu optimálních dat, potřebných znalostí a využitelných informací vztahujících se k dané problematice [1].

Závislost mezi daty, informacemi a znalostmi je chápána tak, že data představují „výrobní surovinu“, která se mění na informaci. Znalosti poté vymezují základní rámec pro myšlenkové procesy interpretace informací a dat. Znalost lze popsat jako čin, činnost nebo akci. Informace je symbolický popis akce. Rozdíl mezi informacemi a znalostmi je významný. Informace je zapotřebí ke vstupu do znalostního procesu koordinace činností. Dosažení vytčeného účelu skrze akci je důkazem praktické a použitelné informace [1].

Na Obr. 1 je sledován logický proces od zpracování dat až po systémy managementu znalostí. Zatímco data nemají explicitní obsah a jejich účel je mnohdy nečitelný a nejasný, informace poskytují předzvěst účelu a cíle. Zatímco u dat je kontext zapotřebí domýšlet, u informací je kontext daleko specifičtější [1].



Obr. 1) Vztah mezi daty, informacemi a znalostmi [1]

U podnikových procesů a projektů je nejdůležitější v první řadě vědět proč, dále co, a teprve nakonec jak. Tradiční organizace ale bohužel často postupuje přesně naopak: nakoupí se řada technologií, zavedou se četné funkce a shromáždí se velké množství dat a informací. Poté se nakoupí informační systémy a získané informace se zafixují. Až nyní se ale začne klást základní otázka: proč? Často je nakonec zjištěna smutná skutečnost, že v podniku chybějí potřebné znalosti k nalezení a dosažení vytyčených cílů. Obr. 2 popisuje proces tvorby znalostí. Informace jsou pouhé vstupy do znalostních procesů, nelze jim tedy přizpůsobovat znalosti organizace [1].



Obr. 2) Proces tvorby znalostí [1]

Management znalostí by se měl postarat o to, aby znalosti nebyly pouze hromaděny, ale i včasné a vhodně využity. K tomu patří šíření znalostí a cílevědomá analýza účinnosti všech opatření související s KM (knowledge management, česky management znalostí, viz Obr. 3). Mezi povinnostmi manažera musí patřit i péče o informační a znalostní zabezpečení zaměstnanců [1].

Stávající znalosti	s průmětem do vize, mise, strategií...
Tvorba znalostí	Lidé nacházejí nové způsoby práce, management rozvíjí know-how v oblastech práce s LZ - přijímání pracovníků, hodnocení, odměňování, motivace, komunikace, vzdělávání.
Zachycení znalostí	Posouzení hodnoty nových znalostí, nalezení způsobů jejich prezentace napříč organizací, motivace, komunikace.
Zařazení znalostí	Nové znalosti musejí být zařazeny do správného kontextu pro využití různých osob a skupin /týmů, týmové činnosti.
Ukladnění znalostí / znalostní sklady	Uložení znalostí v rozumné formě, připravené kdykoliv k využití, průmět do podnikových informačních systémů.
Správa znalostí	Musí být neustále revidovány a ověřovány z hlediska významu a přesnosti/ manažerské auditu
Rozšiřování znalostí	Znalosti musí být zpřístupněny v použitelné formě komukoli, kdo je v organizaci momentálně potřebuje/ neustálé vzdělávání, komunikace, motivace

Obr. 3) Cyklus managementu znalostí [1]

Pro management informací má organizace:

- Identifikovat jaké informace jsou potřeba.
- Určit a získat interní a externí informační zdroje.
- Převést informace na znalosti.
- Využívat údaje, informace a znalosti k vytvoření a plnění cílů.
- Zajistit ochranu a důvěrnost.
- Hodnotit z informací odvozené přínosy ke zlepšení managementu informací a znalostí.

V tomto kontextu se dá konstatovat, že efektivní podnikové řízení nemůže být nikdo orientováno pouze na jednu konkrétní část systému, metodu, technologii či zdroj. Vždy se jedná širokou škálu vzájemně provázaných aktivit. Totéž platí i pro péči o znalosti [1].

2.1.1 Analýza rizik

Všechny oblasti lidské činnosti jsou do jisté míry zatíženy určitou mírou rizika. To platí i pro firmy a podniky. Povinností odpovědného managementu by pak měla být schopnost reagovat na problémy a možná rizika. Ty také vyhledávat a přijímat opatření, která vedou k jejich zamezení. Management provádí analýzu rizik, stanovuje jejich prioritu a přijímá potřebná opatření. Zavedení efektivního systému řízení rizik je nedílnou součástí knowledge managementu. Stupeň významnosti rizika je určen podle možných nežádoucích dopadů a pravděpodobnosti, že daná situace skutečně nastane [3].

Na manažerské rozhodování lze nahlížet z několika úhlů. Obecně se dají rozhodovací problémy dělit na dobře a špatně strukturované. U dobře strukturovaných problémů existují opakovaná řešení a rutinní postupy. Dají se tedy považovat za programovatelné a algoritmovatelné. Špatně strukturované problémy vyžadují tvůrčí přístup, intuici a zkušenosti. Na rozdíl od dobře strukturovaných problémů se jedná o problémy nové a neopakovatelné. Typická je existence více faktorů, které ovlivňují řešení, kdy některé z nich nejsou známy. Management rizik lze označit za preventivní činnosti, které slouží k poznání a minimalizaci rizik. Účinný risk management by měl obsahovat:

- analýzu rizik,
- hodnocení rizik,
- řízení rizik.

Analýza rizik je proces, při kterém jsou dostupné informace použity k identifikaci potenciálního nebezpečí a odhadu rizika. Chráněn je zájem společnosti z hlediska ochrany života, zdraví, majetku a životního prostředí. Při hodnocení rizik je na základě analýzy rizika vytvářen úsudek o přijatelnosti rizika. V úvahu se berou sociálně-ekonomické faktory či vliv na životní prostředí. Řízení rizika je proces, při kterém jsou realizována rozhodnutí týkající se rizik [3].

2.2 Kvalita dat

Data se dají považovat za kvalitní, splňují-li požadavky zamýšleného použití. Analogií by mohla být kvalita produktu vyráběného výrobcem, u kterého samotná kvalita produktu není obchodním výsledkem, zvyšuje ale spokojenost zákazníka a dále ovlivňuje hodnotu daného produktu. Podobně je i kvalita dat důležitým atributem, který může zvyšovat hodnotu dat, a tím ovlivňovat přesnost rozhodování, spokojenost zákazníka a výsledky podnikání [4].

Kritéria používaná k měření kvality dat:

- Přesnost: všechna popisovaná data musí být přesná.
- Relevance: data by měla splňovat požadavky pro zamýšlené použití.
- Úplnost: data by měla obsahovat všechny hodnoty a záznamy.
- Aktuálnost: data musí být aktuální. Zastaralá či neaktuální data nemají de facto žádnou hodnotu.
- Konzistence: uložení dat tak, aby byla ve vzájemných vztazích, které kopírují skutečné vztahy mezi objekty [4].

Standart pro kvalitu dat se liší v závislosti na požadavcích a povaze dat samotných. Aby společnost mohla poskytnout data v dobré kvalitě, musí spravovat a řídit každé úložiště dat v kanálu od začátku do konce. Mnoho organizací se zaměřuje na kontrolu dat až v pozdní fázi. To má často za následek nalezení problému až ve chvíli, kdy je příliš pozdě. Často dlouho trvá zjistit, odkud problém pochází nebo je jeho odstranění finančně a časově náročné [4].

Pokud však společnost dokáže zajistit kvalitu dat každé datové sady v době, kdy je přijata nebo vytvořena, je kvalita dat přirozeně zaručena. K tomu je třeba provést 7 základních kroků, které jsou představeny v následujících kapitolách.

2.2.1 Přísné profilování a kontrola příchozích dat

Ve většině případů špatná data pocházejí z příjmu dat. V organizaci pocházejí data obvykle z jiných zdrojů mimo kontrolu společnosti nebo oddělení. Mohou to být data od jiné organizace či v mnoha případech data shromážděná softwarem třetích stran. Z tohoto důvodu nelze plně zaručit kvalitu dat. Přísná kontrola kvality příchozích dat je možná nejdůležitějším aspektem mezi všemi úkoly kontroly jejich kvality. Vhodný je pak dobrý nástroj pro profilování dat. Takový nástroj by měl být schopen zkoumat následující aspekty údajů:

- formát dat,
- konzistence dat u každého záznamu,
- rozdělení a abnormality hodnot,
- úplnost údajů.

Je také nezbytné automatizovat profilování a upozornění na kvalitu dat, aby byla kvalita příchozích dat vždy důsledně kontrolována a spravována. Nikdy se nedá předpokládat, že příchozí data jsou bez profilování a kontrol tak dobrá, jak se očekávalo. Dále by každá část příchozích dat měla být spravována pomocí stejných standardů a osvědčených postupů [4].

2.2.2 Návrh datového kanálu

Datový kanál by měl být navržen tak, aby nedocházelo k duplikaci dat. Duplicitní data se vztahují k tomu, kdy je část dat vytvořena ze stejného zdroje dat pomocí stejné logiky, ale různými lidmi nebo týmy pro různé účely. Duplicitní data jsou často nesynchronizovaná a vedou k rozdílným výsledkům. Při objevení problému s daty je pak obtížné a mnohdy časově náročné najít hlavní příčinu [4].

Je třeba jasně definovat a pečlivě navrhnout datový kanál v oblastech, jako jsou datová aktiva, modelování dat, obchodní pravidla a architektura. Efektivní komunikace je nutná k podpoře sdílení dat v organizaci, což zlepšuje celkovou efektivitu a snižuje jakékoli potenciální problémy s kvalitou dat způsobené duplikací.

3 oblasti, které zabrání vytváření duplicitních dat, jsou:

- Program správy dat, který jasně definuje vlastnictví datové sady a účinně komunikuje a podporuje sdílení datové sady.
- Centralizovaná správa datových aktiv a modelování dat, které je pravidelně kontrolována.
- Jasný logický design datových kanálů na podnikové úrovni, který je sdílen napříč organizací.

S dnešními rychlými změnami v technologických platformách je spolehlivá správa dat nesmírně důležitá [4].

2.2.3 Přesné požadavky na data

Důležitým aspektem kvality dat je schopnost uspokojit požadavky a poskytnout klientům a uživatelům data k požadovanému účelu. To není tak jednoduché, jelikož:

- Není snadné data správně určit. Skutečné pochopení toho, co klient hledá, vyžaduje důkladnou analýzu a jasnou komunikaci, často prostřednictvím příkladů a vizualizací.
- Požadavek by měl zachycovat všechny scénáře dat. Považuje se za neúplný, pokud nejsou přezkoumány a zdokumentovány všechny závislosti.
- Jasná dokumentace požadavků se snadným přístupem a sdílením je dalším důležitým aspektem, který by měl být prosazován.

Při shromažďování požadavků je zásadní role obchodního analytika. Jeho porozumění klientům i současným systémům mu umožňuje mluvit za obě strany. Po shromáždění požadavků obchodní analytik provádí analýzu dopadů. Pomáhá také přijít s plány testů, aby se ujistil, že produkováná data splňují zadané požadavky. V praxi velmi často dochází k problémům v komunikaci mezi manažerem a programátorem. Objevuje se zde velké riziko nepochopení požadavku pro datovou analýzu [4].

2.2.4 Prosazování integrity dat

Pojem integrity dat označuje záruku úplnosti dat v datovém souboru. Týká se přesnosti a konzistence dat v průběhu jeho životního cyklu. Kompromitovaná data nejsou pro podniky užitečná, nemluvě o nebezpečí způsobeném případnou ztrátou dat citlivých. Z tohoto důvodu jsou procesy integrity dat nezbytnou součástí účinných podnikových bezpečnostních protokolů. Při každé duplikaci či přenosu by měla data mezi aktualizacemi zůstat neporušená a nezměněná. Integritu dat může být narušena několika způsoby:

- Lidská chyba: může být úmyslná či neúmyslná.
- Chyby během přenosu: například neúmyslná změna dat během přenosu dat z jednoho zařízení na zařízení druhé.
- Chyby, viry, malware či jiné kybernetické hrozby.
- Rozbitý hardware: například selhání pevného disku.

Termín integrity dat také vede ke zmatku, protože může odkazovat buď na stav nebo na proces. Integrity dat jako stav definuje datovou sadu, která je platná i přesná. Na druhé straně integrity dat jako proces popisuje opatření použitá k zajištění platnosti a přesnosti datové sady nebo všech dat obsažených v databázi. Metody kontroly a ověřování chyb mohou být označovány jako procesy integrity dat [5].

Když roste objem dat spolu s více zdroji, ne všechny datové sady mohou fungovat v jednom databázovém systému. Referenční integritu dat je proto třeba vynutit aplikacemi a procesy, které je třeba definovat podle osvědčených postupů správy dat a zahrnout je do návrhu implementace. V dnešním světě velkých dat je referenční vymáhání stále obtížnější. Bez myšlenky prosazování integrity na prvním místě by odkazovaná data mohla být zastaralá nebo neúplná, což by vedlo k vážným problémům [4].

2.2.5 Integrace sledovatelnosti datové linie do datových kanálů

U dobře navrženého datového kanálu by se čas potřebný k řešení problému neměl zvyšovat se složitostí systému nebo objemem dat. Bez sledovatelnosti datové linie zabudované do kanálu by sledování příčiny při problému s daty mohlo trvat hodiny nebo dny. To někdy může vyžadovat, aby datoví inženýři prozkoumali kód [4].

Sledovatelnost datové linie má 2 aspekty:

- Metadata: schopnost sledovat vztahy mezi datovými sadami, datovými poli a transformační logikou mezi nimi.
- Samotná data: schopnost rychle vysledovat problém s daty k jednotlivým záznamům.

Sledovatelnost metadat je podstatnou součástí efektivní správy dat. Umožňuje ji jasná dokumentace a modelování každé datové sady. Když je datový kanál navržen a vynucen správou dat, měla by být současně zajištěna sledovatelnost metadat. Sledovatelnost dat je pak obtížnější než sledovatelnost metadat. Navrhnout a implementovat sledovatelnost dat trvá určitou dobu. Je ovšem strategicky zásadní sledovatelnost od začátku zahrnout do datového kanálu. Stojí to za vynaložené úsilí, jelikož sledovatelnost v případě problému s kvalitou dat ušetří značné množství času. Sledovatelnost dat dále vytváří základ pro další zlepšování zpráv o kvalitě dat, což umožňuje zjistit problémy s daty dříve, než jsou data doručena klientům či interním uživatelům [4].

2.2.6 Automatizované regresní testování jako součást řízení změn

K problémům s kvalitou dat často dochází při zavedení nové datové sady nebo při úpravě datové sady již existující. Při efektivním řízení změn by testovací plány měly zajistit, že nedochází k neúmyslným změnám dat v kanálech. S rychlým pokrokem technologií ve velkých datech dochází často k změnám a automatizovaný regresní test s důkladným porovnáním dat je nutností, aby bylo zajištěno konzistentní zachování dobré kvality dat [4].

2.2.7 Výkonné týmy pro kontrolu kvality dat

2 týmy mají kritickou roli v zajištění vysoké kvality dat pro organizaci:

- Zajištění jakosti: tento tým kontroluje kvalitu softwaru a programů, kdykoli dojde ke změnám. Důkladné řízení změn prováděné tímto týmem je zásadní pro zajištění kvality dat v organizaci, která prochází rychlými změnami.
- Kontrola kvality produkce: tým musí dobře rozumět obchodním pravidlům a obchodním požadavkům. Musí být vybaven nástroji pro detekci abnormalit, odlehlých hodnot a dalších neobvyklých scénářů, které se mohou v produkci vyskytnout. Cílem tohoto týmu je identifikovat jakékoli problémy s kvalitou dat a nechat je opravit dříve, než si problémů všimnou uživatelé a klienti.

Vysoká kvalita dat vyžaduje důslednou správu dat příchozích, přesné shromažďování požadavků, důkladné regresní testování pro řízení změn a pečlivý návrh datových kanálů.

Je vždy mnohem jednodušší a méně nákladné snažit se zabránit vzniku problémů s daty než ony problémy řešit při jejich objevení [4].

2.2.8 Řízení kvality dat COBIT

Zkratka COBIT neboli Control Objectives for Information and Related Technology je nástroj pro řízení informatiky, kontrolní nástroj pro auditory a model zralosti. COBIT je hojně využívanou platformou pro řízení kvality. Cílem je propojit principy řízení organizace s pravidly, která jsou uplatňovaná v prostředí ICT (informační a komunikační technologie). Metodika COBIT se snaží strukturovat složitý systém řízení ICT tak, aby se tato struktura stala srozumitelnou i pro manažery a další uživatele bez hlubších znalostí ICT. COBIT umožňuje těmto pracovníkům vytvořit objektivní kritéria, podle kterých je možné posoudit úspěšnost či neúspěšnost jednotlivých oblastí řízení ICT [6].

COBIT definuje čtyři obecné cíle pro úspěšné řízení ICT:

- přispění ke kvalitnímu fungování organizace,
- orientace na uživatele,
- zajištění provozní dokonalosti,
- zaměření na možnosti rozvoje v budoucnosti.

Zajistit tyto obecné cíle není jednoduché. Správné pochopení principů a vztahů zformulovaných v metodice COBIT je důležité pro správné řízení ICT. Je důležité si uvědomit, že metodika COBIT není určena pro každodenní řízení chodu ICT útvarů. Použití metodiky COBIT by mělo sloužit pro komunikaci mezi pracovníky mimo ICT.


COBIT se dá označit za balíček 6 publikací [6]:

- Executive summary – popis konceptů, principů, obsah. Jedná se o shrnutí pro management.
- Framework – jedná se o popis IT procesů, informačních kritérií a IT zdrojů.
- Control Objectives – popis přínosů detailních kontrolních kritérií pro IT procesy.
- IT Assurance Guide – jedná o návrh kontrolních činností a identifikace rizik. Často využíván auditory.
- Implementation Tool Set – obsahuje případové studie uživatelů COBIT, prezentace pro management.
- Management Guidelines – obsahuje modely vyspělosti procesů, klíčové cílové ukazatele (KGI) a klíčové ukazatele výkonnosti (KPI).

COBIT je ucelená a komplexní metodika, která nachází uplatnění u těchto skupin pracovníků:

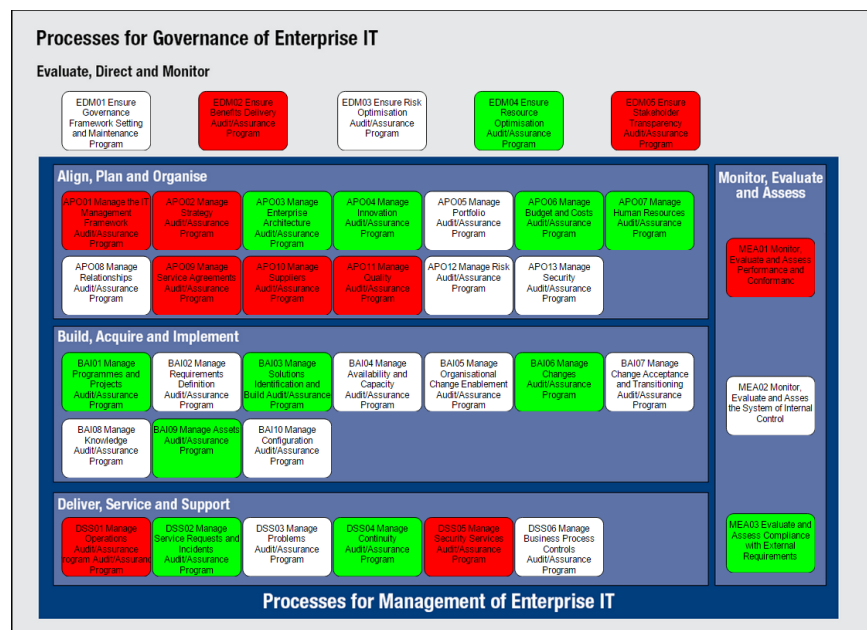
- Management – COBIT managementu usnadňuje orientaci ve složitém prostředí ICT. Manažeri musí rozhodovat o výdajích do provozu ICT a vyhodnotit, zdali jsou výdaje správně a efektivně využívány.
- Uživatelé – vyskytuje se u nich stále vyšší potřeba seznámit se s fungováním ICT.
- Auditři – COBIT jim poskytuje rámec pro způsob hodnocení správnosti nasazení ICT.

COBIT strukturuje podnikovou informatiku do domén. Tyto domény pak na jednotlivé procesy a tyto procesy na jednotlivé činnosti. Spojením těchto prvků vzniká model, který je obvyklé prezentován ve tvaru kostky. Ta je viditelná na následujícím Obr. 4.



Obr. 4) COBIT Kostka [6]

Na Obr. 5 je vidět příklad hodnotící karty pro COBIT. Ta byla vytvořena za použití programu Dragon1.



Obr. 5) Příklad hodnotící karty pro COBIT [7]

3 MANAGEMENT DAT (PRÁCE S DATY)

3.1 Kroky v procesu analýzy dat

Práce a analýza dat se řídí přesně daným procesem. Každá fáze vyžaduje jiné dovednosti a know-how. K získání smysluplných poznatků je klíčové porozumět procesu jako celku. Proces analýzy dat se dá charakterizovat několika hlavními kroky, které jsou popsány v následujících kapitolách.

3.1.1 Definování otázky

Prvním krokem v procesu analýzy dat by mělo být definování úkolu. Definovat úkol znamená přijít s hypotézou a zjistit, jak ji otestovat. Je vhodné uvědomit si jaký obchodní problém má být vyřešen. To zní jednoduše, může to ovšem být složitější, než se zdá. Úkolem datového analytika je porozumět podnikáním a jeho cílům do takové míry, aby mohl být problém vyřešen správných způsobem. Například ve firmě, která nebude mít problém se zajišťováním nových zákazníků, ale s tím, že se tito zákazníci již nevrací, není vhodné se ptát: „Proč firma ztrácí zákazníky?“ ale „Co negativně ovlivňuje zákaznickou zkušenost?“ či ještě lépe: „Jak je možné podpořit udržení zákazníků při minimalizaci nákladů?“ Nyní je problém jasně definován a stačí určit, která data ho pomohou nejlépe vyřešit. Definování cíle většinou záleží na obchodních znalostech a měkkých dovednostech. Sledují se ale i další obchodní metriky [8].

3.1.2 Získání dat

Jakmile je úkol definovaný, může se začít vytvářet vhodná strategie pro shromažďování dat. Klíčové je určit, která data jsou potřebná. Může se jednat o kvantitativní data, např. prodejní statistiky, či data kvalitativní, např. recenze zákazníků. Všechny data zapadají do jedné ze tří kategorií:

Data první strany

Data, která si společnost shromáždila přímo od zákazníků. Obvykle jsou strukturována jasným a definovaným způsobem. Zdrojem těchto dat mohou být informace z CRM (Customer Relationship Management, v překladu řízení vztahů se zákazníky) či průzkumy spokojenosti. [8].

Data druhé strany

K obohacení vzorku dat jsou často využívána data druhých stran. Jedná se vlastně o data první strany jiných organizací. Bývají strukturovaná, a přestože jsou zpravidla méně relevantní než data první strany, mají tendenci být spolehlivá. Příkladem mohou být aktivity na webu (včetně historie online nákupů) [8].

Data třetí strany

Data třetích stran jsou data, která byla shromážděna z mnoha rozdílných zdrojů organizací třetí strany. Tato data jsou velmi často nestrukturovaná, organizace je sbírají za účelem průzkumu trhu či vytvoření zprávy o daném odvětví. Organizace poté tyto data dále prodávají dalším společnostem [8].

3.1.3 Čištění dat

Jakmile jsou data shromážděna, je nutné je připravit na analýzu. Toto čištění má zajistit, že se skutečně pracuje s vysoce kvalitními daty. Mezi klíčové úkony čištění patří:

- Odstranění chyb, duplikátů a odlehlých hodnot – jedná se o nevyhnutelné problémy při shromažďování dat z více zdrojů.
- Odstranění nežádoucích dat – irelevantní data, která nemají vliv na zamýšlenou analýzu.
- Strukturalizace dat – jedná se například o úpravu překlepů či rozložení dat.
- Doplnění důležitých dat – při úpravě dat může vyjít na povrch, že chybí některá důležitá data. Ta mohou být v některých případech doplněna.

Analytici stráví nad čištěním času vysoké množství času. Špatně vyčištěná data či analýza chybných dat mohou mít vážný dopad na výsledky. Vedle čištění dat mnozí analytici provádí také průzkumnou analýzu. Ta pomáhá identifikovat počáteční trendy a charakteristiky. Navíc může dokonce vylepšit danou základní hypotézu. Ruční čištění může být skličující, existují však nástroje k jeho zefektivnění. Jsou to například open-source nástroje jako OpenRefine, které pomáhají s čištěním dat. Ty jsou ovšem funkčně limitované pro velké datové sady [8].

3.1.4 Analýza dat

Po vyčištění dat přichází jejich analýza. Typ prováděné analýzy dat do značné míry závisí na cíli analýzy. Existuje mnoho technik, mezi ně patří například analýza časových řad či regresní analýza. Důležitější než typ techniky je však způsob použití dané techniky. Obecně se dá říct, že všechny typy analýz zapadají do jedné ze čtyř kategorií:

Popisná analýza

Popisná analýza identifikuje, co se již stalo. Jedná o běžně prováděný první krok, který je prováděn před pokračováním v hlubších průzkumech. Společnost tyto údaje může využít například k měření prodejů za určité období. I když společnost nemusí z těchto poznatků vyvodit pevné závěry, shrnutí a popis údajů může pomoci k tomu, jak dále postupovat [8].

Diagnostická analýza

Diagnostická analýza pomáhá pochopit, proč se něco stalo. Jedná se doslova o diagnózu problému. Například na dříve položenou otázku „Co negativně ovlivňuje zákaznickou zkušenost?“ by mohla odpovědět diagnostická analýza. Ta může společnosti najít vzájemný vztah mezi problémem a faktory, které jej způsobují [8].

Prediktivní analýza

Prediktivní analýza pomáhá identifikovat budoucí trendy na základě historických dat. V podnikání se tato analýza používá například k predikci budoucího růstu společnosti. Prediktivní analýza je v posledních letech stále sofistikovanější. Rychlý vývoj strojového učení umožňuje organizacím vytvářet překvapivě přesné předpovědi, jedním příkladem za všechny může být obor pojišťovnictví. Poskytovatelé pojištění používají minulá data k předpovědi, které skupiny osob se pravděpodobně stanou účastníky nehod. Výsledkem je zvýšení pojistky u dané skupiny [8].

Preskriptivní analýza

Tato analýza umožňuje společnosti dělat doporučení do budoucna. Jedná se o poslední a nejkomplexnější krok v analytické části procesu. To proto, jelikož zahrnuje aspekty všech dříve popsanych analýz. Příkladem pro tuto analýzu by mohly být autonomní automobily

a jejich algoritmy. Tyto algoritmy dělají každou sekundu nespočet rozhodnutí na základě minulých i současných dat a zajišťují bezpečnou jízdu automobilu. Předpisová analýza zkoumá, co se stalo, proč se to stalo a co se může stát, aby bylo možné určit nejlepší postup do budoucna. Pomáhá tak například společností s novými produkty či novými oblastmi podnikání [8].

3.1.5 Sdílení výsledků


Po dokončení analýz je posledním krokem sdílení výsledků, které z těchto analýz vycházejí. Nejde pouze jen o sdílení hrubých výsledků analytické práce. Jde o to, aby byly výsledky srozumitelné pro všechny jejich příjemce. Z tohoto důvodu jsou často využívány reporty, grafy a interaktivní vizualizace. Interpretace výsledků je nesmírně důležitá a často ovlivňuje směr, jakým se podnikání či společnost vydá. Firma se na tak základě výsledků může například rozhodnout, zda produkt podpoří, pozmění či zcela zruší. Proto je nesmírně důležité sdílet všechna důkazná data, která jsou nashromážděna. Na druhou stranu je nutné zmínit všechny potenciální mezery v datech [8].

3.2 SQL

Jazyk SQL (Structured Query Language, česky strukturovaný dotazovací jazyk) a relační databázové systémy, které jsou na jeho základy postaveny, představují jednu z nejdůležitějších základních technologií v průmyslu. V dnešní době SQL představuje standart pro počítačové databázové jazyky. Jazyk SQL podporuje nevídané množství databázových produktů. SQL je ke správě dat používán prakticky všemi hlavními produkty.

SQL je nástroj vhodný pro organizaci, správu a získávání dat, která jsou uložena v počítačové databázi. SQL je počítačový jazyk, který je používán pro komunikaci s databází. SQL pracuje se specifickým typem databáze, které se říká relační databáze [9].

Na Obr. 6 je ukázán způsob práce SQL. Zobrazený počítačový systém obsahuje databázi, ve které jsou uloženy důležité informace. Počítačový program, který řídí databázi, se nazývá databázový řídicí systém. Při potřebě získání dat z databáze je napsán požadavek v jazyce SQL. Ten je dále zpracován databázovým systémem, data jsou načtena a vrací se odpovídající informace. Proces, kdy jsou požadována data z databáze a vrací se výsledek, se nazývá databázový dotaz (query) [9].



Obr. 6) Způsob práce SQL [9]

SQL představuje mnohem víc než pouhý dotazovací nástroj, i když to byl jeho primární účel a získávání dat stále patří mezi nejdůležitější funkce. SQL lze také použít k řízení těchto funkcí poskytovaných databázovým systémem:


- Definice dat – SQL umožňuje uživateli definovat strukturu a organizaci uložených dat spolu s definicí jejich vzájemných vztahů.
- Získávání dat – SQL umožňuje uživateli či aplikačnímu programu získávat a používat uložená data z databáze.
- Manipulace s daty – SQL umožňuje uživateli nebo aplikačnímu programu databázi aktualizovat přidáváním nových dat, odstraňováním starých dat či změnou dat již dříve uložených.
- Řízení přístupu – SQL lze použít při potřebě omezení schopnosti uživatele číst, přidávat a modifikovat data. Tímto lze chránit před neautorizovaným přístupem.
- Sdílení dat – SQL se používá ke sladění sdílení dat mezi více uživateli. Dále také k zajištění toho, aby se mezi sebou uživatelé nerušili.
- Integrace dat – SQL definuje v databázi omezení integrity. To ji chrání před porušením, které by mohlo vzniknout kvůli neúplným aktualizacím či systémovým selháním.

SQL je tedy komplexní jazyk pro řízení a ovlivňování databázového systému. SQL se stal standardem pro použití v relačních databázích [9].

3.2.1 Úlohy jazyka SQL

Samotný SQL není databázový řídicí systém, ani se nejedná o samostatný produkt. SQL je integrovanou součástí databázového systému jakožto nástroj pro komunikace s ním.

Databázový stroj se dá považovat za srdce databázového řídicího systému. Nese zodpovědnost za vlastní členění, ukládání a získávání dat z databáze. Je příjemcem požadavků SQL z jiných částí systému, uživatelských aplikačních programů či jiných počítačových systémů. Na Obr. 7 jsou vidět jednotlivé součásti databázového systému. Je také zřejmé, že SQL spojuje jednotlivé komponenty [9].



Obr. 7) Části typického databázového řídicího systému [9]

3.2.2 Funkce SQL

SQL zastává několik funkcí. Hlavními z nich jsou:

- SQL je interaktivní dotazovací jazyk. Pomocí konverzačního jazyka jsou uživateli zadávány příkazy a získaná data se objevují na obrazovce. Jedná se o jednoduchý nástroj pro dotazování se databáze.
- SQL je databázový programovací jazyk. Příkazy mohou být programátory začleněny do aplikačních programů. Tím jsou získány přístupy k datům v databázi. Tato technika přístupu k databázi je používána jak uživatelsky psanými programy, tak i pomocnými databázovými programy.
- SQL je administrativní databázový jazyk. Jazyk SQL je administrátorem používán k definování databázové struktury a k řízení přístupu k uloženým datům. Administrátor je typicky zodpovědný za správu databáze.
- SQL je jazyk aplikací typu klient/server. Jazyk SQL je používán programy ke komunikaci s databázovými servery umístěnými na síti. Ty uchovávají sdílená data. Jedná se o architekturu velmi populární u podnikových aplikací.
- SQL je jazyk pro přístup k datům na internetu. Webové servery pracující se společnými daty a internetové aplikační servery používají SQL jako standardní jazyk pro přístup ke společným databázím.
- SQL je distribuovaný databázový jazyk. SQL pomáhá systémům správy distribuovaných databází při rozmísťování dat mezi propojenými počítačovými systémy.
- SQL je jazyk pro databázové brány. Počítačová síť, která je tvořena směsicí různých databázových produktů, SQL často používá jako bránu. Ta umožňuje spolu komunikovat různým druhům databázových systémů [9].

3.2.3 MySQL vs. MSSQL

MySQL i MSSQL (Microsoft SQL Server) jsou široce používané databázové systémy. MySQL je open-source¹ relační databáze představená v roce 1995, zatímco MSSQL je databáze vyvinutá společností Microsoft a představená již v roce 1989. Obě řešení jsou v produkci již déle než 2 desetiletí a mají silnou pozici na trhu. Ačkoli se MySQL a SQL Server databáze zdají podobné, jejich základní architektury se liší. Existují tak mnohé podobnosti, ale zároveň i odlišnosti [10].

Podobnosti mezi MySQL a MSSQL:

- Tabulky – oba databázové systémy používají standardní modely tabulek pro ukládání dat ve sloupcích a řádcích.
- Vysoký výkon – databáze jsou zodpovědná za co nejrychlejší ukládání dat. Obě databáze nabízí vysokou výkonnost.
- Klíče – oba systémy používají primární i cizí klíče k navázání vztahů mezi tabulkami.
- Popularita na webu – MySQL, MSSQL a dále Oracle jsou nejběžnější databáze používané pro webové aplikace.
- Škálovatelnost – oba systémy jsou vhodné pro malé i velké projekty a jsou schopné se přizpůsobit rychle se měnícímu počtu požadavků [10].

¹ Open-source je označení pro počítačový software s otevřeným zdrojovým kódem.

Rozdíly mezi MySQL a MSSQL:

- Kompatibilita – MSSQL byl původně vyvinut pouze pro operační systém Windows. V dnešní době je MSSQL zpřístupněn i pro Linux a Mac OS X. Na druhou stranu MySQL byl vždy koncipován jako systém pro všechny populární operační systémy.
- Podpora – oba databázové systémy podporují mnoho programovacích jazyků včetně Java, C++, PHP, Ruby, Python, Delphi, Visual Basic, Go, and R. MySQL ovšem podporuje i další jazyky jako Tcl, Scheme, Perl či Eiffel.
- Cena – Microsoft požaduje k přístupu ke všem funkcím zakoupení licence, zatímco MySQL je k použití zdarma.
- Engine – Podpora více úložných engineů dělá MySQL flexibilnějším. MSSQL nedovoluje při vytváření databáze specifikovat engine [10].



Obr. 8) Podobnosti a rozdíly mezi MSSQL a MySQL [10]

4 SCADA

Zkratka SCADA (Supervisory Control And Data Acquisition) je do češtiny nejčastěji překládána jako dispečerské řízení a sběr dat. Průmyslové organizace spoléhají na systémy SCADA, aby dohlížely na aktiva při výrobě a vývoji. Systémy SCADA zajišťují efektivitu výroby, zlepšují rozhodovací procesy a komunikují problémy v reálném čase, aby nedocházelo ke zbytečným prostojům a bezpečnostním rizikům. SCADA je například nedílnou součástí distribuce elektrické energie, plynu, oleje a vody. Tato odvětví obvykle provozují centralizované systémy, které monitorují výrobní závody včetně vzdálených míst. SCADA nabízí společně s využívající moderní průmyslové aplikační technologie nové možnosti a výhody [11]:

- Řídit procesy na vzdálených místech.
- Sbírat data ze senzorů, motorů, čerpadel a ventilů.
- Monitorovat, shromažďovat a zpracovávat data v reálném čase.
- Kombinovat data a integrovat je s různorodými systémy.
- Předávat relevantní data více lidem.

4.1 Části SCADA systémů

Systém SCADA se skládá z několika součástí, které jsou nutné pro jeho správnou funkci. Systémy SCADA jsou rozdílné, nicméně některé součásti jsou pro všechny SCADA systémy povinné:

- Dozorčí počítače,
- RTU,
- PLC,
- Komunikační infrastruktura,
- HMI.

4.1.1 Dozorčí počítače

Dozorčí počítače je český doslovný předklad pro Supervisory computers. Jsou to základní součásti systému SCADA. Je to místo, kde se všechna zasláná data zpracovávají. Dozorčí počítače odesílají řídicí příkazy na vzdálená zařízení. Menší organizace mohou používat jeden dozorčí počítač, zatímco větší systémy SCADA mohou používat více pracovních stanic [11].

4.1.2 RTU


Remote terminal units je samostatná jednotka pro sběr a řízení dat. RTU jsou navrženy k podpoře SCADA systémů. Primární funkcí RTU je kontrola, přenos a získávání dat z procesního zařízení na vzdálených místech. Data mohou být v elektrických parametrech jako je průměrná hodnota napětí, proudu, frekvence. Mohou být také zaznamenána jako teplota, hladina oleje či stav spínače.

Architektura RTU se skládá z procesoru, volatilní² paměti a nevolatilní paměti pro zpracování a ukládání programů a dat. RTU Komunikuje s jinými zařízeními prostřednictvím sériových portů nebo onboard modemu s rozhraním I/O (vstup/výstup) [12].

Moderní RTU obsahují rozhraní vstup/výstup analogové i digitální. Obě rozhraní se dají používat pro komunikaci s koncovými čidly či Master jednotkou. RTU jednotky mohou být napojeny na více Master jednotek. To je užitečné při potřebě informací pro více zdrojů či při výpadku [12].

4.1.3 PLC

Programmable logic controller, česky programovatelný logický automat je forma mikroprocesorového počítače, který používá programovatelnou paměť k ukládání instrukcí a implementaci logických funkcí za účelem řízení strojů a procesů. PLC jsou navrženy tak, aby s nimi mohli pracovat inženýři, kteří nedisponují obsáhlými znalostmi programovacích jazyků. Nejsou navrženy tak, aby programy mohli nastavovat nebo měnit pouze programátoři. Návrháři PLC jej tedy předem naprogramovali tak, aby ovládání řídicího programu bylo jednoduché a intuitivní. Programování se primárně týká implementace logických a přepínacích operací, například: pokud dojde k A nebo B, zapněte C. Pokud dojde k A i B, zapněte D. Vstupní zařízení (senzory či spínače) a výstupní zařízení (motory, ventily atd.) jsou připojeny k PLC. Operátor poté zadá sled instrukcí do paměti PLC. PLC poté sleduje vstupy a výstupy podle tohoto programu a provádí pokyny, pro která byl naprogramován [13].




Obr. 9) Programovatelný logický automat PLC [14]

PLC mají velkou výhodu v tom, že mohou být využity s širokou škálou řídicích systémů. K úpravě řídicího systému a pravidel, která mají být použita, je nutné pouze to, aby operátor zadal jinou sadu pokynů. Výsledkem je flexibilní a efektivní systém, který lze použít s řídicími systémy, které se svou povahou a složitostí liší. Jedná se o hlavní výhodu PLC oproti RTU jednotkám. Ty jsou často zaměřeny pouze na jednu funkci, tudíž například při zrušení výrobní linky se často nedají znova použít. PLC jsou podobné počítačům, ale zatímco počítače jsou optimalizovány pro výpočetní úlohy, PLC jsou optimalizovány pro průmyslové prostředí.

PLC jsou robustní a navrženy tak, aby odolaly vibracím, teplotě, vlhkosti a hluku. Mají rozhraní pro vstupy a výstupy uvnitř ovladače. Jsou snadno programovatelné a mají snadno pochopitelný programovací jazyk.

² Jedná se o paměť, která k uchování a přístupu k informaci potřebuje připojení ke zdroji energie. Nevolatilní paměť potřebuje napájení k zápisu a čtení informací, při odpojení napájení se ale informace uchová.


Typicky má PLC systém základní funkční komponenty procesorové jednotky, paměti, napájecí jednotky, sekce vstupního/výstupního rozhraní, komunikačního rozhraní a programovacího zařízení. Obr. 10 níže ukazuje toto uspořádání [14].



Obr. 10) Uspořádání PLC systému [14]

4.1.4 Komunikační infrastruktura

Komunikační infrastruktura slouží k přenosu informací mezi RTU/PLC a dozorčími počítači. Klade se velký důraz na snadný přístup odkudkoliv. To umožňuje pracovníkům snadné připojení a řešení problémů. Obr. 11 ukazuje uspořádání komunikačního SCADA systému.




Obr. 11) Uspořádání komunikačního SCADA systému [13]

4.1.5 HMI

Human-machine interface, neboli rozhraní člověk-stroj. Jedná se o software i hardware, který dovoluje pracovníkům sledovat stav běžících procesů, upravovat potřebná nastavení či v případě nouze zasahovat do systému. HMI zobrazuje informace o stavu procesu, historické informace a zprávy operátorům, správcům, manažerům, obchodním partnerům a dalším oprávněným uživatelům. Umístění, platforma a rozhraní se mohou velmi lišit. HMI může být vyhrazená platforma v řídicím centru, notebook v bezdrátové síti či pouze prohlížeč v jakémkoli systému připojenému k internetu [13].

Mnoho dnešních moderních průmyslových rozhraní HMI je bohatě multimediálních. Na Obr. 12 je k vidění příklad uživatelského rozhraní HMI. HMI umožňují pracovníkům přijímat SMS/e-mail upozornění o stavu strojů či sledovat videa aktuálně se odehrávajících procesů. Sofistikovanější HMI systémy umožňují dálkové ovládání vícero strojů a operací na různých místech nebo například analýzy provozu. HMI také může zobrazit výroby se týkající KPI. Mezi největší výhody patří schopnost vidět klíčová data v reálném čase. Tento atribut HMI významně přispívá ke snížení složitosti prostředí továrny. [15].



Obr. 12) Příklad rozhraní HMI [16]


4.2 Příklad použití SCADA

Jako příklad použití SCADA systémů s HMI můžou posloužit čističky odpadních vod. Tato zařízení čelí mnoha výzvám, jelikož proces čištění vody zahrnuje mnoho fází jako je prosévání, čerpání, filtrace a odstraňování různých mikroorganismů. Každá jednotlivá fáze navíc může probíhat ve značné dálce od fáze minulé, což monitorování procesů ztěžuje. V tomto konkrétním případě může obsluha na dálku díky obrazovce HMI integrované do systému SCADA sledovat hladinu vody, pH, vodní čerpadlo či množství chemikálií. Na základě informací může přes rozhraní HMI například vypnuto čerpadlo či upravena hladina pH. Operátor takto sleduje řídí procesy úpravy vody [15].

5 MES SYSTÉM

Zkratka MES (Manufacturing Execution Systems) je do češtiny překládána jako výrobní informační systémy. Jedná se o počítačové systémy, které jsou využívány ve výrobních podnicích pro řízení a sledování výrobních procesů. MES pomáhá řídícím pracovníkům přijímat rozhodnutí či odhalit případný problém. To vede ke zlepšení efektivity ve výrobě. Primární vlastností systému MES je to, že pracuje v reálném čase [17].

Systémy MES jsou prostředníkem mezi podnikovými informačními systémy (nejčastěji ERP) a systémy pro řízení výrobních procesů a sběru dat (nejčastěji SCADA). To lze pozorovat na Obr. 13 níže.



Obr. 13) Vertikální integrace výrobních systémů. [17]

5.1 Základní funkce MES

Základní funkcionality systému MES byly poprvé definovány organizací MESA International v roce 1992. Tento model poté prošel v letech 1996 a 2002 evoluční změnou. Aktuální model z roku 2006 se nazývá MESA Model [18].

5.1.1 Správa zdrojů ve výrobě

Sleduje a přiděluje zdroje a kapacity, které jsou nutné pro funkci výrobního procesu. Mezi tyto zdroje patří například osoby, materiál, nástroje a zařízení. Příděl je vyhodnocován podle aktuálního stavu a budoucích požadavků na zdroje a kapacity. Dále jsou zajišťovány informace o dostupnosti zdroje pro přiřazené úkoly [18].

5.1.2 Správa postupů ve výrobě

Jedná se o správu informací sloužících k popisu tvorby finálního produktu. Tyto informace zahrnují například evidenci či výměnu kmenových dat s okolními systémy. Správa postupů ve výrobě je často součástí PLM (Product Lifecycle Management) [18].

5.1.3 Plánování a rozvržení výroby

Plánování výroby je rozhodujícím faktem jak pro samotnou výrobu, tak pro výrobní informační systémy. Je známých mnoho přístupů používaných k plánování výroby. Patří mezi ně například dopředné a zpětné plánování výroby či plánování založené na jednoduchých algoritmech

vycházejících z priorit jednotlivých zakázek. Výsledkem plánování výroby je definice pořadí, ve kterém jednotlivé výrobní stroje zpracovávají výrobní příkazy. Při tvorbě této fronty práce se samozřejmě klade důraz na eliminaci prostojů či nadbytečného seřizování strojů [18].

5.1.4 Řízení a sledování výroby

Jedná se o aktivity, které řídí tok výroby přiřazováním práce jednotlivým zařízením a osobám. Monitoring a řízení opatřují požadované suroviny a energie, sledují aktuální stav výroby a operativně řeší výrobní výpadky. Při zabezpečení výroby řídicím systémem je kontrola zdrojů a informovanost okolních systémů o aktuálním stavu výroby zajištěna výrobním informačním systémem. Řízení výroby v MES systémech je také propojeno s ERP systémy [18].

5.1.5 Sběr dat

MES zajišťuje sběr výrobních a procesních dat. Sběr se vyznačuje velkou různorodostí. U menších podniků se mohou sbírat pouze základní údaje, kdežto ve velkovýrobách s plně automatizovanou výrobou dochází ke sběru tisíců hodnot každou minutu [18].

5.1.6 Sledování výrobků a jejich původ

Aktivity zajišťující shromažďování a poskytování informací o zdrojích (stroje, osoby...), které jsou využívány pro tvorbu finálního produktu, spotřebu materiálu apod. Jedná se o aktivitu důležitou z důvodů legislativních požadavků, auditů i řešení reklamací [18].

5.1.7 Výkonnostní analýzy KPI


Výkonnostní analýzy, označované zkratkou KPI (Key performance indicator), jsou používány k vyhodnocování úspěšnosti aktiv organizace. Případně jsou vyhodnocovány jednotlivé oblasti celého výrobního procesu. KPI se nepoužívá pouze ve výrobních podnicích, nýbrž je používáno v mnoha odvětvích [18].

Je zdokumentováno, že kvantifikace KPI vedou k lepšímu pochopení systému a dalšímu přínosu pro zvýšení produktivity systému. V praxi se často požaduje, aby byly systémy KPI kontrolovány za účelem optimalizace provozu a maximalizace zisku. Je tedy například třeba kontrolovat úroveň zásob, aby bylo možné minimalizovat náklady na zásobování zahrnující skladování, likvidaci a vyskladnění produktu [19].

5.2 Průmysl 4.0 a změny řídicích systémů

Architektura řídicích systémů se v posledních letech víceméně ustálila. Řízení výroby je kombinací zprostředkovaného obrazu stavu výroby, který je k dispozici v HMI a posouzení výrobního manažera, který na základě svých znalostí a zkušeností činí daná rozhodnutí. Systémy, které jsou datově nadřazeny HMI se nazývají MIS (Manufacturing Information System). Systémy MIS se nepodílejí na řízení přímo, nýbrž pouze poskytují informace, díky kterým je výroba řízena. Nabízí se otázka, proč prozatím nedošlo k nahrazení role lidského pracovníka automatizovanými mechanismy. Tedy proč zatím neexistují systémy kategorie MES, které by ze strukturovaných informací generovaly návrhy vhodných zásahů či možných řešení pro danou výrobu. Takovéto systémy by vyžadovaly existenci rozhodovacího modelu, který by spolehlivě modeloval realitu, dále vyhodnocoval jednotlivé stavy a generoval vlastní regulační zásady [20].

Zdali je v budoucnosti možná existence systémů MES v exekutivní koncepci realizace úloh řízení není jednoznačné. Do určité míry lze sledovat možný náznak budoucího vývoje. Klasická koncepce řízení využívá horizontálního propojení jednotlivých složek. Jedním z principů Průmyslu 4.0 je uplatnění internetových technologií. Nikoliv však v uspořádání vertikálním, nýbrž čistě horizontálním, viz Obr. 14. V horizontálním uspořádání jsou veškerá zařízení na jedné úrovni a každé zařízení je napojeno na komunikační síť pouze jednou. Toto napojení by mělo vše sjednotit do jedné komunikační platformy. De facto se jedná o konec původní pyramidální architektury [20].



Obr. 14) Potenciální změny klasického vertikálního pojetí informační sítě v důsledku Průmyslu 4.0 [20]

Podle současného vývoje se dá předpokládat, že v budoucnosti dojde k modifikaci klasického pojetí PLC+HMI/SCADA+MIS/MES, respektive k částečnému ústupu vertikálního přenosu dat. Současně s Průmyslem 4.0 se rozvíjejí možnosti ukládání dat. Nejde pouze o ukládání do PC databází, ale i do malých datových skladů vlastních výrobků či výrobních strojů. Dá se tedy očekávat ústup primární koncepce, která spočívala ve sběru primárních dat a jejich archivaci. Místo RTDB (databáze v reálném čase) budou tuto úlohu vykonávat lokální databáze vlastních produktů, lokální databáze kontejnerů (ty v diskrétní výrobě produkty dopravují), či lokální databáze strojů (u spojitě výroby produkty zpracovávají). Je otázkou, zdali tyto komponenty nebudou vybaveny rozhodovací či optimalizační funkcí. Za předpokladu úspěchu implementace jednoúrovňového propojení prvků účastnících se na řízení výroby lze očekávat u rozhodovacích softwarových modelů zvýšení role HMI. Prostředky HMI by se tak v jednoúrovňovém propojení všech úrovní řízení firmy staly takovým koncentrátozem informací použitelných jak pro výrobní útvary, tak i pro obchodní záležitosti. Každý výrobek či výrobní stroj by tak mohl lokálně shromažďovat výrobní data, která by pak na vyžádání poskytoval dál. Celkově by tedy docházelo ke změně místa, ve kterém probíhá globální rozhodování. A to na soustavu výrobek-výrobní stroj-vizualizační pracoviště. Tím by také došlo

k přiblížení rozhodování vlastnímu výrobně-technologickému procesu, což by mohlo vést k urychlení vývoje a použití vhodných rozhodovacích modelů. Došlo by také ke zjednodušení údržby takovýchto informačních modelů. Zdali ovšem tento přístup přinese kýžené výsledky se ukáže až v nadcházející budoucnosti [20].

5.3 Vliv COVID-19 na automatizaci a robotizaci

K vypnutí průmyslu v důsledku nemoci COVID-19 v České republice naštěstí nedošlo, řada firem nicméně musela a stále musí čelit řadě překážek. Jednou z těchto překážek je například pokles lidského kapitálu ve výrobě, který byl způsoben pandemií přímo i nepřímo. Ke slovu stále častěji přicházejí kolaborativní roboty. Tyto coboty jsou schopny bezpečné práce v blízkosti člověka. Kolaborativní robot (cobot) je označení pro spolupracujícího robota, který je používán k posílení lidských pracovníků či převzetí těžkých úkolů. Vyšší počet nasazení kolaborativních robotů je pouze jedním z důsledků změn ve výrobních, které nastaly kvůli pandemii COVID-19. Zajímavý je také zvýšený zájem o pronájem robotických pracovníků. Tento zájem je hnán složitostí odhadu budoucího vývoje, firmy potřebují nečekané požadavky flexibilně vykrývat. Dalším důvodem pro pronájem robotů jsou fixní náklady. Než okamžitě investovat do přímého nákupu robotů je pro podniky jednodušší si roboty pronajmout po garantované dobu odběru výrobků. Také technologie nových generací získávají při pandemii vyšší pozornost. Výrobci robotů a integrátoři pomáhají podnikům správně udržovat robotickou automatizaci, i když lidští pracovníci musí často pracovat na dálku [21].

5.3.1 Trendy v robotice pro rok 2021

Nalézt trendy v robotice si kladla za cíl konference Roboty 2021. Na té zazněla vize instituce International Federation of Robotics (IFR), která představila 5 převládajících trendů pro rok 2021:

Roboty jsou chytřejší

Rychlý vývoj stále zvyšuje počet úkonů, které jsou roboty schopny samostatně provádět. Příkladem může být například bin picking. Jedná se o složitou operaci, při které musí být robot schopen identifikovat a vybrat jednu součást z koše podobných součástí. Cílová část může být zakryta ostatními díly. Při nalezení dílu software robotu zpracuje informaci, jakým způsobem se k požadovanému dílu dostat. Tato informace je dále použita a robotu je umožněno kýžený díl vyzvednout. Během příštích let budou roboty stále častěji schopné reagovat na prostředí. Robot bude například schopný rozpoznat zamýšlený pohyb člověka a odpovídajícím způsobem upravit svoji vlastní trasu. Dá se také očekávat pokrok v rozpoznávání gest či řeči [21].

Roboty a flexibilní výroba

Výrobci a zástupci logistiky jsou pod stále vyšším tlakem. Jsou nuceni odesílat menší zakázky v kratším časovém rozmezí. Mnoho firem tedy využívá automatizace, aby bylo možné pružně reagovat na nové objednávky. Některé podniky také přechází do výrobních buněk, které mohou být snadno konfigurovány dle zadaného úkolu. Tento trend se nejvíce viditelný u výrobců automobilů, ale tato řešení se dají očekávat i v jiných logistických a výrobních odvětvích. Aktuálně probíhá vysoká automatizace výrobních linek za pomoci propojení strojů včetně robotů. Výrobní proces může být automaticky zpuštěn zadáním objednávky. V tomto nelineárním rozložení výroby je možné jednoduše rekonfigurovat malé produkční buňky, aby prováděly jednotlivé části výrobního procesu. Autonomní mobilní roboty jsou schopny

aktivovat stroje v buňkách a provádět některé úkoly samy. V budoucnu budou roboty schopny dohlížet na kvalitu dílů při dopravě, což povede k zajištění kvality za chodu [21].

Roboty si podmaňují nové trhy

Robotika se stále častěji uplatňuje i v odvětvích, které dosud neautomatizovaly. IFR sleduje rozmach robotů v odvětvích jako je zdravotnictví či výroba potravin a farmaceutických výrobků. U malých a středních výrobců lze také sledovat mnohé změny. Programovat a přepracovávat roboty je nyní snazší, novou generaci kolaborativních robotů je také možné snadno integrovat do stávajících výrobních procesů. Není tedy nutné automatické přepřánování celé výrobní linky. Roboty jsou často pronajímány, nikoliv kupovány. To zjednodušuje první krok k automatizaci [21].

Roboty a odolné dodavatelské řetězce


Obchodní válka mezi USA a Čínou, pandemie COVID-19 či Brexit ukázaly, jako moc rigidní jsou globální dodavatelské řetězce. Roboty mohou výrobcům pomoci s odolností dodavatelských řetězců. Kolaborativní roboty mohou pracovat s lidmi v období nejvyšších počtů objednávek, kdy je pro podniky mnohdy složité nárazově zvýšit počet zaměstnanců. Roboty ve výrobě navíc mohou v rozvinutějších ekonomikách znamenat i ekonomicky výhodnější alternativu [21].

Nižší uhlíková stopa

Roboty minimalizují plýtvání materiálem a umožňují podnikům optimalizovat výrobní prostor. Tím se také snižují náklady na energie. Roboty dále umožňují kratší dodavatelské řetězce, což má opět pozitivní vliv na uhlíkovou stopu. Roboty jsou navíc stále energeticky účinnější. V neposlední řadě roboty disponují dlouhou životností, která bývá navíc často prodlužována. [21].

5.4 OEE

Celková efektivnost zařízení (OEE - Overall Equipment Effectiveness) je ukazatel efektivnosti výrobních zařízení. Ukazatel byl sestaven v 60. letech 20. století pro japonský institut plánování. Hodnota OEE je klíčová pro podniky, které se snaží neustále zlepšovat a zeštíhlovat svoji výrobu. Příklad efektivnosti využití stroje je k vidění na Obr. 15. OEE odkrývá skryté parametry strojů, které mohou být firmou využity a tím zvýšen její provozní zisk [22].



Obr. 15) OEE jako ukazatel efektivnosti využití stroje či zařízení [23]

5.4.1 Výpočet OEE

Hodnota OEE se udává v procentech využití normované kapacity zařízení. Je tedy určeno procento výrobního času, kdy je linka/stroj skutečně produktivní. Stoprocentní skóre OEE by tedy znamenalo, že jsou vyráběny pouze kvalitní výrobky co nejrychleji, bez odstávek. Výsledné hodnocení OEE se liší také podle typů výroby. U kusové výroby je procento zpravidla nižší, zatímco u hromadné vysoce automatizované výroby se hodnota OEE může pohybovat klidně mezi 90 až 100 %. OEE vyšší než 85 % většinou znamenají, že firma pracuje velmi efektivně. OEE je vyjádřeno jako součin 3 faktorů v procentech, viz Obr. 16 [22].

- Dostupnost – výrobní ztráty, které jsou způsobené opravami či poruchami strojů.
- Výkon – ztráty pramenící z nižšího výrobního taktu než je normovaná kapacita.
- Kvalita – ztráty způsobené počtem nekvalitních výrobků [22].

$$\text{OEE} = \text{Dostupnost} \times \text{Výkon} \times \text{Kvalita} \times (100\%)$$

$$\text{Dostupnost} = \frac{\text{Skutečný čas výroby}}{\text{Plánovaný čas výroby}}$$


$$\text{Výkon} = \frac{\text{Skutečně vyrobené množství}}{\text{Teoreticky vyrobené normované množství}}$$

$$\text{Kvalita} = \frac{\text{Celkové množství OK (shodných výrobků)}}{\text{Celkové množství všech výrobků}}$$

Obr. 16) Výpočet OEE [22]

6 STROJOVÉ UČENÍ


Machine learning, neboli strojové učení, definoval v 90 letech 20. století Arthur Samuel. Ten jej popsal jako studijní obor, který dává počítači schopnost se sám učit, aniž by byl explicitně naprogramován. Strojové učení se zaměřuje na vývoj počítačových programů, které se učí růst a měnit, když jsou vystaveny novým datům. Strojové učení je typicky rozdělováno do 3 kategorií. Ty jsou viditelné na Obr. 17 a popsány v dalších kapitolách. Díky algoritmu učení je poté možné rychlé zpracování velkého množství dat. Se stále rostoucím množstvím dat je dnes téměř nemožné všem datům porozumět. Více než 80 % dat je dnes nestrukturovaných. Jedná se například o fotografie, dokumenty, videa či grafy. Najít poté mezi těmito daty souvislosti je pro lidský mozek téměř nemožné. Množství dat je ohromné a procházení těchto dat by zabralo nepřehledné množství času. Proto přichází ke slovu strojové učení, které zvládá vyhodnocovat data za výrazně kratší dobu. Strojové učení je podoblastí AI (Artificial Intelligence, do češtiny překládáno jako umělá inteligence)[24].



Obr. 17) Typy strojového učení [24]

6.1 Supervised learning (učení s učitelem)

Prvním typem strojového učení je supervised learning. V češtině se pro supervised learning používá termín učení s učitelem. Jsou využívána označená data, která slouží k trénování algoritmů. U těchto dat jsou známy vstupy i výstupy. Vstupní data jsou přiřazena proměnné X , výstupní data náleží proměnné Y . Algoritmus se učí porovnáváním svých hodnot s výstupy. To napomáhá k nalezení chyb a následné úpravě modelu. Data jsou rozdělena do dvou částí. První částí jsou data trénovací určená k trénování algoritmu. Druhou kategorií jsou pak data testovací, která se používají k testování algoritmu. Tato metoda je často používána při aplikacích, kde historická data predikují nadcházející události. Na Obr. 18 lze pozorovat průběh strojového učení s učitelem. Učení s učitelem se dělí do 2 typů. Jsou jimi klasifikace a regrese [24].



Obr. 18) Průběh strojového učení s učitelem [24]

6.1.1 Regression

Regrese je prvním typem strojového učení s učitelem. Jedná se o formu prediktivního modelování, při kterém je zkoumán vztah mezi závislou proměnnou (vstup) a proměnnou nezávislou (výstup). Příkladem použití může být predikce ceny domu. Na základě vstupních dat jako je lokalita, počet pokojů, staří nemovitosti, užitná plocha je predikována cena domu. Existuje mnoho regresních algoritmů. Některé z těch hlavních jsou:

Linear Regression

Při lineární regresi se predikuje hodnota jedné proměnné z velikosti druhé proměnné. Předpovídaná proměnná se vyznačuje jako Y. Proměnná, na které se předpovědi zakládají se označuje jako X [24].

Multiple Linear Regression

Jedná se o nejčastější formu analýzy lineární regrese. Používá se pro vysvětlení vztahu mezi jednou závislou proměnnou se dvěma nebo více než dvěma nezávislými proměnnými [24].

Bayesian Regression

Tato metoda umožňuje mechanismu zvládnout nedostatečná či špatně distribuovaná data. Metoda zvládá vyhodnotit, která data jsou kvalitní a které části dat jsou nejisté [24].

6.1.2 Classification

Klasifikace je druhým typem strojového učení s učitelem. Data se využívají k predikcím v nespojitě formě. Výstup informací není vždy spojitý a graf je nelineární. V klasifikační metodě se algoritmus učí ze zadaného datového vstupu. Poté toto učení používá ke klasifikaci svého pozorování. Příkladem použití může být rozhodnutí o tom, jestli je daný email spam či ne. Využívá se algoritmus, který rozeznává slova typická pro spamové emaily. Podobně jako u regrese existuje i u klasifikace mnoho algoritmů. Hlavními jsou:

Logistic Regression/Classification

Je měřen vztah mezi závislou proměnnou, která je propojena s jednou nebo více nezávislými proměnnými pomocí logistické či sigmoidní funkce. Tato metoda je typicky používána tam, kde závislá proměnná nabývá pouze dvou možných hodnot. Například „Ano/Ne“ [24].

K-Nearest Neighbours

Jedná se o velmi přímočarý algoritmus, zároveň je to jeden z nejpoužívanějších algoritmů učení [24].

Decision Tree Classification

Rozhodovací strom vytváří klasifikační modely ve formě stromové struktury. Rozhodovací strom se postupně vyvíjí a současně rozděluje velkou sadu dat na menší podmnožiny. Konečným výsledkem je strom s rozhodovacími a listovými uzly. Rozhodovací uzel má dvě či více větví. Uzel listu představuje klasifikaci nebo rozhodnutí. Rozhodovací stromy mohou zpracovávat kategorická i numerická data [24].


Naive Bayes

Metoda, která vychází z Bayesovy věty³ s předpokladem nezávislosti mezi prediktory. Model Naive Bayes je obzvláště užitečný pro rozsáhlé datové sady [24].

³ Bayesova věta je věta teorie pravděpodobnosti, která udává, jak podmíněná pravděpodobnost nějakého jevu souvisí s opačnou podmíněnou pravděpodobností.

6.2 Unsupervised Learning

Jedná se o druhý typ strojového učení. Do češtiny je unsupervised learning překládáno jako učení bez učitele. Na rozdíl od učení s učitelem algoritmy nemají na vstupu data spojená s cílovou proměnnou. Účelem je prozkoumat data a najít strukturu uvnitř. Při učení bez učitele jsou data neoznačená. Nezpracovaná data vstupují přímo do algoritmu bez předběžného zpracování či znalosti dat. Data nelze rozdělit na data trénovací a testovací. Algoritmus vypočítá data a podle datových segmentů vytvoří shluky dat s novými popisy. Tato metoda je často využívána na transakčních datech. Častá je například identifikace zákazníků s podobnými atributy. S těmi skupinami zákazníků lze následně zacházet podobně v marketingových kampaních. Dále může nalézt primární vlastnosti, které od sebe zákaznický oddělují. Tyto algoritmy jsou také používány k segmentaci textových témat, doporučování položek a identifikaci odlehlých dat. Na Obr. 19 lze pozorovat průběh strojového učení bez učitele. Učení bez učitele se podobně jako učení s učitelem dělí do dvou hlavních typů. Jsou jimi Clustering a Dimensionality Reduction [24].




Obr. 19) Průběh strojového učení bez učitele [24]

6.2.1 Clustering

Clustering (shlukování) je typ učení bez učitele, při kterém se používají neoznačená data. Jedná se o proces, při kterém jsou seskupovány podobné entity dat, tato data poté vytvářejí shluky. Cílem techniky je najít podobná data a ty poté seskupit. Mezi hlavní algoritmy shlukování patří:

K-Means Clustering

Podobná data jsou seskupována do shluků. K-means je shlukovací algoritmus, jehož cílem je najít maxima v každé iteraci. K označuje počet viditelných skupin na vstupu. Výchozí centroidy jsou náhodně označeny v prostoru. Nyní se vypočítají vzdálenosti mezi daty a centroidy. Datový bod se přiřadí ke shluku, který je mu blízko. Centrum shluku je přepočítáno jako průměr datových bodů. Tyto operace se opakují dokud dochází ke změnám [24].



Obr. 20) Metoda K-Means se 3 shluky [24]

Hierarchical Clustering

Jedná o další metodu, při níž jsou data seskupena do shluků. Datové body jsou přiřazeny ke své vlastní datové skupině. Dvě nejbližší skupiny jsou potom sloučeny do stejného shluku. Algoritmus je ukončen, jakmile zůstane pouze jeden shluk [24].

6.2.2 Dimensionality Reduction

Jedná se o další typ učení bez učitele, při kterém se rozměry dat zmenšují, aby se odstranila nechtěná data ze vstupu. Metoda je využívána k odstranění nežádoucích vlastností dat. Cílem je zmenšit objem dat při zachování jejich kvality [24].

Linear Discriminant Analysis

Analýza hlavních komponent je metoda, při které se transformují nové sady proměnných ze starých proměnných, které jsou lineární kombinací skutečných proměnných. Nová sada proměnných je označována jako hlavní komponenty [24].

6.3 Reinforcement Learning

Třetí typ strojového učení, do češtiny se reinforcement learning překládá jako zpětnovazebné učení. Nejsou přítomna žádná vstupní data. Algoritmy zpětnovazebného učení musí situaci vyřešit samy. Jedná se o postup často využívaný v robotice, herním průmyslu či navigaci. Díky metodě pokus/omyl algoritmus zjistí, které akce přinášejí nejvýznamnější odměny. Zpětnovazebné učení má tři komponenty: Agent, který může být popsán jako žák či tvůrce rozhodnutí. Prostředí, které popisuje vše, s čím agent interaguje. Akce, které představují vše, co může agent udělat [24].

6.3.1 Q-Learning

Jedná se o metodu zpětnovazebného učení, při které se agent snaží naučit optimální strategii z historie komunikace s prostředím. Agent je umístěn do libovolného prostředí. Jeho úkolem je naučit se chovat tak, aby bylo dosaženo maximálního užitku [24].

6.4 Semi-Supervised Learning

Jedná se o kombinaci učení s učitelem a bez učitele. Tento typ učení je používán pro stejné účely jako učení s učitelem. Označená i neoznačená data jsou používána k trénování malého množství označených a velkého množství neoznačených dat. Své využití nachází u metod jako je predikce, klasifikace a regrese. Jedním z důvodů použití metody je fakt, že proces označování velkého množství dat pro učení s učitelem je často časově i finančně náročný. Zahrnutí velkého množství neoznačených dat během tréninkového procesu má tendenci zlepšit přesnost konečného modelu a redukovat potřebný čas a finanční náklady [24].

7 VYHODNOCENÍ DAT

Pro diplomovou práci byla použita data z firmy zabývající se výrobou technických tkanin. Tyto tkaniny nacházejí své použití například u výrobců pneumatik. Na Obr. 21 je k vidění řez pneumatikou, která používá kordovou tkaninu.

ŘEZ PNEUMATIKOU


- 1/** TĚLO PNEUMATIKY
- 2/** KORDOVÁ TKANINA
- 3/** OCELOVÁ VÝZTUŽ
- 4/** KORDOVÁ KOSTRA



Obr. 21) Řez pneumatikou využívající kordovou tkaninu [25]


7.1 Proces výroby

Stěžejními částmi výroby tkanin jsou procesy skaní a tkaní. Jedná se o části výroby, které jsou kritické z důvodů vzniku přetrhů. Skaní je proces, při kterém jsou dvě nebo více nití spojeny zákrutem. Skáním se získává nit, která je hladší, pevnější a stejnoměrnější než nit jednoduchá. Skaní může být prováděno jednostupňové i vícestupňové, viz Obr. 22. Vlastnosti skaných tkanin jsou ovlivněny faktory jako je počet a směr zákrutů. Podle počtu zákrutů se rozlišují skané tkaniny tvrdé, měkké a efektní [26].




Obr. 22) Jednostupňové a vícestupňové skaní [26]

Tkaní je proces, při kterém jsou dvě navzájem kolmé soustavy nití kříženy. Podélná soustava je označována jako osnova, příčná poté jako útek, viz Obr. 23.



Obr. 23) Popis tkaní [27]

Na Obr. 24 je k vidění procesní mapa výroby tkanin ve firmě, která poskytla data ke zpracování diplomové práce. Materiál prochází dlouhou cestou několika výrobních procesů, než se z něho stává hotová kordová tkanina.



Obr. 24) Procesní mapa výroby tkanin [28]

7.2 Sběr dat

Z důvodů pandemie nemoci COVID-19 bohužel nebylo umožněno navštěvovat firmu, ze které jsou data získána. Firma využívá technický informační systém od společnost Wizkon. Data byla zaslána formou souborů Excel. Na Obr. 26 a 27 jsou k dispozici náhledy zaslaných dat.

id_technologie	id_stroj	id_smena	smena	tym	smenaod	smenado	casCelkem	kontrSoucet	casProvozu	casDojeto	casPretrhu	casPoruch	casRucniStop	casPP	casNeniZak
38	3809	1154625	2 A		04.04.2020 14:00	04.04.2020 22:00	40320	40320	0	0	0	0	0	0	40320
37	3709	1154529	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	58166	2260	3808	0	86	0	0
37	3712	1154538	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	0	0	0	0	0	0	64320
37	3701	1154505	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	34243	27107	2500	218	252	0	0
37	3702	1154508	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	52017	10873	1430	0	0	0	0
37	3706	1154520	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	47929	12318	3693	380	0	0	0
37	3707	1154523	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	10477	43341	9	842	75	0	9576
37	3711	1154535	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	0	0	0	0	0	0	64320
38	3801	1154601	2 A		04.04.2020 14:00	04.04.2020 22:00	40320	40320	36985	151	3173	10	1	0	0
38	3802	1154604	2 A		04.04.2020 14:00	04.04.2020 22:00	40320	40320	38756	172	1292	0	0	0	0
38	3812	1154634	2 A		04.04.2020 14:00	04.04.2020 22:00	40320	40320	30508	8055	620	23	74	0	1040
38	3811	1154631	2 A		04.04.2020 14:00	04.04.2020 22:00	38400	38400	35183	385	2832	0	0	0	0
37	3713	1154541	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	0	0	0	0	0	0	64320
37	3714	1154544	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	0	0	0	0	0	0	64320
38	3810	1154628	2 A		04.04.2020 14:00	04.04.2020 22:00	40320	40320	0	0	0	0	0	0	40320
37	3708	1154526	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	43579	958	18823	960	0	0	0
37	3704	1154514	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	54740	6994	2551	0	35	0	0
37	3705	1154517	2 A		04.04.2020 14:00	04.04.2020 22:00	64320	64320	41323	18389	4448	0	160	0	0
37	3705	1154516	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	59610	960	3750	0	0	0	0
37	3704	1154513	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	47054	11361	5905	0	0	0	0
37	3708	1154525	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	46034	0	17326	960	0	0	0
38	3810	1154627	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	0	0	0	0	0	0	40320
37	3714	1154543	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	0	0	0	0	0	0	64320
37	3713	1154540	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	0	0	0	0	0	0	64320
38	3812	1154633	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	37987	2333	0	0	0	0	0
38	3811	1154630	1 D		04.04.2020 6:00	04.04.2020 14:00	38400	38400	35033	2664	682	12	9	0	0
38	3802	1154603	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	37932	1953	421	14	0	0	0
38	3801	1154600	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	34220	3411	2676	13	0	0	0
37	3711	1154534	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	0	0	0	0	0	0	64320
37	3707	1154522	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	23539	35658	4170	225	728	0	0
37	3706	1154519	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	59063	1859	3398	0	0	0	0
37	3702	1154507	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	62885	174	1261	0	0	0	0
37	3701	1154504	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	61610	0	2230	0	480	0	0
37	3712	1154537	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	0	0	0	0	0	0	64320
37	3709	1154528	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	63527	0	793	0	0	0	0
38	3809	1154624	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	0	0	0	0	0	0	40320
37	3703	1154510	1 D		04.04.2020 6:00	04.04.2020 14:00	64320	64320	57412	4695	1248	513	452	0	0
38	3804	1154609	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	0	0	0	0	0	0	40320
38	3803	1154606	1 D		04.04.2020 6:00	04.04.2020 14:00	38400	38400	0	0	0	0	0	0	38400
38	3806	1154615	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	0	0	0	0	0	0	40320
38	3805	1154612	1 D		04.04.2020 6:00	04.04.2020 14:00	40320	40320	0	0	0	0	0	0	40320

Obr. 25) Náhled zadaných dat skaní [28]

id_technologie	id_stroj	id_smena	smena	tym	smenaod	smenado	casCelkem	oblozeni	casNeniZakazka	casChodStrojePriprava	casCekaniMatPriprava	casCekaniSerizPriprava
67	6701	1490437	1 B		02.03.2021 6:00	02.03.2021 14:00	480	S0414300.00	0	0	0	0
67	6701	1490043	3 A		01.03.2021 22:00	02.03.2021 6:00	480	S0414300.00	0	0	0	0
67	6701	1490042	2 C		01.03.2021 14:00	01.03.2021 22:00	480	S0414300.00	0	0	0	0
67	6701	1490041	1 B		01.03.2021 6:00	01.03.2021 14:00	480	S0414300.00	0	0	0	0
67	6701	1489905	3 A		28.02.2021 22:00	01.03.2021 6:00	480	00.00	103	0	0	0
67	6701	1489904	2 -		28.02.2021 14:00	28.02.2021 22:00	480	00.00	480	0	0	0
67	6701	1489903	1 -		28.02.2021 6:00	28.02.2021 14:00	480	00.00	480	0	0	0
67	6701	1489509	3 -		27.02.2021 22:00	28.02.2021 6:00	480	00.00	480	0	0	0
67	6701	1489508	2 -		27.02.2021 14:00	27.02.2021 22:00	480	00.00	480	0	0	0
67	6701	1489507	1 -		27.02.2021 6:00	27.02.2021 14:00	480	00.00	480	0	0	0
67	6701	1489371	3 -		26.02.2021 22:00	27.02.2021 6:00	480	00.00	480	0	0	0
67	6701	1489370	2 B		26.02.2021 14:00	26.02.2021 22:00	480	00.00	480	0	0	0
67	6701	1489369	1 A		26.02.2021 6:00	26.02.2021 14:00	480	00.00	480	0	0	0
67	6701	1488975	3 C		25.02.2021 22:00	26.02.2021 6:00	480	00.00	480	0	0	0
67	6701	1488974	2 B		25.02.2021 14:00	25.02.2021 22:00	480	00.00	480	0	0	0
67	6701	1488973	1 A		25.02.2021 6:00	25.02.2021 14:00	480	00.00	480	0	0	0
67	6701	1488837	3 C		24.02.2021 22:00	25.02.2021 6:00	480	00.00	480	0	0	0
67	6701	1488836	2 B		24.02.2021 14:00	24.02.2021 22:00	480	00.00	480	0	0	0
67	6701	1488835	1 A		24.02.2021 6:00	24.02.2021 14:00	480	S0216502.00	121	1	0	0
67	6701	1488441	3 C		23.02.2021 22:00	24.02.2021 6:00	480	S0216502.00	0	0	0	0
67	6701	1488440	2 B		23.02.2021 14:00	23.02.2021 22:00	480	S0216501.00	0	0	0	0
67	6701	1488439	1 A		23.02.2021 6:00	23.02.2021 14:00	480	S0216500.00	0	11	0	0
67	6701	1488303	3 C		22.02.2021 22:00	23.02.2021 6:00	480	S0216500.00	0	2	0	0
67	6701	1488302	2 B		22.02.2021 14:00	22.02.2021 22:00	480	S0216500.00	0	0	0	0
67	6701	1488301	1 A		22.02.2021 6:00	22.02.2021 14:00	480	S0216500.00	0	0	0	0
67	6701	1487907	3 C		21.02.2021 22:00	22.02.2021 6:00	480	S0216500.00	0	0	0	0
67	6701	1487906	2 -		21.02.2021 14:00	21.02.2021 22:00	480	S0216500.00	0	0	0	0
67	6701	1487905	1 -		21.02.2021 6:00	21.02.2021 14:00	480	S0216500.00	0	0	0	0
67	6701	1487769	3 -		20.02.2021 22:00	21.02.2021 6:00	480	S0216500.00	0	0	0	0
67	6701	1487768	2 -		20.02.2021 14:00	20.02.2021 22:00	480	S0216500.00	0	0	0	0
67	6701	1487767	1 -		20.02.2021 6:00	20.02.2021 14:00	480	S0216500.00	0	0	0	0
67	6701	1487373	3 -		19.02.2021 22:00	20.02.2021 6:00	480	S0216500.00	0	0	0	0
67	6701	1487372	2 A		19.02.2021 14:00	19.02.2021 22:00	480	S0216500.00	0	0	0	0
67	6701	1487371	1 C		19.02.2021 6:00	19.02.2021 14:00	480	S0217200.00	0	279	2	0
67	6701	1487235	3 B		18.02.2021 22:00	19.02.2021 6:00	480	S0217200.00	0	0	0	0
67	6701	1487235	3 B		18.02.2021 22:00	19.02.2021 6:00	480	S0217200.00	0	286	14	58
67	6701	1487234	2 A		18.02.2021 14:00	18.02.2021 22:00	480	S0217200.00	0	12	0	0
67	6701	1487233	1 C		18.02.2021 6:00	18.02.2021 14:00	480	S0158306.00	0	0	0	0
67	6701	1486839	3 B		17.02.2021 22:00	18.02.2021 6:00	480	S0158305.00	0	0	0	0
67	6701	1486838	2 A		17.02.2021 14:00	17.02.2021 22:00	480	S0158305.00	0	0	0	0
67	6701	1486837	1 C		17.02.2021 6:00	17.02.2021 14:00	480	S0158305.00	0	0	0	0
67	6701	1486701	3 B		16.02.2021 22:00	17.02.2021 6:00	480	S0158304.00	0	0	0	0


Obr. 26) Náhled zadaných dat tkaní [28]

7.3 Zpracování dat skaní

Data, která byla firmou poskytnuta jsou velmi obsáhlá a dají se analyzovat na mnoho způsobů. Dle mých informací je systém sběru dat ve firmě implementován krátce a na základě sbíraných dat zatím nebyly firmou vyhodnoceny žádné relevantní výsledky. Primárním problémem ve výrobě při procesu skaní jsou přetřhy. Ty byly analyzovány a hodnoceny primárně pomocí kontingenčních tabulek a z nich vytvořených grafů.

7.3.1 Týdenní přetřhy podle technologií pro všechny materiály.

Firma využívá ve výrobě mnoho materiálů a technologií výroby. Pod každou technologii výroby spadají určité výrobní stroje. Pro tento konkrétní příklad byly vybrány stoje technologie 37 a 38. Na Obr. 27 lze vidět zpracování přetřhů materiálů za prvních 18 týdnů roku 2021.



Obr. 27) Týdenní přetřhovost technologie 37 a 38 [28]


Přetřhovost při skaní u technologie 37 nevykazuje v prvních 15 týdnech žádné větší odchylky. V 16. týdnu dokonce přichází minimum a přetřhovost dosahuje hodnoty 4,4 %. V 17. a 18. týdnu ale přichází prudký nárůst přetřhovosti, který má v 18. týdnu hodnotu 8,5 %. Rozdíl mezi minimem v 16. týdnu a maximem v 18. týdnu je tedy 4,1 %.

Začátek roku ukazuje u technologie 38 přetřhovost okolo 5 %. Poté přichází zvýšení a hodnota přetřhovosti se 5 týdnů pohybuje okolo hranice 7,5 %. Následuje mírné snížení a poté zvýšení přetřhovosti. V posledním 18. týdnu je hodnota přetřhovosti 8,1 %.

Průměrná týdenní přetřhovost pro technologii 37 je 6,03 %. Pro technologii 38 vychází průměrná týdenní přetřhovost 6,87 %. Technologie 37 tedy disponuje v průměru o 0,84 % nižší přetřhovostí.

7.3.2 Týdenní přetrhovost podle materiálů

Jak již bylo řečeno, ve firmě je zpracováváno mnoho materiálů. Zajímavou statistikou je průměrná přetrhovost u rozdílných materiálů, které jsou ovšem zpracovávány stejnou technologií na stejných strojích. Pro srovnání byly vybrány materiály SLK 220x 1x 2 320/320s 259NA a SLK 167x 1x 2 375/375s 159AA, viz Obr. 28. Tyto materiály využívají technologii 37 a její stroje.




Obr. 28) Týdenní přetrhovost podle materiálů [28]

Materiál SLK 220x 1x 2 320/320s 259NA má průměrnou přetrhovost 7,4 %. Materiál SLK 167x 1x 2 375/375s 159AA má průměrnou přetrhovost 5,8 % a ve 14 z 18 týdnů vykazuje nižší přetrhovost. Materiál SLK 220x 1x 2 320/320s 259NA vykazuje ve 3 týdnech přetrhovost vyšší než 10 %.

7.3.3 Denní přetřhovost materiálu SLK 220x 1x 2 320/320s 259NA

Materiál SLK 220x 1x 2 320/320s 259NA byl využit již v minulé kapitole. V této kapitole je k vidění jeho denní přetřhovost za únor 2021, viz Obr. 29. Materiál byl celý měsíc zpracováván na 2 strojích. Jednalo se o stroje 3706 a 3707.




Obr. 29) Denní přetřhovost materiálu SLK 220x 1x 2 320/320s 259NA za měsíc únor [28]

Spojnice trendu ukazuje za měsíc únor snižující se hodnotu přetřhovosti. Průměrná přetřhovost za měsíc únor dosáhla hodnoty 6,2 %. Únorová hodnota je tedy o 1,2 % nižší než hodnota za prvních 18 týdnů roku 2021, která byla pozorována na Obr. 28 v minulé kapitole.

7.3.4 Přetřhovost materiálu SLK 144x 1x 2 380/380s 259NA NOC

V této kapitole je vyhodnocena přetřhovost materiálu SLK 144x 1x 2 380/380s 259NA CON. Na Obr. 30 je vyhodnocení přetřhovosti materiálů během 16. a 17. týdne roku 2021. Materiál byl oba týdny zpracováván celkově na 15 strojích (3801 až 3815).




Obr. 30) Přetřhovost materiálu SLK 144x 1x 2 380/380s 259NA CON za měsíc únor [28]

Na první pohled to možná vypadá, že v přetřhovosti je mezi 16. a 17. týdnem značný rozdíl. Ve skutečnosti je ale hodnota průměrné přetřhovosti pro 16. týden 7,6 %. Pro 17. týden je to 7,7 %. K největšímu rozdílu dochází u stroje 3815, kdy je rozdíl mezi dvěma týdny 8,1 %. Pro kontrolu bylo nahlédnuto i do dat z 15. týdne, kdy byla průměrná přetřhovost 7,8 %, tedy o pouhé 2 desetiny procenta vyšší než v 16. týdnu.


7.3.5 Využití technologií a strojů při skaní

Jednotlivé technologie a pod ně spadající stroje disponují různými mírami využití. Z kapitoly o OEE je jasné, že cílem by mělo být co nejvyšší využití strojů a co nejnižší prostoje. Obr. 31 ukazuje využití jednotlivých technologií při procesu skaní v prvních 15 týdnech roku 2021.



Obr. 31) Využití technologií při procesu skaní [28]


Z grafu je vidět, že nejlépe je na tom technologie 36. Ta disponuje nejnižší hodnotou prostojů i času bez zakázek. Naopak u technologie 39 lze sledovat, že není dostatečně využívána. Hodnota prostojů je u technologie 39 také vyšší než u zbylých 3 technologií. Obr. 32 ukazuje celkové využití technologií 36 až 39 po jejich sečtení. Využití strojů pro provoz dosahuje hodnoty 68,6 %. Cílem do budoucna by mělo být snížení času bez zakázky a prostojů.



Obr. 32) Průměr využití technologií 36–39 při procesu skaní [28]

7.3.6 Rozdělení prostojů při skaní

Obr. 33 zobrazuje rozdělení prostojů při skaní za použití technologie 37. Z výšečového grafu lze vidět, že nejvíce prostojů vzniká při dojetí cívky, kdy se čeká na obnovení výroby. Druhým nejčastějším důvodem prostojů je přetrh tkaniny. Tyto 2 důvody jsou dohromady odpovědný za téměř 88 % prostojů, což odpovídá Paretovu⁴ pravidlu. Zbylých 7 důvodů tvoří dohromady 12 % z celkového času prostojů.



Obr. 33) Rozdělení prostojů při skaní u technologie 37 [28]


⁴ Paretovo pravidlo ve zkratce říká, že 80 % důsledků pramení z 20 % příčin.

7.4 Zpracování dat tkaní

Pozornost u dat ze tkaní byla věnována především zpracování prostožů.

7.4.1 Příklad využití stroje 6701

V následujícím Obr. 34 je zobrazeno rozdělení chodu stroje. K vidění je procentuální rozdělení času bez zakázky, procesu příprav a procesu tkaní (včetně prostožů). Jasně viditelný je srpnem počínající úsek, kdy stroj technologie 67 zůstává bez zakázky. Důvodem je fakt, že se výrazně snižuje čas potřebný k přípravě.



Obr. 34) Využití stroje 6701 za rok 2020 [28]


Data, která vedla k vytvoření grafu na Obr. 34 jsou viditelná jsou v Tab. 1. Například hodnota procesu tkaní včetně prostožů je pro leden 49 %. Avšak je nutné si uvědomit, že samotný chod stroje při tkaní představuje pouhých 28,1 %. Téměř 21 % času z procesu tkaní představují prostože. Podobně je tomu také v následujících měsících. Vysokých hodnot ve všech měsících dosahuje čekání na vývaz a stop - ruční. K vidění jsou i další konané úkony.

Měsíc	Leden	Únor	Březen	Duben	Květen	Červen	Červenec	Srpen	Září	Říjen	Listopad	Prosinec
Bez zakázky												
Bez zakázky	12,2%	6,3%	4,8%	5,5%	4,8%	2,4%	2,4%	15,1%	31%	39,9%	33%	39%
Přípravy												
Manipulace	1,2%	1,7%	0,7%	1,3%	1,3%	1,4%	0,3%	0,7%	1%	0,9%	0,7%	1%
Vývaz	4,8%	5,3%	5,2%	4,6%	4,2%	4,4%	3,5%	4,6%	5,4%	4,6%	4%	4,4%
Zajištění	1,6%	1,4%	1,5%	1,8%	1,7%	1,5%	1,1%	2%	2,3%	1,9%	1,4%	1,7%
Seřizování	0,6%	0,2%	0,3%	0,5%	0,5%	0,6%	0,3%	0,4%	0,7%	0,6%	0,4%	0,4%
Oprava	1,1%	0,5%	0,9%	1,4%	1,5%	1,1%	0,5%	2,4%	1%	0,6%	0,4%	0,2%
Čištění	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Čekání na údržbu	0,4%	0,2%	0,1%	0%	0,2%	0,1%	0%	0,2%	0%	0,7%	1,5%	0,6%
Čekání na materiál	0%	0,2%	0,1%	0,4%	0,3%	0,5%	0,3%	0,3%	0,3%	0,3%	0,4%	0,1%
Čekání na vývaz	17,7%	18,6%	20,1%	19,9%	21,1%	25,4%	33,3%	22,7%	12,3%	8,2%	22,4%	11%
Čekání na zajištění	1%	2,1%	1,7%	1,3%	0,8%	0,9%	2,1%	2,3%	1,8%	1%	0,7%	1%
Nedeklarovaný prostor	8,9%	13,4%	8%	7,2%	7,2%	7,9%	10,1%	3,1%	0,3%	4,4%	6,7%	5,5%
Příprava chodu stroje	1,4%	1,1%	1,4%	0,6%	0,8%	1,9%	0,5%	1,1%	0,5%	0,8%	1,5%	0,9%
Celkový čas příprav	38,7%	44,7%	40,1%	39,2%	39,6%	45,6%	52,0%	39,6%	25,7%	23,9%	40%	26,8%
Tkaní												
Chod stroje tkaní	28,1%	29,6%	32,9%	25,6%	27%	27%	15,2%	30,5%	30,2%	22,7%	18,3%	25,1%
Stop - osnova	0,6%	0,6%	0,7%	0,6%	0,5%	0,9%	0,5%	0,7%	0,7%	0,4%	0,4%	0,6%
Stop - útek	1,1%	0,9%	0,9%	0,7%	0,6%	0,7%	0,4%	0,6%	0,6%	0,5%	0,4%	0,3%
Stop - ruční	13,5%	13,6%	13,8%	8,6%	9,1%	8,9%	11,2%	4,5%	3,5%	2,4%	1,6%	2,7%
Stop TPV	0,4%	0,9%	1,1%	1,2%	1,3%	1,6%	0%	1,4%	1,4%	1,5%	1,2%	0,9%
Čekání na materiál	3,5%	1,6%	2,4%	15,6%	13,9%	9,5%	16,7%	4,8%	5,1%	7%	3,5%	3,5%
Čekání na seřízení	1,6%	0,9%	2,2%	0,6%	1%	1,2%	1,5%	0,5%	0,5%	0,6%	0,5%	0,6%
Čekání na servis	0%	0%	0%	0%	0%	0,8%	0%	0%	0,4%	0,3%	0,2%	0,1%
Opravy seřizovač	0,2%	0,1%	0,2%	0,2%	0,2%	0,1%	0,1%	0,2%	0,1%	0,1%	0,1%	0,1%
Opravy servis	0,1%	0,1%	0,1%	0%	0,1%	0,1%	0%	0%	0%	0%	0%	0%
Celkové prostroje tkaní	21%	19,4%	22,3%	29,7%	28,6%	25,1%	30,5%	14,8%	13,1%	13,5%	8,7%	9,2%
Proces tkaní včetně prostrojů	49%	49%	55,1%	55,3%	55,6%	52,1%	45,7%	45,3%	43,3%	36,2%	27,0%	34,2%

Tab 1) Celkové rozdělení chodu stroje [28]

7.4.2 Chod a prostoje stroje 6701


V minulé kapitole byl graficky zobrazen proces tkaní včetně prostoje. Obr. 35 zobrazuje rozdělení procesu tkaní na prostoje a samotný chod stroje. Na grafu je viditelné snížení prostoje a zvýšení čistého času tkaní počínající srpnem 2020.



Obr. 35) Prostoje a chod stroje 6701 za rok 2020 při tkaní [28]

7.4.3 Prostoje „ruční stop“

Další zajímavou statistikou je „ruční stop“. Obr. 36 ukazuje, jak často byl za 12 měsíců roku 2020 stroj ručně zastaven zaměstnancem.



Obr. 36) „Ruční stop“ na stroji 6701 [28]

Obr. 36 deklaruje, že počet využití možnosti ručního zastavení stroje se v průběhu roku zmenšoval. Výjimkou je pouze červenec, kdy přišlo krátkodobé navýšení.

7.5 Příklad úspor při snížení přetrhovosti

Následující kapitola se věnuje možné finanční úspoře při snížení přetrhovosti u procesu skaní. Pro výpočet jsou použity materiály SLK 144. Výpočet počítá s roční výrobou z 2 000 000 cívek a průměrnou přetrhovostí při skaní 7,2 %. Hodnoty pro přetrhovost 7,2 % v jsou viditelné v Tab. 2.

Počet kusů cívek ve výrobě	Přetrhovost	Počet přetrhů	Průměrná váha cívky	Průměrný nevyužitý chod z cívky	Nevyužitý chod z cívky	Nevyužitý chod z cívky celkem	Sazba nevyužití technologie	Celkové ztráty při přetrhovosti 7,2 %
2 000 000	7,2%	144000ks	5,5kg	61%	3,4kg	483120kg/rok	10,3kč/kg	4 976 136 Kč

Tab 2) Finanční ztráty při přetrhovosti 7,2 % [28]

Celkové ztráty při přetrhovosti 7,2 % jsou téměř 5 milionů korun. Výpočet potenciálních úspor počítá se zlepšením přetrhovosti o 1 % na celkovou přetrhovost 6,2 %, viz Tab. 3.

Zlepšení přetrhovosti o 1 %								
Počet kusů cívek ve výrobě	Přetrhovost	Počet přetrhů	Průměrná váha cívky	Průměrný nevyužitý chod z cívky	Nevyužitý chod z cívky	Nevyužitý chod z cívky celkem	Sazba nevyužití technologie	Celkové ztráty při přetrhovosti 1 %
2 000 000	1%	20000ks	5,5kg	61%	3,4kg	67100kg/rok	10,3kč/kg	691 130 Kč

Tab 3) Finanční ztráty pro přetrhovost 1 % [28]

Zlepšení přetrhovosti o 1 % znamená úsporu téměř 700 000 Kč. Přetržená cívka je nazývána zkratkou KD („krátká délka“). Tyto cívky jsou po přetrhu převezeny k SSM stroji. Přetržené cívky jsou dále dosoukány na požadovanou délku (spojení se uskutečňuje pomocí stroje Mezdan). Náklady na přesoukání v tabulce v Tab. 4. Méně přetrhů znamená nižší počet KD, méně dosoukání a nižší spotřebu energie. Také pracovník, který by měl dosoukání na starost se může věnovat jiným úkolům.

Náklady na přesoukání KD na SSM						
Zlepšení	Počet cívek	Průměrně přesoukaných cívek/směna	Počet potřebných směn	Celkem potřeba hodin	Sazba Kč/hod	Finanční náklady
1%	20000ks	180ks	111,1	889	265 Kč	235 556 Kč

Tab 4) Náklady na přesoukání cívek [28]

Do výpočtu je třeba započíst také spotřebu elektrické energie a náklady na opravy a údržbu stroje na přesoukání, viz Tab. 5.

Úspory při snížení přetrhovosti o 1 %				
Ztráty při přetrhovosti 1 %	Náklady na přesoukání KD na SSM	Elektrická energie	Údržba a opravy	Úspory celkem
691 130 Kč	235 556 Kč	10 000 Kč	10 000 Kč	946 686 Kč

Tab 5) Celkové úspory při snížení přetrhovosti o 1 % [28]

Celková roční finanční úspora tedy při snížení přetrhovosti o 1 % vychází na téměř 950 000 Kč.

8 ZÁVĚR

První část práce se věnuje teoretickým východiskům u sběru a vyhodnocení dat. Byl vytvořen teoretický systémový rozbor řešené problematiky. Do budoucna se dá očekávat další zvýšení zájmu o firemní data. Lidé (za pomoci počítačů, strojového učení...) jsou schopni z dat dolovat stále větší množství relevantních informací. Dá se tedy předpokládat, že trend zájmu o data bude nadále pokračovat a posilovat.

Druhá část práce se věnuje konkrétním výrobním datům z firmy, která se zabývá výrobou tkanin. Procesní mapa ukazuje, jak složitým výrobním procesem musí tkanina projít, než se z ní stává hotový produkt. Stěžejními částmi výroby tkanin jsou operace skaní a tkaní. Při těchto procesech ve výrobě dochází k mnoha problémům, což dělá tyto procesy zajímavé z pohledu kvality. Data ze skaní a tkaní jsou zpracována a následné výsledky znázorněny pomocí grafů. Dat k analýze je nepřehledné množství, jelikož ve firmě se vyskytuje velké množství materiálů i strojů, na kterých jsou materiály zpracovávány. Pro vyhodnocení dat je možné pracovat s různými časovými intervaly (denní, týdenní, měsíční přetrhovost). V diplomové práci jsou popsány relevantní příklady možných pohledů na výrobní data.

Pravděpodobně nejdůležitějším aspektem hodnocení výrobních dat je finanční stránka věci. Příklad ztrát a úspor je popsán u přetrhovosti při procesu skaní. U materiálů SLK 144 vychází roční úspora při snížení přetrhovosti o 1 % na téměř 950 000 Kč. To jasně ukazuje, jakých úspor lze dosáhnout při vyhodnocení výrobních dat a jejich správné aplikaci ve výrobě. Není tedy s podivem, že firmy jsou ochotny investovat do sledování a hodnocení podnikových dat stále vyšší finanční prostředky.

9 SEZNAM POUŽITÝCH ZDROJŮ

- [1] Petříková, R.: Moderní management znalostí (principy, procesy, příklady dobré praxe). 1. vyd. Praha: Professional Publishing, 2010. 324 s. ISBN 9788074310119
- [2] Novotný, P., Pour, J., Slánský, D.: *Business Intelligence. Jak využít bohatství ve vašich datech*. 1. vyd. Brno: Grada, 2005. 192 s. ISBN 8024710943
- [3] Kořínek, T.: *Metody hodnocení pro management rizik ve veřejné správě* [online]. Pardubice, 2010. 13 s. Článek publikovaný na Univerzita Pardubice, Fakulta ekonomicko-správní, Ústav systémového inženýrství a informatiky. [cit. 17. května 2021]. Dostupné z <https://dk.upce.cz/bitstream/handle/10195/38518/KorinekT_MetodyHodnoceni_2010.pdf?sequence=1>
- [4] Shen, S. 7 Steps to Ensure and Sustain Data Quality [online]. Towards data science. Zveřejněno dne: 29.7.2019. [cit. 17. května 2021]. Dostupné z <<https://towardsdatascience.com/7-steps-to-ensure-and-sustain-data-quality-3c0040591366>>
- [5] Brook, Ch.: What is Data Integrity? Definition, Best Practices & More [online]. Waltham: Digital Guardian. Zveřejněno dne: 1.12.2020. [cit. 17. května 2021]. Dostupné z <<https://digitalguardian.com/blog/what-data-integrity-data-protection-101>>
- [6] COBIT [online]. Wiki.valek.net. Zveřejněno dne: 24.5.2008. [cit. 17. května 2021]. Dostupné z <<https://wiki.valek.net/doku.php?id=statnice:slovník:cobit>>
- [7] COBIT IT Governance Framework Monitor: Processes for Smart Governance of Enterprise IT [online]. Dragon1. Zveřejněno dne: 5.9.2015. [cit. 17. května 2021]. Dostupné z <<https://www.dragon1.com/watch/140695/cobit-it-governance-framework-monitor-processes-for-smart-governance-of-enterprise-it>>
- [8] HILLIER, W.: A Stepby-Step Guide to the Data Analysis Process [online]. CareerFoundry. Zveřejněno dne: 13.8.2020. [cit. 17. května 2021]. Dostupné z <<https://careerfoundry.com/en/blog/data-analytics/the-data-analysis-process-step-by-step/>>
- [9] Groff, J. R., Weinberg, P. N.: *SQL: kompletní průvodce*. 1. vyd. Brno: Computer Press, 2005. 936 s. ISBN 80-251-0369-2.
- [10] MySQL vs. MSSQL—Performance and Main Differences Between Database and Servers [online]. Austin: DNSStuff. Zveřejněno dne: 4.8.2020. [cit. 18. května 2021]. Dostupné z <<https://www.dnsstuff.com/mysql-vs-mssql-performance>>
- [11] What Is SCADA? [online]. Maintain X. Zveřejněno dne: 11.12.2020. [cit. 18. května 2021]. Dostupné z <<https://www.getmaintainx.com/learning-center/scada-definition/>>
- [12] Wan Jusoh, W. N. S. E., Mat Hanafiah, M. A., Ghani, Ab. M. R., Raman, S. H.: Remote terminal unit (RTU) hardware design and implementation efficient in different application [online]. Langkawi: Power Engineering and Optimization Conference (PEOCO), 2013 IEEE 7th International. P. 570-773. Zveřejněno dne: 3.7.2013. [cit. 18. května 2021]. Dostupné z <<https://core.ac.uk/download/pdf/235644584.pdf>>

- [13] Stouffer, K., Falco, J.: Guide to supervisory control and data acquisition (SCADA) and industrial control systems security [online]. Gaithersburg: National institute of standards and technology. Zveřejněno: září 2006. [cit. 18. května 2021]. Dostupné z <https://www.researchgate.net/publication/246350235_Guide_to_Supervisory_Control_and_Data_Acquisition_SCADA_and_Industrial_Control_Systems_Security>
- [14] Bolton, W.: *Programmable logic controllers*. 4th ed. Oxford: Elsevier Newnes, 2006. 303 pgs. ISBN 978-0-7506-8112-4
- [15] What is a Human-Machine Interface or HMI [online]. San Giovanni Lupatoto: Exor International. Zveřejněno: 7.2.2019. [cit. 18. května 2021]. Dostupné z <<https://www.exorint.com/en/blog/2019/02/07/what-is-a-human-machine-interface-and-do-you-make-or-buy-it>>
- [16] Software for remote viewing of HMI from Desktop PC - Pro-face Remote HMI Client for Win [online]. Pro-face by Schneider Electric. Zveřejněno: 2021 [cit. 18. května 2021]. Dostupné z <https://www.proface.com/en/product/soft/remotehmi_client/top>
- [17] MES systém (Manufacturing Execution System) [online]. Hvězdoňovice: MES Centrum. Zveřejněno 2021 [cit. 18. května 2021]. Dostupné z <<http://www.mescenter.org/cz/clanky/5-co-je-to-mes-system>>
- [18] MES systém - základní funkcionality [online]. Hvězdoňovice: MES Centrum. Zveřejněno: 2021 [cit. 18. května 2021]. Dostupné z <<http://www.mescenter.org/cz/clanky/6-zakladni-funkcionalita-mes-systemu>>
- [19] Wang, Ch., Zhou, S.: Control of key performance indicators of manufacturing production systems through pair-copula modeling and stochastic optimization [online]. Amsterdam: Journal of Manufacturing Systems Vol. 58, Part. 1, pp. 120-130. Zveřejněno: 2021 [cit. 18. května 2021]. Dostupné z <<https://www.sciencedirect.com/science/article/pii/S0278612520301904>>
- [20] Dub, M., Novotný, R.: Nastane s příchodem Industry 4.0 změna klasického vertikálního pojetí PLC + HMI/SCADA + MIS/MES? [online]. Děčín: Automa. Str. 14 – 15. Zveřejněno: 8.9.2016 [cit. 18. května 2021]. Dostupné z <https://automa.cz/Aton/FileRepository/pdf_articles/8951.pdf>
- [21] Smelík, L.: Trendy v robotice se utváří pod vlivem pandemie [online]. Český Těšín: Trade Media International. Zveřejněno: 19.4.2021 [cit. 18. května 2021]. Dostupné z <<https://www.vseoprmyslu.cz/robotizace/prumyslove-roboty/trendy-v-robotice-se-utvari-pod-vlivem-pandemie.html>>
- [22] Vojáček, A.: OEE = celková efektivnost zařízení a výroby [online]. Zveřejněno: 19.5.2019 [cit. 18. května 2021]. Dostupné z <<https://automatizace.hw.cz/oeo-celkova-efektivnost-zarizeni-a-vyroby.html>>
- [23] Ježek, V.: Když OEE mám měřit, tak výsledkům chci věřit [online]. Želečovice: API - Akademie produktivity a inovací, s.r.o. Zveřejněno: 5.11.2018 [cit. 18. května 2021]. Dostupné z <<https://www.e-api.cz/25911n-kdyz-oeo-mam-merit-tak-vysledkum-chci-verit>>
- [24] Dwivedi, D.: Machine Learning For Beginners [online]. Towards data science. Zveřejněno dne: 7.5.2018. [cit. 17. května 2021]. Dostupné z <<https://towardsdatascience.com/machine-learning-for-beginners-d247a9420dab>>

- [25] Kordové tkaniny [online]. Velká nad Veličkou: Kordárna PLUS a.s. Zveřejněno: 2017 [cit. 18. května 2021]. Dostupné z <<http://www.kordarna.cz/kordove-tkaniny/>>
- [26] Skaní [online]. Brno: Textilní zkušební ústav. Zveřejněno: 2021 [cit. 18. května 2021]. Dostupné z <<http://www.skolertextilu.cz/elearning/416/zaklady-textilnich-technologii/technologie-tkani/Skani.html>>
- [27] Textilarten [online]. Hürth: Shirtigo. Zveřejněno: 2021 [cit. 18. května 2021]. Dostupné z <<https://helpcenter.shirtigo.de/wiki/textilien/textilarten/>>
- [28] *Interní data společnosti Kordána Plus a.s.: podniková dokumentace*. Velká nad Veličkou, 2021

10 SEZNAM ZKRATEK, TABULEK A OBRÁZKŮ

10.1 Seznam zkratk

Zkratka	Význam
KM	Knowledge Management
COBIT	Control Objectives for Information and Related Technology
ICT	Information and Communication Technologies
IT	Information Technology
KGI	Key Goal Indicator
KPI	Key Performance Indicator
CRM	Customer Relationship Management
SQL	Structured Query Language
MSSQL	Microsoft SQL Server
SCADA	Supervisory Control And Data Acquisition
RTU	Remote Terminal Unit
PLC	Programmable Logic Controller
HMI	Human Machine Interface
MIS	Manufacturing Information System
MES	Manufacturing Execution System
ERP	Enterprise Resource Planning
PLM	Product Lifecycle Management
IO	Input/Output
RTDB	Real Time Database
IFR	International Federation of Robotics
OEE	Overall Equipment Effectiveness
AI	Artificial Intelligence

10.2 Seznam tabulek

TAB 1) CELKOVÉ ROZDĚLENÍ CHODU STROJE [28]	50
TAB 2) FINANČNÍ ZTRÁTY PŘI PŘETRHOVOSTI 7,2 % [28].....	52
TAB 3) FINANČNÍ ZTRÁTY PRO PŘETRHOVOST 1 % [28].....	52
TAB 4) NÁKLADY NA PŘESOUKÁNÍ CÍVEK [28].....	52
TAB 5) CELKOVÉ ÚSPORY PŘI SNÍŽENÍ PŘETRHOVOSTI O 1 % [28]	53

10.3 Seznam obrázků

OBR. 1) VZTAH MEZI DATY, INFORMACEMI A ZNALOSTMI [1].....	11
OBR. 2) PROCES TVORBY ZNALOSTÍ [1].....	12
OBR. 3) CYKLUS MANAGEMENTU ZNALOSTÍ [1]	12
OBR. 4) COBIT KOSTKA [6].....	18
OBR. 5) PŘÍKLAD HODNOTÍCÍ KARTY PRO COBIT [7].....	18
OBR. 6) ZPŮSOB PRÁCE SQL [9].....	21
OBR. 7) ČÁSTI TYPICKÉHO DATABÁZOVÉHO ŘÍDICÍHO SYSTÉMU [9]...	22
OBR. 8) PODOBNOSTI A ROZDÍLY MEZI MSSQL A MYSQL [10]	24
OBR. 9) PROGRAMOVATELNÝ LOGICKÝ AUTOMAT PLC [14].....	26
OBR. 10) USPOŘÁDÁNÍ PLC SYSTÉMU [14].....	27
OBR. 11) USPOŘÁDÁNÍ KOMUNIKAČNÍHO SCADA SYSTÉMU [13]	27
OBR. 12) PŘÍKLAD ROZHRANÍ HMI [16].....	28
OBR. 13) VERTIKÁLNÍ INTEGRACE VÝROBNÍCH SYSTÉMŮ. [17]	29
OBR. 14) POTENCIÁLNÍ ZMĚNY KLASICKÉHO VERTIKÁLNÍHO POJETÍ INFORMAČNÍ SÍTĚ V DŮSLEDKU PRŮMYSLU 4.0 [20].....	31
OBR. 15) OEE JAKO UKAZATEL EFEKTIVNOSTI VYUŽITÍ STROJE ČI ZAŘÍZENÍ [23].....	34
OBR. 16) VÝPOČET OEE [22].....	34
OBR. 17) TYPY STROJOVÉHO UČENÍ [24]	35
OBR. 18) PRŮBĚH STROJOVÉHO UČENÍ S UČITELEM [24]	35
OBR. 19) PRŮBĚH STROJOVÉHO UČENÍ BEZ UČITELE [24]	37
OBR. 20) METODA K-MEANS SE 3 SHLUKY [24].....	37
OBR. 21) ŘEZ PNEUMATIKOU VYUŽÍVAJÍCÍ KORDOVOU TKANINU [25] 39	
OBR. 22) JEDNOSTUPŇOVÉ A VÍCESTUPŇOVÉ SKANÍ [26].....	39
OBR. 23) POPIS TKANÍ [27].....	40
OBR. 24) PROCESNÍ MAPA VÝROBY TKANIN [28].....	41
OBR. 25) NÁHLED ZADANÝCH DAT SKANÍ [28]	42
OBR. 26) NÁHLED ZADANÝCH DAT TKANÍ [28].....	43
OBR. 27) TÝDENNÍ PŘETRHOVOST TECHNOLOGIE 37 A 38 [28]	44
OBR. 28) TÝDENNÍ PŘETRHOVOST PODLE MATERIÁLŮ [28].....	45
OBR. 29) DENNÍ PŘETRHOVOST MATERIÁLU SLK 220X 1X 2 320/320S 259NA ZA MĚSÍC ÚNOR [28]	46
OBR. 30) PŘETRHOVOST MATERIÁLU SLK 144X 1X 2 380/380S 259NA CON ZA MĚSÍC ÚNOR [28].....	46
OBR. 31) VYUŽITÍ TECHNOLOGIÍ PŘI PROCESU SKANÍ [28]	47

OBR. 32) PRŮMĚR VYUŽITÍ TECHNOLOGIÍ 36–39 PŘI PROCESU SKANÍ [28]	
	47
OBR. 33) ROZDĚLENÍ PROSTOJŮ PŘI SKANÍ U TECHNOLOGIE 37 [28]	48
OBR. 34) VYUŽITÍ STROJE 6701 ZA ROK 2020 [28]	49
OBR. 35) PROSTOJE A CHOD STROJE 6701 ZA ROK 2020 PŘI TKANÍ [28] .	51
OBR. 36) „RUČNÍ STOP“ NA STROJI 6701 [28].....	51