

# Využití statistických metod jako nástroje manažerského rozhodování v podniku

## Bakalářská práce

*Studijní program:*

B6208 Ekonomika a management

*Studijní obor:*

Podniková ekonomika

*Autor práce:*

**Viktoriya Yurhel**

*Vedoucí práce:*

Ing. Vladimíra Hovorková Valentová, Ph.D.

Katedra ekonomické statistiky







## Zadání bakalářské práce

# Využití statistických metod jako nástroje manažerského rozhodování v podniku

*Jméno a příjmení:* **Viktoriya Yurhel**  
*Osobní číslo:* E17000068  
*Studijní program:* B6208 Ekonomika a management  
*Studijní obor:* Podniková ekonomika  
*Zadávací katedra:* Katedra ekonomické statistiky  
*Akademický rok:* **2019/2020**

### Zásady pro vypracování:

1. Formulace cíle práce.
2. Teoretická část práce – Manažerské rozhodování a jeho význam, rozhodovací procesy, statistické metody uplatňované při manažerském rozhodování v podniku.
3. Představení vybrané společnosti.
4. Analýza používání statistických metod v práci manažerů firmy, návrh na využití dalších statistických metod, které by vedly k usnadnění manažerské práce.
5. Závěrečné zhodnocení výsledku práce a doporučení managementu firmy.

Rozsah grafických prací:  
Rozsah pracovní zprávy:  
Forma zpracování práce:  
Jazyk práce:

30 normostran  
tištěná/elektronická  
Čeština



### Seznam odborné literatury:

- BUDÍKOVÁ, Marie, Maria KRÁLOVÁ, Bohumil MAROŠ. 2010. *Průvodce základními statistickými metodami*. Praha: GRADA Publishing. ISBN 978-80-247-3243-5.
- DICKEN, Peter. 2011. *Global shift: mapping the changing contours of the world economy*. 6<sup>th</sup> ed. New York: Guilford Press. ISBN 978-1-60918-006-5.
- FOTR, Jiří a Lenka ŠVECOVÁ. 2010. *Manažerské rozhodování: postupy, metody a nástroje*. 2. vyd. Praha: Ekopress. ISBN 978-80-86929-59-0.
- HINDLS, Richard, Markéta ARLTOVÁ, Stanislava HRONOVÁ, Ivana MALÁ, Luboš MAREK, Iva PECÁKOVÁ a Hana ŘEZANKOVÁ. 2018. *Statistika v ekonomii*. Průhonice: Professional Publishing. ISBN 978-80-88260-09-7.
- TRIOLA, Mario F. 2017. *Elementary Statistics*. 13<sup>th</sup> ed. Boston: Pearson Education Limited. ISBN 978-0134462455.
- PACÁKOVÁ, Viera a kol. 2009. *Štatistické metódy pre ekonómov*. Bratislava: Iura Edition. ISBN 978-80-8078-284-9.
- PROQUEST. 2019. *Databáze článků ProQuest* [online]. Ann Arbor, MI, USA: ProQuest. Dostupné z: <http://knihovna.tul.cz>

Konzultant: Ing.Pavel Cvejn

Vedoucí práce:

Ing. Vladimíra Hovorková Valentová, Ph.D.  
Katedra ekonomické statistiky

Datum zadání práce:

31. října 2019

Předpokládaný termín odevzdání:

31. srpna 2022

prof. Ing. Miroslav Žižka, Ph.D.  
děkan

L.S.

Ing. Jan Öhm, Ph.D.  
vedoucí katedry

V Liberci dne 31. října 2019

## Prohlášení

Prohlašuji, že svou bakalářskou práci jsem vypracovala samostatně jako původní dílo s použitím uvedené literatury a na základě konzultací s vedoucím mé bakalářské práce a konzultantem.

Jsem si vědoma toho, že na mou bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, zejména § 60 – školní dílo.

Beru na vědomí, že Technická univerzita v Liberci nezasahuje do mých autorských práv užitím mé bakalářské práce pro vnitřní potřebu Technické univerzity v Liberci.

Užiji-li bakalářskou práci nebo poskytnu-li licenci k jejímu využití, jsem si vědoma povinnosti informovat o této skutečnosti Technickou univerzitu v Liberci; v tomto případě má Technická univerzita v Liberci právo ode mne požadovat úhradu nákladů, které vynaložila na vytvoření díla, až do jejich skutečné výše.

Současně čestně prohlašuji, že text elektronické podoby práce vložený do IS/STAG se shoduje s textem tištěné podoby práce.

Beru na vědomí, že má bakalářská práce bude zveřejněna Technickou univerzitou v Liberci v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů.

Jsem si vědoma následků, které podle zákona o vysokých školách mohou vyplývat z porušení tohoto prohlášení.

Viktoriya Yurhel



## **Anotace**

Tato práce se zabývá manažerským rozhodováním na základě statistických nástrojů a metod. Jedná se konkrétně o zkoumání chybovosti v procesech, na kterých participuje člověk. Zkoumáme několik odvětví v podniku Magna Exteriors (Bohemia) s.r.o. Cílem této práce je vytvořit optimalizace procesů v závislosti na míře chybovosti, které mohou mít vyšší efektivitu a eliminují lidskou chybu. Budeme se zároveň zajímat o to, jestli pracovníci chybují v konkrétních časových úsecích během každého dne a také o to, jestli je distribuce chyby napříč jednotlivými odděleními relevantní.

## **Klíčová slova**

Manažerské rozhodování, lidský faktor, distribuce chyby, optimalizace procesů, periodicitata dat

## **Annotation**

This work deals with managerial decision-making based on statistical tools and methods. It is specifically an error rate analysis in man-made errors in processes. We analyze several sectors in the company Magna Exteriors (Bohemia) s.r.o. The goal of this work is to create process optimizations depending on the error rate, which can have higher efficiency and eliminate human error. At the same time, we will be interested in whether workers make errors in specific time periods during each day, and also in whether the distribution of errors across individual departments is relevant.

## **Key words**

Managerial decision-making, human factor, man-made error distribution, process optimization, data periodicity



## **Poděkování**

Děkuji tímto za podporu, čas a cenné rady vedoucí práce Ing. Vladimíře Hovorkové Valentové, Ph.D. a jednatelem společnosti Magna Exteriors (Bohemia) s. r. o. Ing. Pavlu Cvejnovi. Děkuji také společnosti Magna Exteriors (Bohemia) s. r. o. za poskytnutí přístupu k jejímu zázemí pro řešení této problematiky.



## Obsah

Úvod.....	13
1 Manažerské rozhodování a jeho význam.....	14
1.1 Meritorní stránka.....	15
1.2 Stránka formálně logická.....	15
2 Rozhodovací procesy a jejich struktura.....	16
2.1 Rozhodovací problémy.....	16
2.1.1 Klasifikace rozhodovacích problémů.....	16
3 Analýza dat.....	18
3.1 Fáze analýzy dat.....	18
3.1.1 Stanovení cíle.....	18
3.1.2 Shromažďování dat.....	19
3.1.3 Čištění dat.....	19
3.1.4 Interpretace dat.....	20
3.1.5 Sdílení výsledků.....	20
4 VYBRANÉ STATISTICKÉ METODY PŘI MANAŽERSKÉM ROZHODOVÁNÍ	
21	
4.1 Metody popisné statistiky.....	21
4.1.1 Základní statistické pojmy.....	21
4.1.2 Rozdělení četností.....	22
4.1.3 Statistické charakteristiky.....	22
4.2 Statistická indukce.....	25
4.2.1 Bodový odhad.....	26
4.2.2 Intervalový odhad.....	26
4.3 Shluková analýza.....	28
4.3.1 Hierarchické metody.....	29
4.3.2 Nehierarchické metody.....	30

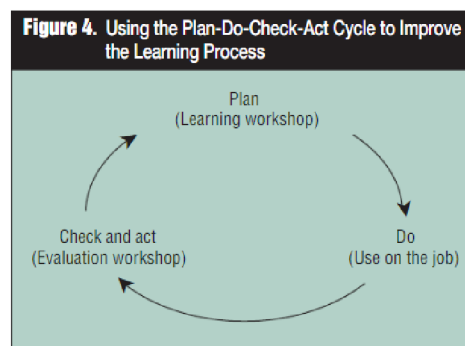
4.4	Q-Q graf .....	30
4.5	Spektrální analýza časových řad .....	31
5	Manažerské rozhodování ve společnosti Magna Exteriors (Bohemia) s.r.o. ....	33
5.1	Metodika.....	33
5.2	Charakteristika podniku .....	34
5.2.1	Technologie podniku .....	34
5.3	Podnikatelský cíl .....	35
5.4	Zákazníci .....	36
5.5	Obecná struktura podniku .....	37
5.6	Manažerské činnosti .....	37
5.6.1	Nástroje pro měření lidské chyby .....	37
5.6.2	Analýza lidské chyby .....	39
5.6.3	Zhodnocení analýzy a návrh intervenčního konceptu.....	44
5.6.4	Distribuce chyby .....	44
5.7	Procesy podniku, které jsou zatíženy lidskou chybou.....	45
5.8	Úskalí podniku a jejich možná řešení.....	46
5.8.1	Historie chyb .....	46
5.8.2	Rozdíly cen .....	46
5.8.3	Kódování v projektech .....	47
5.8.4	Nastavení jobu .....	48
5.8.5	Inventarizace majetku .....	48
5.8.6	Odvolávky .....	48
6	Závěr .....	49
7	Použité zdroje .....	50

# Úvod

Použití statistických technik, jako je statistické řízení procesu (SPC) či experimentální design, již dlouho hraje důležitou roli v obchodu a průmyslu nejen v USA, ale ve všech vyspělých ekonomikách. Bohužel efektivní integrace statistiky do vědy o řízení byla ztížena nejednoznačností v tom, jak statistika zapadá do této oblasti. Například hromadné školení manažerů v SPC a experimentálním designu se setkalo s omezeným úspěchem. Pokud se má statistika stát nedílnou součástí managementu, musí se řešit čtyři hlavní problémy:

- Manažeři musí rozumět tomu, proč potřebují mít statistické znalosti.
- Současní i budoucí manažeři musí tyto znalosti rozvíjet.
- Musí být přijata opatření, která zajistí, že znalosti budou účinně aplikovány.
- Musí být posouzena návratnost znalostí a jejich aplikace. To, co manažeři potřebují vědět a proč, je řešeno a ilustrováno.

Klíčem k porozumění a používání statistického myšlení je rozpoznat, že jde o nastavení mysli. Pochopení a používání statistického myšlení vyžaduje změnu stávajícího myšlení. Manažeři mohou efektivně rozvíjet porozumění statistikám pomocí cyklu učit se, použít a hodnotit.



*Obrázek 1: Cyklus učít se-použít-ohodnotit*

Zdroj: PROQUEST. 2019 Databáze článků ProQuest

Cyklus začíná definováním statistického myšlení. Následuje výukový workshop, ve kterém mohou manažeři prohloubit své chápání a znalosti statistického myšlení. Vzhledem k tomu, že dospělí se nejlépe učí praxí, dalším krokem je, aby manažeři ve své každodenní práci používali koncepty a nástroje statistického myšlení. Využití na pracovišti je důležité, protože statistické myšlení podobně jako sportování je činnost charakterizovaná chováním, činy a interakcemi. Efektivní využití vyžaduje, aby manažer získával zkušenosti na poli praxe.

# 1 Manažerské rozhodování a jeho význam

Rozhodování je jeden z nejvýznamnějších a nejdůležitějších kroků managementu, jelikož výsledek rozhodovacích procesů může ovlivnit celý chod a budoucnost organizace. Správně se rozhodnout a nést zodpovědnost za rozhodnutí je nedílnou součástí manažerské práce. Na rozhodovací proces působí mnoho faktorů, a to zejména osobnost manažera, charakter a závažnost rozhodovacího problému a podmínky pro rozhodování. (Veber 2009)

Podle Hružové (2010) „manažerské rozhodování vychází z poznatků psychologie a sociologie, ale i matematiky a statistiky, z nejstarších a vyzrálých vědních disciplín. Jedná o multidisciplinární vědu, která využívá poznatků řady společenských a exaktních věd, jak zjednodušeně schematizuje (obr. 2). Důležité je, že není teoretickou vědou, ale že se vyvíjí a prověřuje v praxi.“



Obrázek 2: Multidisciplinarita manažerského rozhodování

Zdroj: HRŮZOVÁ, Helena. Manažerské rozhodování

Základní pojmy rozhodování byly vybrány podle Vebera et. al (2009):

- *Deskriptivní teorie rozhodování* – zaměřuje se na popis, analýzu a hodnocení již proběhlých rozhodovacích problémů.
- *Normativní teorie rozhodování* – poskytuje návod, jak by měly být rozhodovací problémy řešeny.
- *Dobře strukturované problémy* – jednodušší problémy řešené na nižších úrovních řízení charakteristické mj. rutinními přístupy k jejich řešení.
- *Postoj rozhodovatele k riziku* – vyjadřuje přístup k volbě rizikových variant – averz, sklon či neutrální postoj k riziku.
- *Riziko a nejistota* – taková situace v prostředí, ve kterém se podnik pohybuje, pro niž je charakteristická částečná či plná neznalost budoucího vývoje.

- *Rozhodovací problém* – problém s více než jednou variantou řešení.
- *Rozhodovací proces* – proces řešení rozhodovacího problému členěný do více časově návazných fází.
- *Špatně strukturované problémy* – složité problémy řešené na vyšších úrovních řízení, charakteristické mimo jiné i inovativními přístupy k řešení.

Rozhodování probíhá na různých úrovních řízení organizací a má dvě stránky:

- *meritorní* – věcnou, obsahovou,
- *formálně logickou* – procedurální.

## 1.1 Meritorní stránka

Odráží odlišnosti rozhodovacích procesů – jejich typu zaměření. Každý typ rozhodovacího procesu má své charakteristické rysy, které jsou zdrojem odlišností těchto procesů: (Svozilová, 2011)

- výrobní program,
- kapitálové investice,
- uvedení výrobku na trh a jeho marketingové strategie,
- organizačním uspořádání firmy,
- vytvoření společného podniku,
- výběru pracovníků.

## 1.2 Stránka formálně logická

Jedná se o společné rysy a vlastnosti rozhodovacích procesů, a to bez ohledu na jejich odlišnou obsahovou náplň. (Svozilová, 2011)

Jednotlivé rozhodovací procesy spojuje určitý rámcový postup, procedura řešení odvíjející se od (Svozilová, 2011)

- identifikace problému,
- vyjasňování jeho příčin a cílů řešení,
- vyhodnocení variantních řešení,
- volbu varianty určení k realizaci.

## 2 Rozhodovací procesy a jejich struktura

Rozhodovací proces je systém řešení problémů s více variantami řešení, posuzování a výběr nejlepší možné varianty. Tzv. proces volby je vyhodnocení jednotlivých variant a určení optimálního rozhodnutí.

Rozhodování a celá rozhodovací proces ovlivňuje mnoho faktorů: (Veber, 2009)

- rozhodovací problémy, především jejich charakter a závažnost,
- podmínky pro rozhodování, zejména disponibilní čas, míra rizika a nejistoty aj.,
- osobnost rozhodovatele (manažera), především jeho přístup k rozhodování, styl rozhodování, ale i minulé zkušenosti atd.

### 2.1 Rozhodovací problémy

Obecně lze říci, že problémy můžeme definovat jako existenci odchylky mezi žádoucím stavem a skutečným stavem. Nežádoucí odchylka je stav, kdy současná situace je horší než situace, která je žádoucí. Pro vytvoření žádoucí situace se můžeme zaměřit na zkušenosti z minulosti, ze kterých můžeme čerpat. (Veber, 2009)

Manažer by měl mít při rozhodování možnost volit mezi alternativními řešeními. Manažeři potřebují splnit více různých cílů najednou. (Veber, 2009)

#### 2.1.1 Klasifikace rozhodovacích problémů

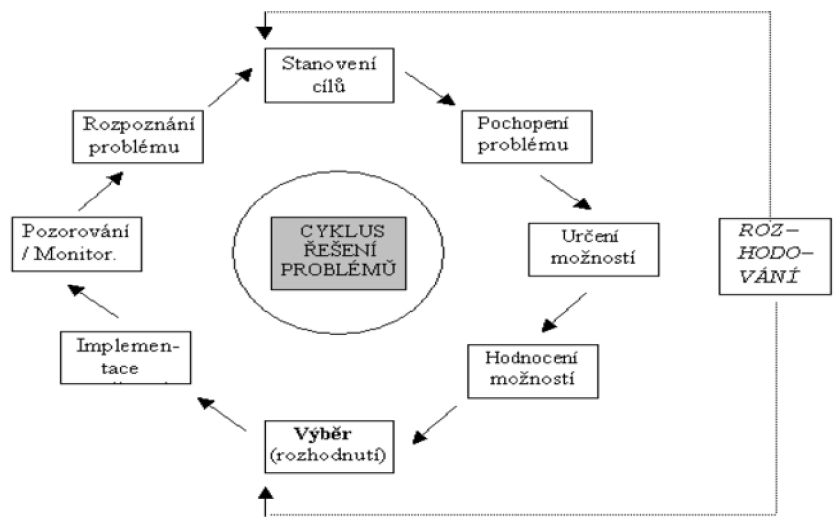
Základní klasifikace podle složitosti a možnosti algoritmizace je dle Vebera (2009)

- dobře strukturované problémy,
- špatně strukturované problémy.

Dobře strukturované problémy můžeme definovat jako jednoduché, programované nebo algoritmizované pro které je charakteristické, že je lze opakovaně řešit na nižších (operativních) úrovních řízení a existují k nim rutinní postupy řešení.

Špatně strukturované problémy jsou řešeny na vyšších úrovních řízení a do jisté míry jsou vždy nové a neopakovatelné.





*Obrázek 3: Cyklus řešení problému*

Zdroj: HRŮZOVÁ, Helena. Manažerské rozhodování

## 3 Analýza dat

Analýza dat je procesem kontroly, čištění, transformace a modelování dat s cílem objevit užitečné informace, vyvodit potřebné závěry a podpořit rozhodování. Analýza dat má mnoho aspektů a přístupů, zahrnuje různé techniky a používá se v různých oblastech obchodu, vědy či průmyslu. V dnešním obchodním světě hraje analýza dat roli při přijímání rozhodnutí, která mohou mít díky ní vyšší vypovídající hodnotou, a tedy pomáhá podnikům fungovat efektivněji.

Analýza dat je proces získávání nezpracovaných dat a jejich následné přeměny na informace užitečné pro rozhodování uživatelů. Data se shromažďují a analyzují za účelem zodpovězení otázek, testování hypotéz nebo vyvracení teorií. (Sarantakos, 2007)

Statistik Tukey (1977) definoval analýzu dat v roce 1961 jako postupy a techniky pro interpretaci výsledků takových postupů, způsoby plánování shromažďování dat, aby se jejich analýza usnadnila, zpřesnila a všechny stroje a výsledky (matematické) statistiky, které se vztahují na analýzu dat. (Lexis-Beck, 2010)

Existuje několik fází analýzy dat, které lze rozlišit. Fáze jsou iterativní, zpětná vazba z pozdějších fází může vést k další práci ve fázích dřívějších. (Lewis-Beck, 2010)

### 3.1 Fáze analýzy dat

#### 3.1.1 Stanovení cíle

Prvním krokem je stanovení cíle analýzy dat, který se obvykle značí jako *problem statement* (volně jako „problémová otázka“). Tento krok je o stanovení hypotézy a metody, jak je ji možné testovat. Zde se objevují určité otázky, jako je určení obchodního problému, který se daná osoba pokouší vyřešit. Tato otázka, na které se celá analýza zakládá, je zásadní. Pokud se například objeví problém ztráty zákazníků, zaměřuje se datový analytik na to, aby pochopil podstatu problému tak, že získá představu o podnikání a jeho cílech, aby mohl být problém definován správným způsobem. (Yayici, 2015)

Přestože firma vyniká, pokud jde o získávání nových klientů, nedokáže si s nimi zajistit stálý obchod, což vyvolává otázku nejen proč čelí ztrátě zákazníků, ale také po aspektech, které nepříznivě ovlivňují zákaznickou zkušenost a jak můžeme zvýšit udržení spotřebitelů a zároveň snížit náklady. (Taddy, 2019)

Po definování problému je nezbytné dospět k závěru, které zdroje dat mohou pomoci při jeho řešení. Můžete si například všimnout, že platforma má hladký prodejní proces, ale má slabou zákaznickou zkušenost, kvůli které se zákazníci nevracejí, aby využili jejích služeb. Zde se tedy zaměříme na otázku, které zdroje dat mohou hrát roli v reakci na tento problém. (Taddy, 2019)

Přestože firma vyniká, pokud jde o získávání nových klientů, nedokáže s nimi zajistit stálý vztah, což vyvolává otázku nejen proč čelí ztrátě zákazníků, ale také které aspekty nepříznivě ovlivňují zákaznickou zkušenost a jak můžeme zvýšit udržení spotřebitelů. (Taddy, 2019)

### 3.1.2 Shromáždění dat

Jakmile je stanoven cíl, musí analytik pracovat na shromáždění a uspořádání vhodných dat. Tím je definování požadovaných údajů nezbytným předpokladem. Mohou to být kvalitativní nebo kvantitativní údaje. Každý z údajů je primárně uspořádán do tří kategorií, a to údaje: (Lexis-Beck, 2010)

- *první strany* – data, která uživatel nebo jeho společnost přímo shromáždila od svých zákazníků;
- *druhé strany* – data první strany shromážděna od jiných společností. Ta mohou být k dispozici přímo od společnosti nebo prostřednictvím soukromého trhu. Může jít o data z podobných zdrojů jako data první strany, jako je aktivita na webu, zákaznické průzkumy, aktivita na sociálních sítích atd.
- *třetí strany* – data, která byla shromážděna z více zdrojů prostřednictvím organizace třetí strany. Ty jsou často z velké části nestructurované a shromažďuje je mnoho společností pro generování průmyslových zpráv a pro provádění marketingových analýz a průzkumů.

### 3.1.3 Čištění dat

Jakmile jsou data shromážděna, připravujeme se na provedení analýzy, která zahrnuje čištění dat a zajištění jejich kvality. Mezi hlavní povinnosti spojené s čištěním dat patří: (Lexis-Beck, 2010)

- odstranění chyb, duplikací a problémů s odchylkami, ke kterým dochází při agregaci dat z více zdrojů;
- odstranění nepodstatných dat a nerelevantních pozorování, která nesouvisejí s navrhovanou analýzou.
- poskytování datové struktury;

- doplnění porušení dat.

### 3.1.4 Interpretace dat

Jakmile jsou data vyčištěna, zaměříme se na jejich analýzu. Přístup, který zaujímáme k analýze těchto dat, závisí na našem cíli. Ať už se jedná o analýzu časových řad, regresní analýzu nebo jednorozměrnou či vícerozměrnou analýzu, existuje mnoho typů analýzy dat, jejichž zvolení závisí na tom, čeho chceme touto analýzou dosáhnout. Různé typy analýzy dat lze rozdělit do čtyř kategorií: (Lexis-Beck, 2010, Yayici, 2015)

- *popisná analýza* – určuje, co již proběhlo. Obvykle se provádí předtím, než analytik prozkoumá problém hlouběji. Může jít například o počet uživatelů přistupujících k jejich produktu během určitého období, což může být použito k měření prodejních údajů v posledních několika letech.
- *diagnostická analýza* – tato forma analýzy je zaměřena na pochopení toho, proč k určitému problému došlo.
- *předpovědní analýza* – tato forma analýzy umožňuje analytikovi detekovat budoucí trendy a předpovídat růst na základě historických dat.
- *preskriptivní analýza* – tato forma analýzy umožňuje uživatelům vytvářet budoucí doporučení. Jako poslední krok v procesu analýzy zahrnuje všechny analyzované aspekty, které byly zmíněny dříve.

### 3.1.5 Sdílení výsledků

Jakmile analytik dokončí své analýzy a odvodí své poznatky, tak posledním krokem v procesu analýzy dat je sdílení poznatků s dotčenými lidmi. Protože je to složitější než pouhé zveřejňování výsledků práce a jde také o dešifrování výsledků a jejich snadné zobrazení. (Yayici, 2015)

## 4 VYBRANÉ STATISTICKÉ METODY PŘI MANAŽERSKÉM ROZHODOVÁNÍ

Statistická analýza poskytuje rámec pro organizování a analýzu dat a zkoumání obchodních problémů logickým a systematickým způsobem. Se značným pokrokem v oblasti výpočetní techniky, ke kterému došlo, mají podniky lepší přístup k datům a jejich množství je větší než kdykoli předtím. Statistická analýza poskytuje manažerům nástroje nezbytné pro práci s velkým množstvím dat a pro stále efektivnější obchodní rozhodování na základě závěrů získaných z těchto dat. (Cyhelský et al., 1999)

Statistické metody lze rozdělit do dvou širokých kategorií – *deskriptivní* metody a metody *inferenční*. Metody deskriptivní statistiky se skládají z různých technik – jak matematických, tak grafických – pomocí kterých lze organizovat a popisovat data. Manažer by se například mohl zajímat o to, jaký je průměrný výdělek skupiny pracovníků, nebo o to, zda existují značné rozdíly v průměru položek vyrobených ve výrobním cyklu. (Cyhelský et al. 1999)

### 4.1 Metody popisné statistiky

Popisné statistiky mohou být užitečné při popisu určitých charakteristik produktu a procesu. Nejdůležitější popisné statistiky jsou charakteristiky polohy, jako je průměr, charakteristiky variability, jako je směrodatná odchylka či rozptyl, charakteristiky tvaru rozdělení a vztahu mezi procesy či veličinami, jako je lineární korelace. (Cyhelský et al., 1999)

#### 4.1.1 Základní statistické pojmy

Základem je *statistický soubor*, což je konečný soubor určitých dat, která chceme zkoumat. Údaje mohou být do jisté míry obecné. Pokud chceme zkoumat například průměrnou hrubou mzdu v ČR, statistickým souborem zde bude množina všech lidí v ČR. Počet prvků ve statistickém souboru se nazývá *rozsah souboru*. Námi definovaný rozsah statistického souboru by se tak rovnal počtu obyvatel České republiky. (Cyhelský et al., 1999)

Dále definujeme pojem *statistická jednotka*, což je konkrétní prvek statistického souboru. V našem případě by se jednalo o jednu konkrétní osobu. (Kříž et al., 2009)

Důležitým pojmem je *statistický znak*, což je společná vlastnost prvků, kterou chceme měřit. V našem příkladu by statistickým prvkem byl plat. (Kříž et al., 2009)

Statistika může být buď *kvalitativní*, nebo *kvantitativní*. Kvantitativní (množství = množství, počet) znak je znak vyjádřitelný čísly (například plat, výška, počet dětí, ...), kvalitativní znak je pak vyjádřitelný slovně (barva, ano/ne, povolání, ...). (Kříž et al., 2009)

### 4.1.2 Rozdělení četností

Ve statistice je četnost pojem, který udává počet hodnot daného znaku ve statistickém souboru. Četnosti dělíme na absolutní a relativní. (Cyhelský et al., 2009)

*Absolutní četnost* popisuje, kolikrát byla pozorována určitá hodnota daného znaku.

*Relativní četnost* udává, jak často se určitý druh události vyskytuje v rámci celkového počtu pozorování. Je to typ frekvence, který používá procenta, proporce a zlomky. (Cyhelský et al., 2009)

Často se používá četnost v kumulativní podobě, jedná se tedy o *kumulativní četnost*. Četnosti hodnot statistického znaku jsou vzestupně uspořádány a postupně sčítány čili jde o součet četností po sobě jdoucích tříd. (Kříž et al., 2009)

### 4.1.3 Statistické charakteristiky

Porovnávat různé statistické soubory na základě rozdělení četností je značně obtížné, pracné a zdlouhavé. Proto existují charakteristiky, které mohou data s určitou přesností vhodně reprezentovat. (Kožíšek a Stieberová, 2014)

#### Charakteristiky úrovně

Charakteristiky úrovně se reprezentují s různou přesností a vypovídající hodnotou statistický soubor jedním číslem. Často se v publikacích píše, že statistika počítá pro tento účel tzv. střední hodnoty a mezi střední hodnoty patří průměry: *aritmetický průměr*, *geometrický průměr*, *harmonický průměr*, *kvadratický průměr* a ostatní střední hodnoty: *modus*, *medián*. Abychom tohle tvrzení nechápali nesprávně, k tomu, abychom mohli spočítat střední (očekávanou) hodnotu, potřebujeme náhodnou proměnnou a její distribuci. Jestliže počítáme průměr žákových školních známek, nejedná se o střední hodnotu. (Kožíšek a Stieberová, 2014)

#### Charakteristiky variability

Jednou ze základních charakteristik variability je *variační rozpětí*, které značíme  $R$ . Můžeme jej definovat jako rozdíl mezi nejvyšší a nejnižší hodnotou řady (rozdíl mezi nejvyšší a nejnižší hodnotou znaku v souboru). Matematicky jej vyjadřujeme jako: (Kožíšek a Stieberová, 2014)

$$R = x_{max} - x_{min}. \quad (1)$$

Nejde ale o příliš vypovídající charakteristiku, jelikož je ovlivněna extrémními hodnotami a neříká nic o tom, jak se chovají hodnoty uvnitř souboru. Proto se variační rozpětí často

modifikuje tak, že místo minimální a maximální hodnoty počítáme s kvantily, nejčastěji s kvartily, a říkáme, že jde o tzv. *kvartilové rozpětí*  $R_q$ : (Kožíšek a Stieberová, 2014)

$$R_q = x_{0,75} - x_{0,25}. \quad (2)$$

Velkým nedostatkem variačního i kvantilového rozpětí je skutečnost, že nebereme v úvahu všechny hodnoty proměnné. (Kožíšek a Stieberová, 2014)


Další důležitou charakteristikou variability je *rozptyl*, který představuje míru rozptýlení hodnot kolem střední hodnoty. Pakliže budou hodnoty více odchýleny od střední hodnoty, rozptyl bude větší. Pro rozptyl máme dva vzorce v závislosti na tom, jestli jej chceme provádět na výběrovém souboru s tím, že výsledek zobecníme na základní soubor, nebo z celého základního souboru. Pak pro rozptyl základního souboru platí: (Hron et al., 2021)

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2, \quad (3)$$

Pro výběrový rozptyl existuje vzorec: (Hron et al., 2021)

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2. \quad (4)$$

Všimněme si, že sumu ve výběrovém rozptylu dělíme výrazem  $n - 1$ , oproti rozptylu základního souboru, kde dělíme výrazem  $n$ . Těto úpravě se říká *Besselovská korekce*. Tato „oprava“ je provedena s cílem definovat skutečnost, že tyto statistiky vzorku mají tendenci podhodnocovat skutečné parametry nalezené v populaci. Odvození je ale poměrně náročné. U větších souborů  $n > 30$  je rozdíl hodnot obou rozptylů zanedbatelný. Princip rozptylu nejlépe pochopíme z obrázku 4. (Meloun a Militký, 2012)



Obrázek 4: Čtverec odchylek

Zdroj: is.muni.cz

Červená čára představuje průměrné hodnoty, modré body jsou naměřené hodnoty a čtverce znázorní druhé mocniny vzdáleností od hodnot průměrných, tedy  $(y_i - \bar{y})^2$ . Geometricky vzato, u rozptylu sečteme plochy těchto čtverců a vydělíme je jejich počtem. Tím zjistíme průměrnou velikost čtverce, a tedy průměrnou druhou mocninu vzdáleností naměřených hodnot

od průměru / střední hodnoty. Tímto získáme informaci o rozptýlení dat kolem průměru / střední hodnoty. (Meloun a Militký, 2012)

Často se používá charakteristika *směrodatná odchylka*, což není nic jiného než odmocnina z rozptylu, až už základního souboru nebo výběrového rozptylu. Pro rozptyl základního souboru tedy platí: (Hron et al., 2021)

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}. \quad (5)$$

Pro vzájemné srovnávání variability dvou či více souborů se značně odlišnou úrovní hodnot (např. variabilitu váhy křepelk v gramech a skotu v metrických centech) používáme charakteristiku *variální koeficient*. Pro základní a výběrový soubor používáme následující vzorce: (Hron et al., 2021)

$$V = \frac{\sigma \cdot 100}{\mu}, \quad V = \frac{s \cdot 100}{\bar{y}}. \quad (6)$$

Výsledek se obvykle vyjadřuje v procentech.

Mezi často používané relativní míry variability patří *střední chyba průměru* (SEM), kterou spočítáme jako: (Meloun a Militký, 2012)

$$SEM = \frac{\sigma}{\sqrt{n}}. \quad (7)$$

Vzorec plyne ze vztahu rozptylu základního souboru a výběrového rozptylu. Ze vzorce je patrné, že s narůstajícím  $n$ , tedy velikostí souboru, bude SEM menší.

## Charakteristiky tvaru rozdělení

Tyto charakteristiky popisují, jak jsou data rozložena z hlediska četnosti oproti nějakému referenčnímu rozdělení. Uvedeme dvě charakteristiky – míra šikmosti a špičatosti. (Hron et al., 2021)

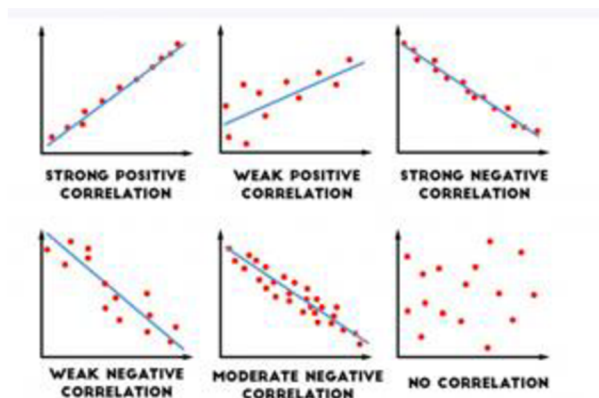
## Korelace

Korelace představuje vzájemný vztah dvou nebo více procesů či veličin. Jestliže se jedna z nich mění, pak se korelativně mění také druhá a opačně. Jestliže korelaci mezi dvěma veličinami identifikujeme, je pravděpodobné, že na sobě závisejí. Nelze usoudit, že by jedna z nich měla být příčinou a druhá následkem. Kauzalitu totiž korelace nedokáže rozhodnout. (Hron et al., 2021)

Korelace vychází ze skalárního součinu, potažmo z odchylek dvou přímek, kdy stejným způsobem charakterizujeme polohu/vztah dvou souborů intervalem  $< -1; 1 >$ , přičemž číslo  $1$  představuje mezi veličinami maximálně kladný vztah a  $-1$  nepřímý vztah neboli



antikorelaci. Pokud je korelace rovna 0, znamená to, že veličiny spolu nemají žádný vztah. Číslu charakterizujícím míru korelace říkáme *korelační koeficient*. Těch je více druhů v závislosti na účelu výpočtu či rozložení dat. Jde například o *Pearsonův korelační koeficient* a *Spearmanův korelační koeficient*. Nejjednodušším případem korelace je *korelace*, kdy zkoumáme, jestli naměřené hodnoty mají vztah s hodnotami na přímce  $y = x$ . Pak můžeme rozlišit různé korelace podle následujícího obrázku (obr. 5). (Hron et al., 2021)



Obrázek 5: Příklady korelace

Zdroj: quizlet.com

V manažerské praxi je možno metody korelace použít ve spoustě odvětví. Můžeme například měřit korelaci finanční výkonnosti a cílů kvality, počátečních investic a provozními náklady nebo výší investice a kontribuce k nastaveným cílům. (Hron et al., 2021)

Nejznámější formulí pro výpočet korelačního koeficientu je: (Hron et al., 2021)

$$r_{xy} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (8)$$

## 4.2 Statistická indukce

V praxi obvykle používáme výběrový statistický soubor k tomu, abychom mohli zkoumat vlastnosti základního souboru (populace). Na základě dat výběrového souboru zevšeobecnujeme úsudek, tedy usuzujeme obecně nad celou populací. Stěžejní úloha statistické indukce je odhad neznámých parametrů/charakteristik základního souboru prostřednictvím údajů, které získáme náhodným výběrem ze základního souboru. Důležitým charakterem statistického odhadu je, že při libovolném úsudku o základním souboru je třeba počítat s možností, že tento je chybný. (Borokov, 2019)

Podle typu rozdělení, kterým se řídí základní soubor je možno na základě dat výběrových souborů z tohoto rozdělení zjistit různé charakteristiky, které se v jistém smyslu blíží

k odpovídajícím charakteristikám základního souboru (průměr, rozptyl, medián,...). Odhadování parametrů základního souboru na základě charakteristik výběrových souborů lze provést v zásadě dvěma metodami: (Borokov, 2019)

1. *Bodový odhad* – neznámý parametr základního souboru odhadujeme pomocí jediného čísla, bodu. Bodovým odhadem parametru základního souboru jsou popisné charakteristiky výběrového souboru.
2. *Intervalový odhad* – neznámý parametr základního souboru odhadujeme pomocí intervalu hodnot, ve kterém se parametr základního souboru nachází s určitou pravděpodobností.

#### 4.2.1 Bodový odhad


Neznámý parametr základního souboru odhadujeme pomocí jediného čísla, bodu. Parametrem základního souboru míníme aritmetický průměr, rozptyl, směrodatnou odchylku. Pro tyto charakteristiky platí, že výběrové charakteristiky jsou *nestranným odhadem* charakteristik základního souboru, což znamená, že očekávaná hodnota se shoduje s hodnotou parametru, který chceme odhadnout. Bodový odhad neposkytuje žádnou informaci o přesnosti a spolehlivosti odhadu hodnoty. Dále se tímto odhadem nebudeme zabývat. (Hron et al., 2021)

#### 4.2.2 Intervalový odhad

Jde o odhad příslušné charakteristiky základního souboru pomocí intervalu. Tento odhad je reprezentován intervalem  $(G_d, G_h)$ , který s danou vysokou pravděpodobností bude obsahovat skutečnou hodnotu odhadované charakteristiky základního souboru. Tato pravděpodobnost se nazývá spolehlivostí odhadu a značí se  $1 - \alpha$ . Interval, jehož dolní a horní meze jsou  $G_d$  respektive  $G_h$ , pak nazýváme *intervalem spolehlivosti* pro charakteristiku  $G$  a platí pro něj obecný vzorec (Cyhelský et al., 1999)

$$P(G_d > G > G_h) = 1 - \alpha. \quad (9)$$


Intervaly spolehlivosti rozlišujeme na oboustranné a jednostranné. U obou z nich se můžeme dopustit chyby pouze v 5 % případů, pokud zvolíme spolehlivost odhadu 0,95. Z tohoto důvodu, pokud jde o oboustranný interval spolehlivosti, budeme muset celkovou přípustnou 5% chybu rozložit na dvě části – levou a pravou. (Cyhelský et al., 1999)



**Obrázek 6: Oboustranný interval spolehlivosti**

Zdroj: základy statistiky, Autoři: Jiří Neubauer, Marek Sedlačík a Oldřich Kříž

Tedy na 2,5 % z jedné a 2,5 % z druhé strany. U jednostranného intervalu spolehlivosti připoustíme tuto chybu pouze z levé anebo pravé strany. (Cyhelský et al., 1999)



**Obrázek 7: Jednostranné intervaly spolehlivosti**

Zdroj: inggeo.fsv.cvut.cz

V případě intervalových odhadů nazýváme tuto chybu jako chybu přípustnou. Naším cílem bude, aby intervalový odhad byl co možná nejvíce spolehlivý a současně co možná nejužší. Tyto dvě vlastnosti jdou ovšem mnohdy proti sobě. Čím spolehlivější bude náš intervalový odhad, tím širší bude muset interval být, a naopak. Nižší šířka intervalu nám bude snižovat přesnost odhadu. Pokud bychom chtěli mít užší a také spolehlivější interval, museli bychom rozšířit výběr o další jednotky. Další důležitá vlastnost, na které bude šířka intervalu spolehlivosti záviset, bude velikost výběrového souboru. Čím více pozorování do našeho výběrového souboru zařadíme, tím užší a přesnější odhad získáme. Na šířku intervalu má vliv ještě jedna vlastnost, a tou je rozptýlenost základního souboru. (Cyhelský et al., 1999, Hron et al., 2021)

Například užší interval spolehlivosti pro průměrnou výšku žáků základní školy získáme, pokud se budeme zajímat pouze o devátáky, jejichž výška je vzhledem k věku ustálená, než pokud budeme počítat interval spolehlivosti pro průměrnou výšku žáků celé základní školy, a to od prvňáků po devátáky. V tomto případě budeme mít v základním souboru hodně 100 cm

měřících prvňáků, ale také několik dvoumetrových devátáků. Z toho jasně vyplývá, že i rozptýlenost základního souboru bude mít vliv na šířku našeho intervalu spolehlivosti, a to tak, že čím větší bude rozptyl základního souboru, tím širší bude interval spolehlivosti. (Cyhelský et al., 1999, Hron et al., 2021)

Důležité vědět, jaké rozdělení parametry a populace mají. Pokud máme populaci s normálním rozdělením, pak výběrový průměr má rozdělení (Anděl, 2011)

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right). \quad (10)$$

Pro normované normální rozdělení dostáváme náhodnou veličinu: (Anděl, 2011)

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1). \quad (11)$$

Z této veličiny dokážeme nyní vytvořit odhad střední hodnoty základního souboru. Když tuto veličinu dosadíme do oboustranného intervalu spolehlivosti, dostaneme (Anděl, 2011)

$$P\left(G_d > \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} > G_h\right) = 1 - \alpha. \quad (12)$$

Hraniční hodnoty  $G_d$  a  $G_h$  jsou kvantily rozdělení. Nyní záleží na tom, kolikaprocentní je interval spolehlivosti. Pokud  $1 - \alpha = 0,95$ , pak  $\alpha/2 = 0,25$  a  $1 - \alpha/2 = 0,75$ , takže jde o kvartily, pak platí: (Anděl, 2011)

$$P\left(u\left(\frac{\alpha}{2}\right) > \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} > u\left(1 - \frac{\alpha}{2}\right)\right) = 1 - \alpha, \quad (13)$$

kde  $u$  představuje kvantil normálního rozdělení. Nyní je třeba pouze vyjádřit střední hodnotu  $\mu$  několika jednoduchými matematickými kroky. Nakonec dostáváme (Anděl, 2011)

$$P\left(\bar{X} - u\left(\frac{\alpha}{2}\right) \cdot \sigma/\sqrt{n} > \mu > \bar{X} + u\left(\frac{\alpha}{2}\right) \cdot \sigma/\sqrt{n}\right) = 1 - \alpha. \quad (14)$$

Tato rovnice odpovídá intervalu spolehlivosti pro parametr  $\mu$  v následujícím tvaru: (Anděl, 2011)

$$\left[\bar{X} - u\left(\frac{\alpha}{2}\right) \cdot \frac{\sigma}{\sqrt{n}}, \bar{X} + u\left(\frac{\alpha}{2}\right) \cdot \frac{\sigma}{\sqrt{n}}\right]. \quad (15)$$

### 4.3 Shluková analýza

Shluková analýza je soubor statistických metod a algoritmů zpracování dat. Funguje tak, že organizuje položky do skupin či shluků na základě podobných vlastností. Organizuje data do shluků tak, že v rámci jednoho shluku mají maximální podobnost, a mimo shluk minimální. (Everitt, 2011)

Cílem shlukové analýzy je najít podobné skupiny subjektů, kde „podobnost“ mezi každou dvojicí subjektů znamená nějakou globální míru přes celý soubor. (Meloun a Militký, 2012)

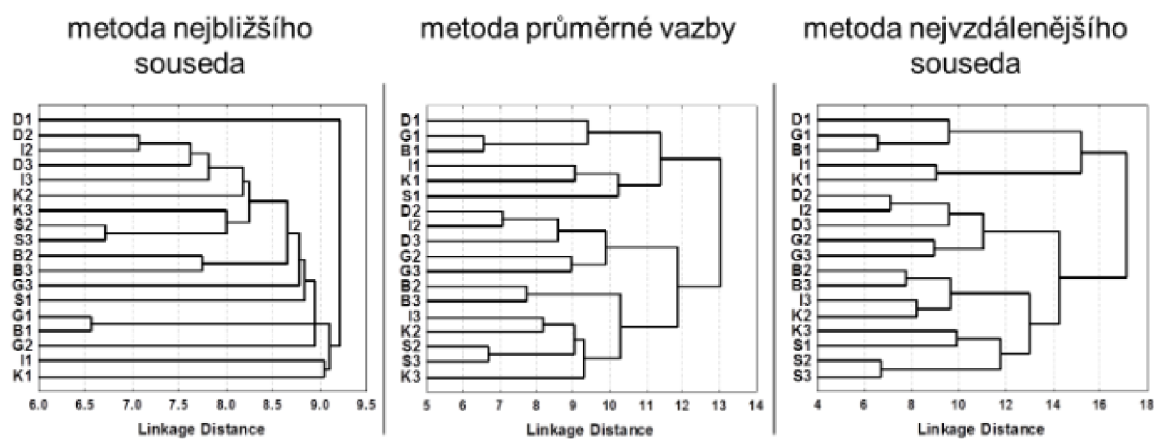
Před spuštěním algoritmu shlukové analýzy nevíme, kolik shluků v datech existuje. Na rozdíl od mnoha jiných statistických metod se shluková analýza obvykle používá, když neexistuje žádný předpoklad o pravděpodobných vztazích v datech. Poskytuje informace o tom, kde v datech existují asociace a vzory, ale ne o tom, jaké mohou být nebo co znamenají.

Algoritmy shlukové analýzy dělíme na hierarchické a nehierarchické. (Meloun a Militký, 2012)

### 4.3.1 Hierarchické metody

Hierarchické shlukování je množina metod shlukové analýzy, které shlukování vykonávají postupným spojováním menších shluků (aglomerativní metody) anebo naopak dělením velkých shluků na menší (divisní metody) podle daných pravidel. Jednotlivé metody používají různé metriky (vzdáleností mezi shluky, mezi body a mezi shluky a body). (Meloun a Militký, 2012)

Hierarchické shlukování touto metodou se obvykle znázorňuje prostřednictvím binárního stromu, *dendrogramu*. Jednotlivé uzly představují shluky. Vodorovné úrovně stromu jsou stupně rozkladů shluků. Svislý směr udává vzdálenost mezi shluky. (Meloun a Militký, 2012)



Obrázek 8: Dendrogram hierarchického shlukování

Zdroj: Meloun a Militký, 2012

Na obrázku 8 je použita metoda aglomerativní, tedy z jednotlivých počátečních hodnot se postupně tvoří shluky tak, až dojde seskupení do jednoho výsledného shluku.

Data a shluky se mezi sebou posuzují podle míry vzdálenosti/podobnosti. Nejčastěji se volí metrika *euklidovská míra*, což je vzdálenost dvou bodů tak, jak ji známe v reálném světě, ale existují i jiné (manhattanská, korelační koeficient, Čebyševova, ...). Posuzujeme vzdálenosti

u všech souřadnic, které objekty mají. Vzdálenost posuzujeme mezi shluky na základě několika metod. Mezi nejznámější patří: (Meloun a Militký, 2012)

- *Metoda nejbližšího souseda* – spojuje objekty, které jsou si nejbliže. U shluků spojí vždy takové, jejichž objekty jsou si nejbliže. Pak vzdálenost dvou různých shluků je určena vzdáleností dvou nejbližších objektů z nich.
- *Metoda nejvzdálenějšího souseda* – vzdálenost shluků je určena vzdáleností dvou nejvzdálenějších objektů v těchto shlucích. Metoda vytváří menší, těsnější, kompaktnější a dobře ohraničené shluky.
- *Centroidní metoda* – tato metoda používá pro třídění objektů euklidovskou vzdálenost těžiště shluku, což je hypotetický objekt mající souřadnice vzniklé průměrem všech souřadnic objektů shluku.

### 4.3.2 Nehierarchické metody

Nehierarchické shlukování zahrnuje vytváření nových shluků sloučením nebo rozdělením shluků. Nesleduje stromovou strukturu jako hierarchické shlukování. Tato technika seskupuje data za účelem maximalizace nebo minimalizace některých hodnotících kritérií. (Everitt, 2012)

Nejznámější metodou je Shlukování *K-means*, které má za cíl přiřadit objekty k uživatelem definovanému počtu shluků ( $k$ ) takovým způsobem, aby se maximalizovalo oddělení těchto shluků a zároveň se minimalizovaly vzdálenosti uvnitř shluku vzhledem k průměru nebo těžišti shluku. Algoritmus je obvykle standardně nastaven na euklidovské vzdálenosti, avšak mnoho implementací může přijmout alternativní kritéria, jako jsou různé vzdálenosti nebo míry odlišnosti. Pokud ne, alternativní vzdálenosti nebo odlišnosti mohou být transformovány tak, aby byly kompatibilní s euklidovským zobrazením. Od uživatele se obvykle očekává, že nastaví 3 parametry: 1) počet očekávaných shluků ( $k$ ), 2) metodu inicializace a 3) použitou metriku vzdálenosti. (Everitt, 2012)

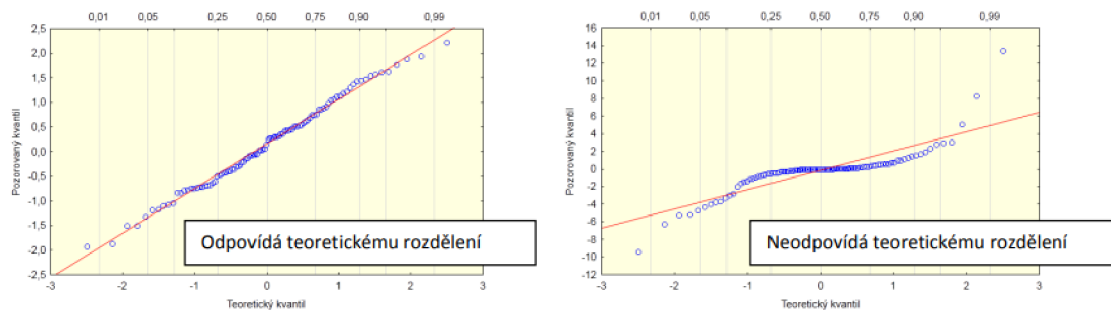
## 4.4 Q-Q graf

Q-Q graf neboli kvantil-kvantilový graf, je grafický nástroj, který nám pomáhá posoudit, zda soubor dat pochází z nějakého teoretického rozdělení, jako je normální nebo exponenciální. Pokud například spustíme statistickou analýzu, která předpokládá, že naše závislá proměnná je normálně rozdělena, můžeme použít graf *Normální Q-Q* ke kontrole tohoto předpokladu. Je to pouze vizuální kontrola, ne přesný důkaz, takže může být tato metoda subjektivní. Umožňuje

nám však na první pohled vidět, zda je náš předpoklad věrohodný. (Frost, 2020, Meloun a Militký, 2012)

Do grafu se vykreslují proti sobě teoretické vůči naměřeným (empirickým) kvantilům (hodnota, pod kterou je určitý procent dat). (Frost, 2020)

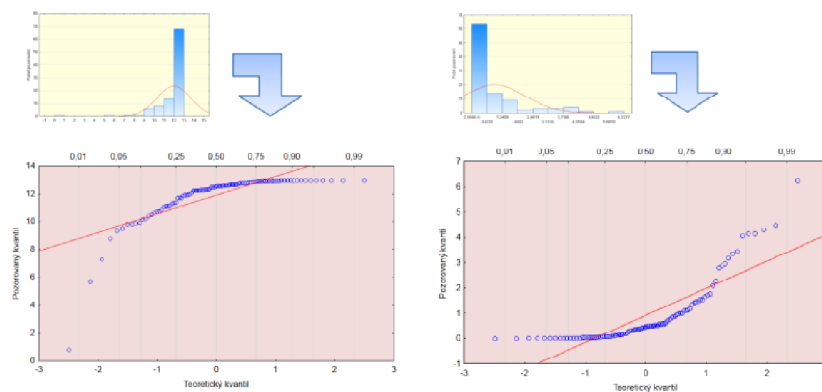
Data musí splňovat v Q-Q grafu rozdělení, které lícuje s přímkou, tedy skutečnost, že kvantily teoretického a empirického rozdělení budou stejné. (Frost, 2020)



Obrázek 9: Odhad rozdělení z Q-Q grafu

Zdroj: statsoft.cz

Podle tvaru dat v Q-Q grafu můžeme určit také, které charakteristiky rozdělení našich dat neodpovídají teoretickému rozdělení. Například, pokud data vykazují tvar paraboly, je rozdělení více zešíkmené. (Frost, 2020)



Obrázek 9: Tvar dat v Q-Q grafu v závislosti na šikmosti

Zdroj: Frost, 2020

## 4.5 Spektrální analýza časových řad

Mnoho časových řad vykazuje periodické chování. Toto periodické chování může být také velmi složité. Spektrální analýza je technika, která nám umožňuje objevit základní periodicity. Abychom mohli provést spektrální analýzu, musíme nejprve transformovat data z časové do frekvenční oblasti. (Venables & Ripley 2002).

Technické detaily spektrální analýzy jdou nad rámec této práce. Klasickým zdrojem je Priestly (1981), nicméně existuje spousta dalších. Stručně řečeno, kovariance časové řady může být reprezentována funkcí známou jako spektrální hustota. Spektrální hustotu lze odhadnout pomocí objektu známého jako periodogram, což je druhá mocnina korelace mezi časovou řadou a sinovými/kosinovými vlnami na různých frekvencích, které tato řada zahrnuje (Venables & Ripley 2002).

Pro velké  $n$  je periodogram pro různé frekvence přibližně nezávislý. Tuto nezávislost lze zlepšit – stejně jako vizuální kvalitu a interpretovatelnost vyhlazením periodogramu pomocí určitého vyhlazovače (což je obecně nějaký druh váženého klouzavého průměru). (Venables & Ripley 2002).



## 5 Manažerské rozhodování ve společnosti Magna Exteriors (Bohemia) s.r.o.

Spousta lidí má zkreslenou představu o manažerské práci a vidí manažery pouze jako revizory nebo komunikační spojku s jinými odděleními. V moderní době IT technologií, kdy podniky konvergují k automatickým nástrojům, je nutné, aby se i manažer dokázal orientovat v některých IT konceptech, moderních nástrojích pro analýzu dat či statistických softwarech. Existuje spousta nástrojů, které jsou manažery využívány, a značně jim usnadňují práci, čímž ji usnadňují i celému oddělení.

V této části se věnujeme především tomu, jak mohou manažeři a jejich pracovní tým analyzovat různé toky dat, efektivitu práce s nimi a na základě statistických nástrojů rozhodnout o realizaci optimalizace a případně jakou konkrétní optimalizaci vytvořit.

### 5.1 Metodika

Nejprve proběhla komunikace mezi některými manažery a klíčovými pracovníky, na základě čehož byly vybrány relevantní problematiky, které jsou analyzovány v této práci. Tyto problematiky byly vybrány hlavně na základě analýzy chyb pomocí aplikace TMetric. Vybraly se plány dodávek, odvolávky od zákazníka, inventarizace majetku, cenové rozdíly. U těchto problematik měříme míru lidské chyby, tzn. kolik chyb se za určité období v daném toku dat generuje, kolik času je třeba strávit nad jejich eliminací, jestli mají některé chyby periodicitu v rámci týdnů, které fáze pracovní doby jsou pro pracovníky úskalím apod.

Měření chyby u každého pracovníka je chápáno jako proces:

1. nalezení a zaznamenání chyb,
2. zjištění počtu chyb,
3. kolik času je věnováno opravě chyb.

Chyba se může distribuovat dál, takže se celý proces opakuje u dalšího pracovníka, který následně s daty pracuje.

Měření lidské chyby provádíme pomocí aplikace TMetric, která dokáže měřit i krátké časové úseky, které zaznamenává a po celém dni poskytne report v grafu a také standardizovanou tabulku, kterou je možno jako soubor .csv otevřít v programu Excel.

Každý pracovník poskytuje jako výstup data, která charakterizují míru lidské chyby v souvislosti s plynulostí nějakého procesu. Následně v grafu porovnáme zatíženost chybou pro jednotlivé kategorie (viz první odstavec kapitoly 6.1) a u nich se provede podrobnější analýza,

opět prostřednictvím TMetric a statistické analýzy v programu MS Excel. Výstupy jsou vizualizovány především grafy v programu MS Excel. V některých případech je zapotřebí analyzovat rozdělení či trend dat a jejich periodicitu. K tomu využíváme statistické metody regresní přímka, klouzavý průměr, periodogram spektrální analýzy časových řad či Q-Q graf.

Na základě těchto statistických metod a nástrojů se rozhodujeme, jestli je podíl lidské chyby relevantní, a vhodný pro nějakou optimalizaci. Pakliže vhodný je, je nutné vytvořit koncept, který bude efektivní, a díky kterému dokážeme danou lidskou chybu eliminovat.

Nechceme koncept realizovat programovým kódem, to je záležitost IT pracovníků, poskytneme pouze relevantní návrh, který je možné realizovat programovým kódem a bude efektivní. To, jestli efektivní skutečně bude, je nutné změřit.

## **5.2 Charakteristika podniku**

Magna Exteriors (Bohemia) s.r.o. je dcera americké společnosti Magna International, která byla založena před 70 lety. V České republice disponuje dvěma závody v Liberci a Nymburku a dvěma modulovými centry v Lipovce a Plazech.

České závody Plastimat, což byl předchůdce Magny, započaly svou činnost výroby plastových dílů v Jablonci nad Nisou v roce 1946 a šlo o podnik, který se specializoval na výrobu plastů. Plastimat byla již od počátku velmi úspěšná firma, která disponovala vlastním know-how. Magna Exteriors (Bohemia) s.r.o. na něj navázala výrobou plastů, potažmo plastových produktů a před 25 lety se začala specializovat na automobilový průmysl. Technologie a výrobní postupy, které používá, jsou v souladu s nejnovějšími trendy v automobilovém průmyslu a každým rokem dochází k inovacím, které Magně zajišťují, aby v ČR mohla být monopolem v tomto odvětví.

I přesto, že firma vyrábí spousty různých automobilových dílů, nejčastěji jde o nárazníky, prahy, blatníky, lemy kol a páté dveře.

### **5.2.1 Technologie podniku**

Základem výroby v Magně je 230 vstřikovacích strojů určených ke konvenčnímu i speciálnímu vstřikování. Jde například o Mucell, GID, 2K či zastřikování kovových zálistků. Dále výrobní proces zahrnuje lakovací linky na vodou ředitelné i ředitelové barvy, montážní linky s laserovými, hydraulickými i pneumatickými děrovacími a ultrazvukovými, vibračními, torzními a hotplate svařovacími přístroji. Magna Exteriors (Bohemia) využívá také robotickou technologii v podobě robotických lepicích linek.

Liberecký závod disponuje jedinečnou technologií ovíjení uzavřeného rámu skelným vláknem a nymburský závod zahrnuje unikátní konstrukci lakovny či štíhlou výrobu bez procesních meziskladů, což značně urychluje výrobu. Velmi přínosným prvkem je pro firmu také řízený sklad na nárazníky.

### 5.3 Podnikatelský cíl

Firma Magna Exteriors (Bohemia) je podnik, který zahrnuje výrobu, nákup a prodej. Vyrábí automobilové plastové díly, převážně exteriérové. Ke zhotovení dílů je zapotřebí nakoupit materiály či komponenty, které firma nakoupí od dodavatele, může jít například o barvy, granuláty na vstřikování, materiály, polotovary, senzory apod. Pro zákazníka Škoda Auto a.s. např. vyrábí nárazníky, ale některé komponenty je potřeba nakoupit, jako výše zmíněné senzory.

Firma Magna Exteriors (Bohemia) se jako jiní dodavatelé snaží se získat zakázku od zákazníka, který bude např. vyrábět novou řadu automobilu a potřebuje si nechat zhotovit nárazníky. V tuto chvíli poskytne firmám, které vyrábějí nárazníky, poptávku. Na tuto poptávku vytvoří výběrové řízení.

Ve chvíli, kdy firma Magna Exteriors (Bohemia) získá novou zakázku, tak začíná *projektová fáze projektu*. Pro firmu je důležité vytvořit koncept, co a jak se bude vyrábět, jaké komponenty se budou nakupovat od dodavatele, logistické toky, cenové nabídky a každé oddělení vytvoří příslušnou dokumentaci. Následně začne výroba neboli SOP (Strat Of Project – začátek sériové výroby). Před zahájení sériové výroby se stanoví také seznam náhradních dílů, které se budou v případě potřeby dodávat v rámci série, ale i po ukončení sériové výroby (EOP –End Of Project).

K náhradním dílům se přistupuje odlišně také při zhotovování. U některých projektů jejich zhotovení rozlišujeme od sériové výroby. Např. nárazníky se v sérii zhotoví kompletně, včetně nalakování a různých perforací kvůli namontování komponentům. Ale náhradní díl se zákazníkovi poskytne bez lakování, bez děrování pro senzory apod. Zákazník si některé úpravy může po ukončení sériové výroby provést sám. Obdobně je to u ostatních dílů.

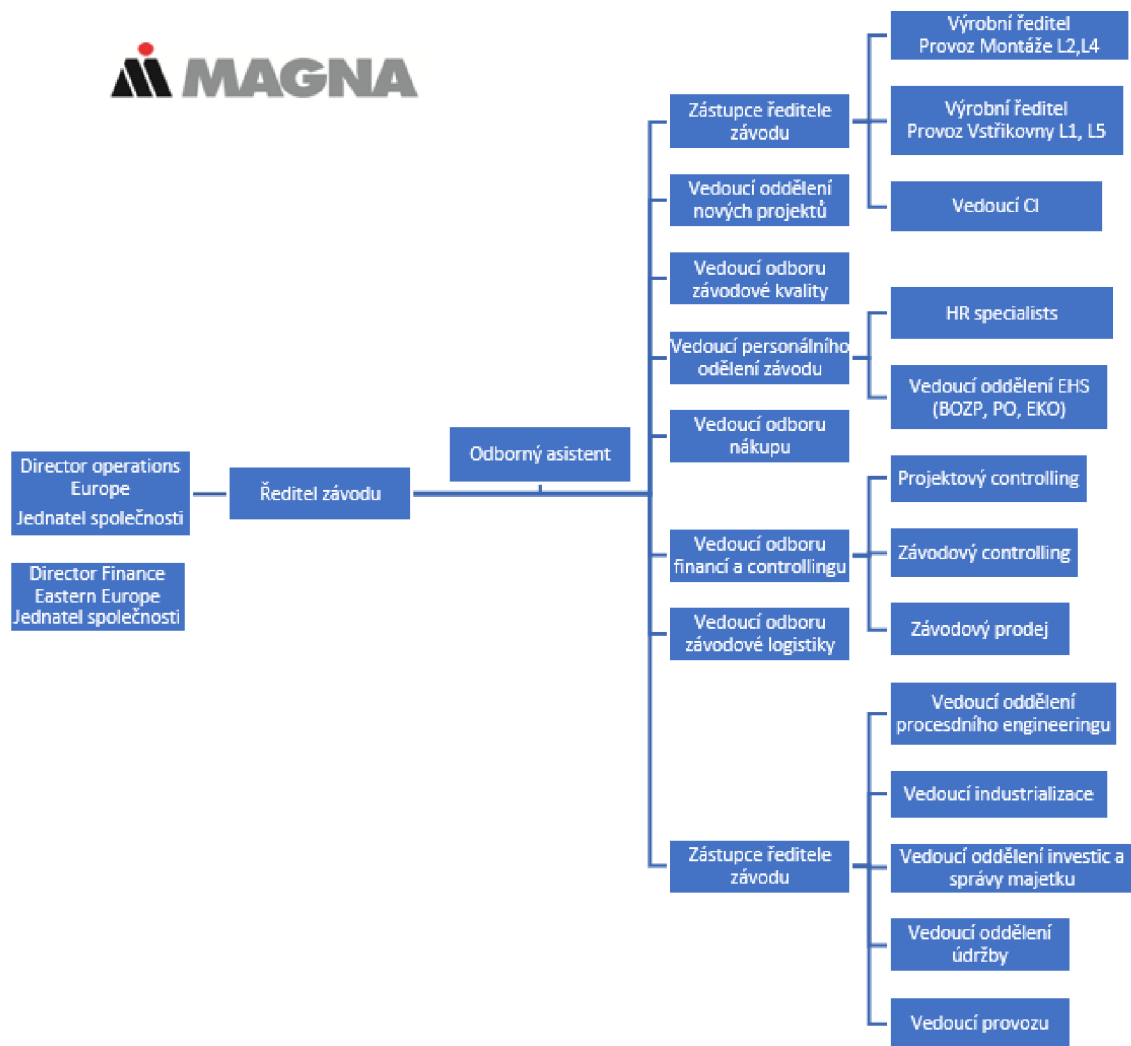
K výrobě dílů je potřeba výrobních linek a dalších různých výrobních zařízení. Magna Exteriors (Bohemia) samozřejmě disponuje vlastními. Nicméně většina zařízení pro výrobu daného projektu je ve vlastnictví zákazníka. Magna Exteriors (Bohemia) je nakoupí, integruje do výroby, ale zákazník je zaplatí.

## 5.4 Zákazníci

Zákazníci Magna Exteriors (Bohemia) jsou velké automobilové společnosti, převážně německé, až na Jaguar. Automobilky nejsou naprosto autonomní společnosti, které disponovali výrobou všech součástí a dílů. Některé díly by samozřejmě dokázaly a mohly vyrábět samy, ovšem často volí variantu dodavatele, a to s různých důvodů – finančních, personálních, organizačních atd. Magna Exteriors (Bohemia) má hned několik stálých zákazníků, přičemž jejich množství se může měnit. Stávající zákazníci jsou:

- Škoda,
- Volkswagen,
- Audi,
- Man,
- Jaguar – Land Rover,
- BMW,
- Mercedes-Benz,
- Seat,

## 5.5 Obecná struktura podniku



Obrázek 11: Struktura podniku (vlastní)

Zdroj: vytvořená struktura výrobního závodu Liberec (konzultováno se zodpovědnou osobou ve společnosti Magna Exteriors (Bohemia) s.r.o.)

## 5.6 Manažerské činnosti

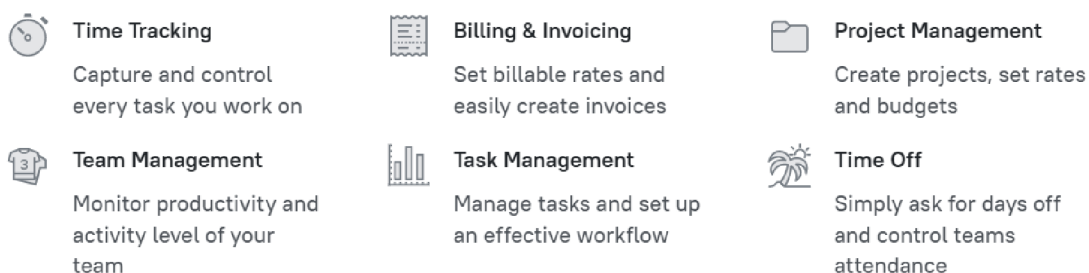
### 5.6.1 Nástroje pro měření lidské chyby

Změřit lidskou chybu a její podíl na efektivitě toku informací/dat je poměrně problematické, proto je třeba podrobně analyzovat tuto problematiku a uvědomit si, ve kterých částech/oblastech podniku opravdu hrozí, že jestli dojde ke zpoždění doručení informace nebo doručení invalidní informace, může to mít nepříznivý vliv na chod podniku.

Lidskou chybu budeme chápat jako omyl, který způsobil člověk, kvůli němuž může dojít k prostojům či modifikaci správných dat, které mohou mít vliv na proces.

K měření vlivu lidské chyby je zapotřebí měřit prostoje v podnikových procesech, potažmo jejich dílčích částech a čas strávený nad opravováním chybných dat. Rozhodli jsme se k tomuto účelu použít aplikaci TMetric, což je chytrá volba pro sledování času, aby pracovníci, týmy i vedení viděli průběh práce a udrželi tým, náklady a kvalitu pod kontrolou. Tato aplikace má spousty funkcí.

### Features



**Obrázek 12: Funkce aplikace TMetric**

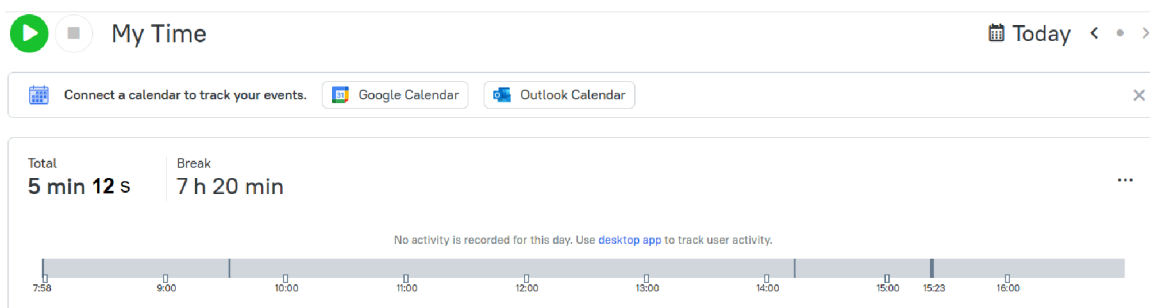
Zdroj: aplikace TMetric

Pro naše účely je nejdůležitější funkcí „Time tracking“ a „Task Management“. Prostřednictvím těchto funkcí jsme schopni analyzovat operace, které provádějí jednotliví účastníci průzkumu, a měřit čas těchto operací. Modul „Task Management“ obsahuje prvky pro vizualizaci dat a work-flow.

K problematice této kapitoly je zapotřebí, aby měli aplikaci nainstalovanou pracovníci, kteří řeší tok relevantních/příslušných dat/informací. Hlavním problémem jsou cenové rozdíly, kde jsme zjistili, že je se lidská chyba projevuje v největší míře, a může se dostat až k zákazníkovi.

Tuto aplikaci mohou mít pracovníci nainstalovanou jak na svém smartphonu, chytrých hodinkách, tabletech, tak i PC či notebookech.

Pracovníci mají v aplikaci svůj profil a zaznamenávají časové okamžiky opravy chyb. Vypadá to následovně.



**Obrázek 10: Záznam opravy chyb**

Zdroj: aplikace TMetric

Zde vidíme, že pracovník čtyřikrát prováděl opravu dat během své pracovní doby, která je uvedena na horizontálním pásu, a to 8:00–16:00. V pásu, který představuje pracovní dobu, jsou

vyznačeny čtyři časové proužky, které značí takou opravnou událost. Tyto události se ukládají v databázi a jsou připraveny pro vizualizaci.

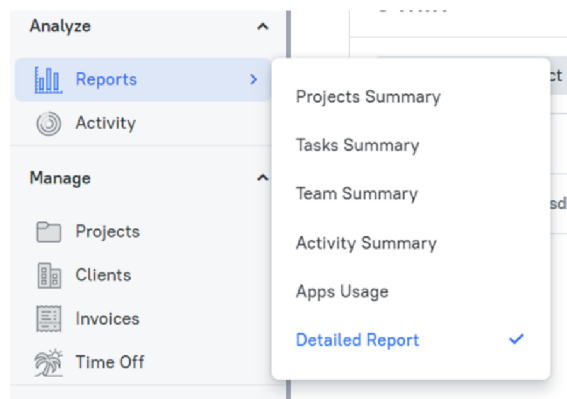
Nad pásem s pracovní dobou je uveden celkový čas, který pracovník strávil opravami. V tomto případě je to 5 min 12 s.

<input type="checkbox"/>	Add Time Entry	Add Break	
<input type="checkbox"/>	chyba1	7:58 - 7:59	1 min 2 s ▶
	Break	7:59 - 9:31	1 h 32 min +
<input type="checkbox"/>	chyba2	9:31 - 9:32	1 min 3 s ▶
	Break	9:32 - 14:13	4 h 41 min +
<input type="checkbox"/>	chyba3	14:13 - 14:14	1 min 4 s ▶
	Break	14:14 - 15:21	1 h 07 min +
<input type="checkbox"/>	chyba4	15:21 - 15:23	2 min 3 s ▶

Obrázek 11: Měření časových úseků v TMetric

Zdroj: aplikace TMetric

Do tabulky výše se události automaticky ukládají, včetně délky jejich trvání. Aplikace poskytuje reporty pracovníků. Každý si může zobrazit vlastní report nebo je možno, aby si vedoucí průzkumu zobrazil report všech pracovníků.



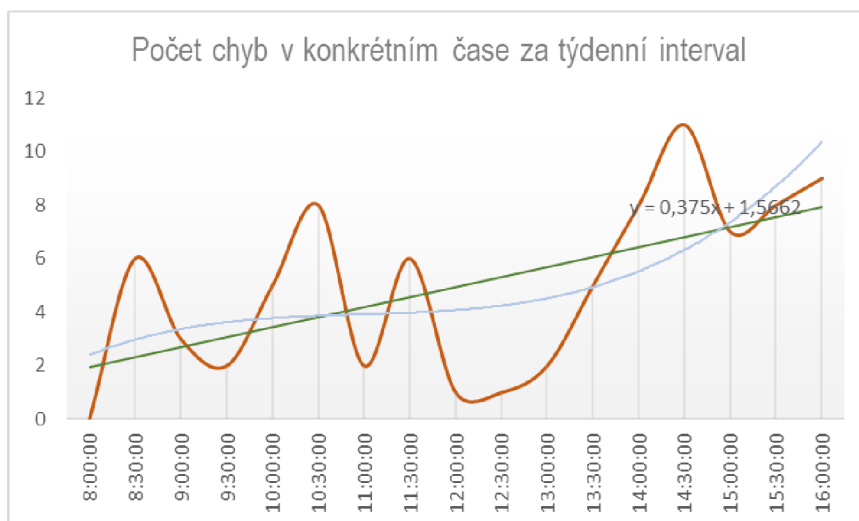
Obrázek 12: Reporty

Zdroj: aplikace TMetric

## 5.6.2 Analýza lidské chyby

Nejprve se podíváme na jednotlivé toky dat/informací a zjistíme, kde je lidská chyba nejvíce znatelná.

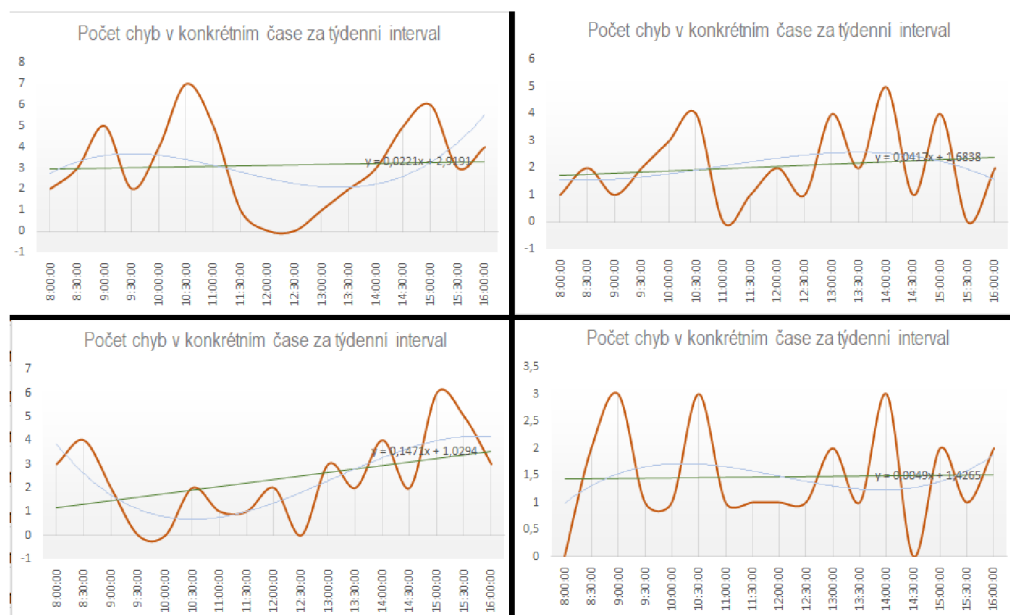
Tok dat/informací v rámci cenových rozdílů podléhá nejvyšší pravděpodobnosti chybovosti. Nejdříve uvedeme graf, který vizualizuje počet chyb v konkrétním čase za týdenní interval.



Obrázek 136: Počet chyb v konkrétním čase za týdenní interval

Zdroj: vlastní zpracování v MS Excel

Všimněme si, že týdenní chybovost má značné výkyvy. Nespolehlivěji vypadá práce kolem poledne, ovšem nepřítomnost chyb bude způsobena spíš tím, že pracovníci kolem oběda neprovádějí transporty dat. Nejvyšší chybovost je v týdenním intervalu od 14:00 do 15:00, což je na konci pracovní doby, kdy je nepozornost pochopitelná. Zajímavostí ovšem je, že chyby jsou přítomny ještě v 16:00, kdy už má dotyčný končit pracovní dobu, ale jde vidět, že některé důležité pracovní záležitosti nechává na konec. Na obr. 19 vidíme grafy počtu chyb ve čtyřech týdnech v rámci měsíce.

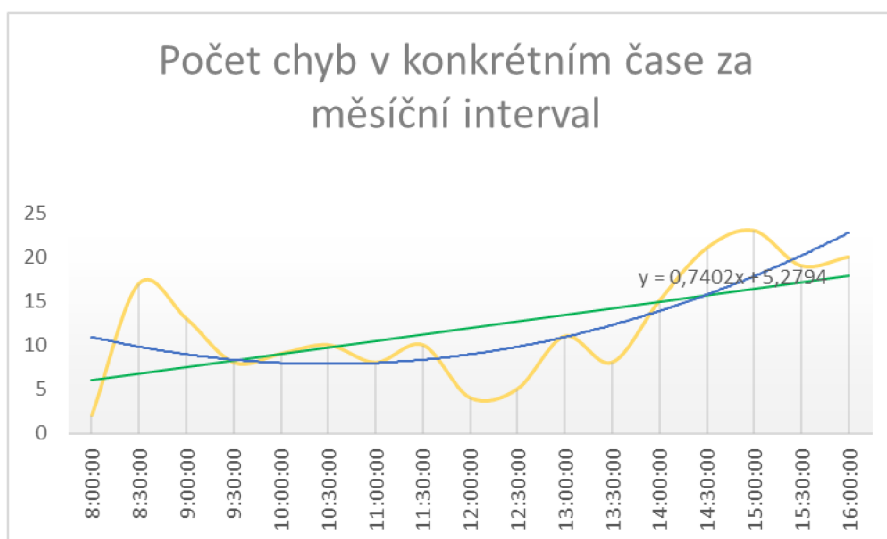


Obrázek 14: Počet chyb ve čtyřech týdnech během jednoho měsíce

Zdroj: vlastní zpracování v MS Excel



Stejný graf máme připraven za měsíční interval.



Obrázek 18: Počet chyb v konkrétním čase za měsíční interval

Zdroj: vlastní zpracování v MS Excel

Měsíční interval má podobný průběh, ale výkyvy nejsou tak značné. Provedeme (lineární) korelaci mezi týdny v měsíci, abychom zjistili, jestli mají signifikantní souvislost/vztah. K tomuto účelu použijeme v Excelu funkci CORREL. Výsledky jsou následující.

	týden 1	týden 2	týden 3	týden 4
týden 1		0,654	0,533	0,439
týden 2	0,654		0,642	0,711
týden 3	0,533	0,642		0,346
týden 4	0,439	0,711	0,346	

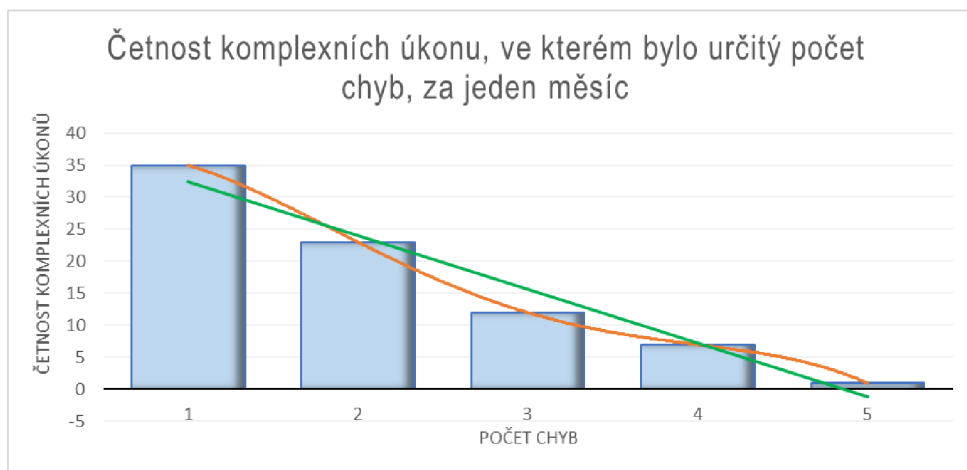
Obrázek 19: Korelace mezi jednotlivými týdny v měsíci

Zdroj: vlastní zpracování v MS Excel

Korelace mají pozitivní závislosti a v některých případech se pohybují kolem 0,6–0,7, což jsou hodnoty s poměrně signifikantním vztahem. Všechny týdny vysokou korelaci nemají, ale ve většině případů jde o data, která můžeme skloňovat vzhledem k závislosti na práci v určitých časových úsecích během dne.

Zcela jistě by šlo z grafů vydedukovat, že v určitých časových úsecích není vhodné provádět některé náročnější úkony, které vyžadují soustředěnost, ovšem některé pracovní úkony jsou nedeterministické a je možné, že bude mnohdy zapotřebí je provádět i před koncem pracovní doby.

Každá informace má v podniku nějaký tok. Zákazník požaduje službu/výrobek, ten je třeba integrovat do systému SAP a dále distribuovat do výrobní sféry. Zjistili jsme, že v průběhu cesty informace přes několik oddělení, mohou nastat i situace, kdy se chyba vygeneruje latentně, či dokonce se jedna chyba opraví, ale v další fázi se vygeneruje jiná. S tímto jevem jsme nepočítali. Operativně jsme vytvořili statistiku počtu chyb v jednotlivých komplexních úkonech, kde má informace nějaký konkrétní tok.

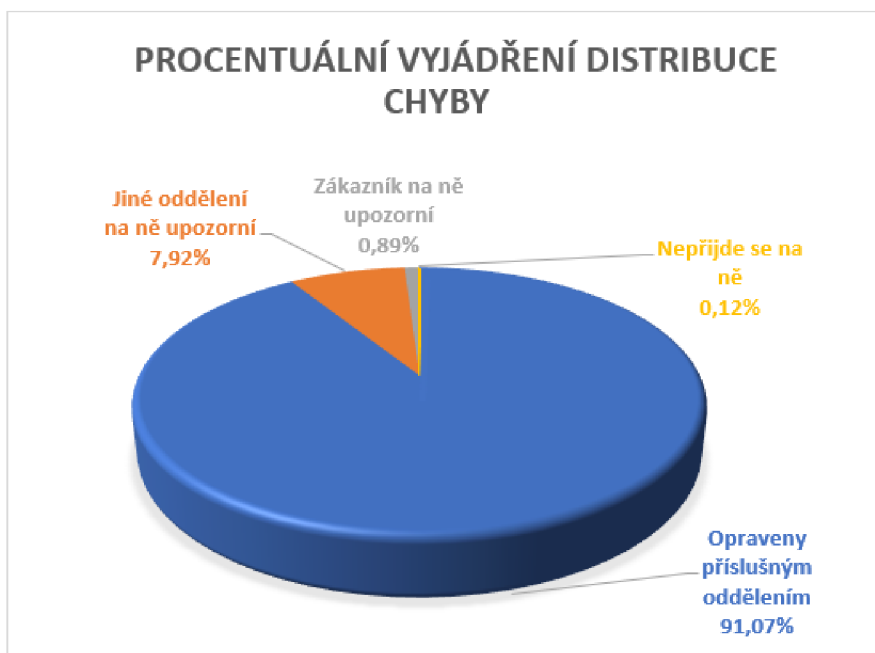


Obrázek 20: Četnost komplexních úkonů, ve kterých bylo určitý počet chyb, za jeden měsíc

Zdroj: vlastní zpracování v MS Excel

Četnosti počtu chyb mají samozřejmě klesající trend, zajímavé je, že počty chyb mají přibližně lineární průběh, tedy rozdíly v četnostech sousedních kategorií jsou zhruba konstantní. Očekávali bychom spíše polynom vyššího stupně.

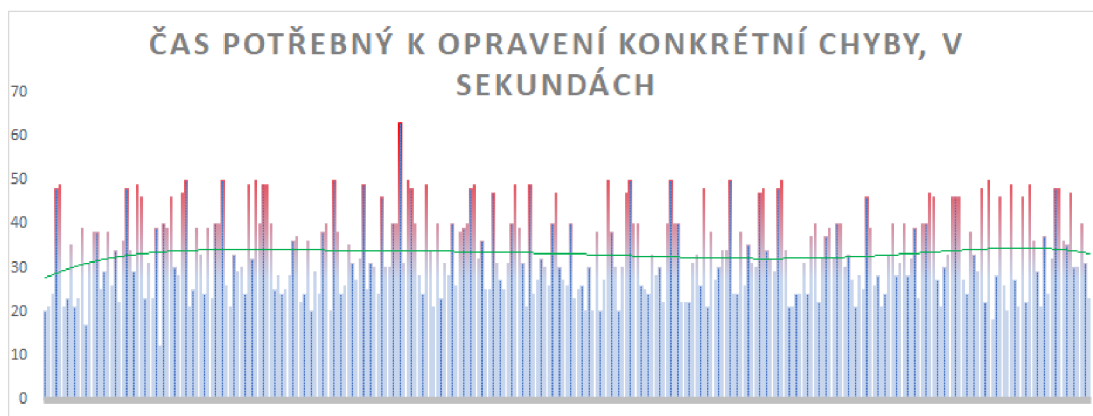
Ovšem pozitivní je, že ačkoli je nenulová pravděpodobnost, že chyba může být v konkrétním toku dat i více, necelých 90 % chyb je opraveno oddělením, které chybná data obdrží bezprostředně po vzniku chyby. Pak 7,92 % opraví jiné oddělení. K zákazníkovi se sice dostane „pouze 0,89 % chyb, nicméně je zapotřebí, aby se toto procento eliminovalo na nulu.



Obrázek 15: Procentuální vyjádření distribuce chyby

Zdroj: vlastní zpracování v MS Excel

Důležitou proměnnou je v této problematice čas. Chyby, které generuje člověk, je samozřejmě třeba odhalit, ovšem eliminace každé chyby vyžaduje určitou časovou režii.



Obrázek 22: Čas potřebný k opravě konkrétní chyby, v sekundách

Zdroj: vlastní zpracování v MS Excel

V grafu na obr. 24 vidíme časy, které byly potřeba k odstranění chyby v určitém časovém úseku, konkrétně za dobu jednoho měsíce. Pokud uvažujeme chyby za sebou chronologicky, jde o časovou řadu, která zahrnuje necelých 5 týdnů. Okem těžko poznáme, jestli je v datech nějaká periodičita. Tuto skrytou periodicitu bychom ovšem mohli zkoumat pomocí nástroje spektrální analýzy, a to periodogramu, který bychom využili na časovou řadu v obrázku 24. Tato problematika ovšem značně přesahuje rámec této práce.

### 5.6.3 Zhodnocení analýzy a návrh intervenčního konceptu

Na základě několika kritérií jsme přišli na to, že jakýkoliv proces, jehož součástí je člověk, zahrnuje nenulovou pravděpodobnost chybovosti. Na základě analýzy v 6.6.2 bychom mohli vyvodit intervenční opatření, které by zahrnovalo optimalizaci činností pracovníků, a to zejména v souvislosti s časovým faktorem, ovšem proměnných, které mohou ovlivňovat práci manažerů, administrativních pracovníků či technologů, je spousta. My jsme se snažili poukázat na to, že chyby jsou přítomny, a částečně analyzovat pracovní dobu pracovníků a zjistit, jestli chybují v konkrétních časových úsecích. To se nám sice podařilo, ovšem nelze tuto problematiku abstrahovat pouze na závislost chyby na konkrétní fázi dne nebo konkrétního dne v týdnu.

V dnešní době by bylo rozhodně optimální, aby důležité procesy, které zahrnují v podniku transport relevantních dat od zákazníka k různým oddělením, nebo naopak, byly v maximální míře automatizovány. Můžeme tím přejít generování chyb, špatné verifikaci dat a také některým pracovníkům ušetřit čas, který je třeba obětovat pro výše zmíněné činnosti.

Ideální je vytvořit automatizovaný nástroj, který by byl maximálně univerzální, a měl přívětivé uživatelské rozhraní, které by v největší míře dokázalo eliminovat pravděpodobnost lidské chyby.

### 5.6.4 Distribuce chyby

Chyba může při práci člověka vzniknout a být opravena jiným pracovníkem, k němuž data směřují. Existuje ale určitá pravděpodobnost, že dotyčný, který má kontrolovat validitu dat a chybu eliminovat, vygeneruje chybu jinou, případně chybu nezachytí a generuje další. Například pokud pracovník má zkontrolovat platnost dat v excelové tabulce, jejich správné kódování, může při opravě kódu výrobku vygenerovat jinou chybu, přičemž chyba v kódu výrobku zůstane.

Každá data mají v podniku nějaký tok. Někdy může jít pouze o zaznamenání dat od zákazníka do SAPu či nějaké pracovní excelovské tabulky, v jiných případech se data distribují přes několik oddělení do výrobní oblasti a zpátky k zákazníkovi ve formě služby/výrobku vytvořené/ho na základě zmíněných dat.

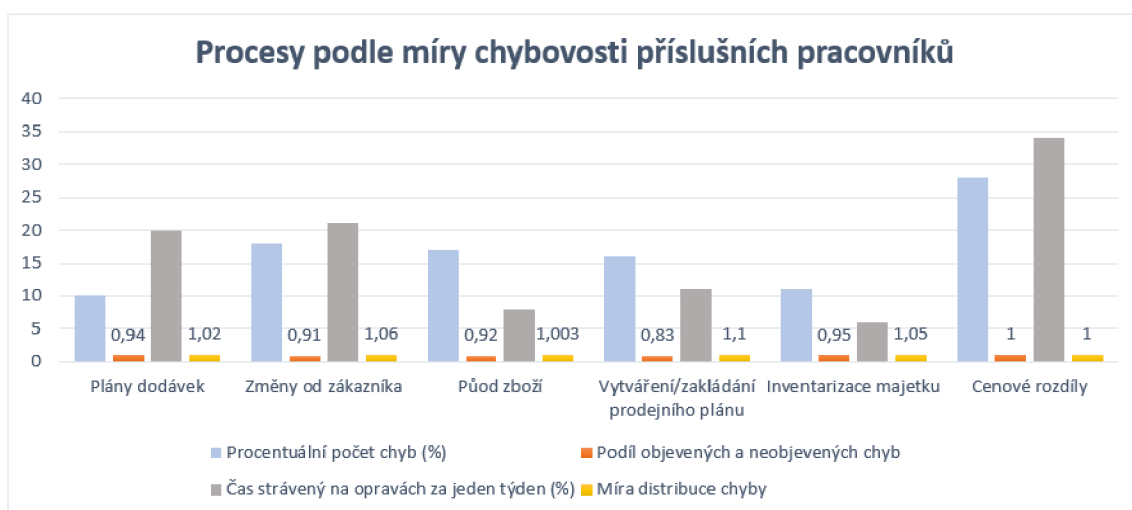
## 5.7 Procesy podniku, které jsou zatíženy lidskou chybou

V této kapitole zmiňujeme, popisujeme a analyzujeme procesy, které se firma rozhodla vybrat jako nejvíce ohroženy chybovostí člověka. Analyzovali jsme pro tyto procesy z pohledu chyb a jejich počtu, podílu objevených a neobjevených chyb, času stráveného na opravách těchto chyb. Zajímavou charakteristikou byla ještě „míra distribuce chyby“, což znamená přes kolik oddělení, kde se chyby mohly opravit, tato chyba prošla.

Analyzované procesy jsou:

- to plány dodávek,
- odvolávky od zákazníka,
- inventarizace majetku,
- cenové rozdíly.

Tyto procesy vizualizujeme sloupcovým grafem (obr. 26).



Obrázek 23: Procesy podle míry chybovosti příslušných pracovníků

Zdroj: vlastní zpracování v MS Excel

Cenové rozdíly jsou nejvíce zatíženy chybovostí. Je to tím, že máme velké množství dat, tím je myšleno počet dílů a k nim jednotlivé ceny. Prodejní ceny jsou následně zadány do SAPu. Ale i tahle krátká cesta je poměrně často chybová a může vést k velkým cenovým rozdílům.

## 5.8 Úskalí podniku a jejich možná řešení

### 5.8.1 Historie chyb

Firma může s přehledem fungovat na systému, který je tvořen excelovskými soubory. Excel je poměrně robustní systém s vývojovým prostředím, ve kterém lze pracovat prostřednictvím nepatrně upraveného programovacího jazyka Visual Basic pro excel, s názvem Visual Basic for Applications. Dokážeme zde programovat formulářové prvky a složité operace, pomocí kterých lze automatizovat různé činnosti.

Jednou z důležitých funkcí této aplikace je tvorba protokolu o činnosti v daném souboru. Tento protokol se ukládá do tzv. logovacích souborů, což jsou často textové soubory s koncovkou *.log*. Tyto soubory mohou pomoci odhalit chyby v různých transakcích a modifikacích dat v souborech CSV či obecných excelovských souborech. Pokud několik pracovníků sdílí soubor a upravují jej, zdá se být složité dohledat, který z nich a v jakém čase udělal chybou operaci, ovšem pokud si před prací vytvoříme logovací soubor pro tento excelovský soubor, dokážeme pomocí něj dohledat, v jakém čase u jakého uživatele došlo ke konkrétní operaci, tedy i chybě.

IT oddělení by mělo být schopno takový soubor vytvořit. Nejde o nic složitého, pouze o krátký skript ve vývojáři v excelovském souboru.

Skripty lze samozřejmě různě upravovat a přidávat funkce podle toho, v jakém formátu chceme protokol mít.

Po vytvoření tohoto skriptu a jeho spuštění se automaticky po uložení logovací soubor vytvoří ve stejné složce, jako je náš pracovní excelovský soubor. Od této chvíle zaznamenává všechny operace s daty a jednotlivými uživateli, které jsou uvedeny chronologicky za sebou.

### 5.8.2 Rozdíly cen

Mezi cenami, které jsou nastaveny v systému, a cenami, které mají skutečně platit pro zákazníka může být rozdíl, který je třeba narovnat. Tohle ovšem není předpovídatelé. Rozdíl může být jak ve prospěch Magny, tak i zákazníka. Z tohoto důvodu je vždy nutné mít optimální finanční rezervu. Pokud se ovšem podrobněji podíváme na zákaznické i systémové ceny, zjistíme, že existuje několik faktorů, které mohou velikost rezervy ovlivňovat. Totiž jak na straně Magny, tak i zákazníka, může docházet k nesprávně či pozdě zadaným údajům, což ovlivní okamžitý tok finančních prostředků, ať už směrem do Magny nebo naopak. Takže lidský faktor má určitý podíl na tom, kolik v danou chvíli zákazník zaplatí.

### 5.8.3 Kódování v projektech

Každý projekt má svůj ceník, který obsahuje několik dílčích ceníků, např. ceník pro zadní nárazník, přední nárazník, plus ceníky pro nějaké deriváty modelů automobilů (RS, Scout, ...). Ceníky jsou excelovské tabulky. Každý projekt má hlavní tabulku s názvem *Přehled*, která poskytuje informace o soupisu potřebných dílů.

5	<b>SK381 NZ KH Basis</b>		
6	LAW 1	<b>L5E000221A</b>	NZ BASIS
7	LAW 2	<b>L5E000222A</b>	NZ BASIS - frontové
8	LAW 3	<b>L5E000223B / 223M</b>	soustava PDC - Bosch a Valeo
9	LAW 3	<b>L5E000223B 9B9</b>	soustava PDC - IP - nelektronické senzory - pro batyru Schwabe - magnet a Sennheiser - systém
10	LAW 4	<b>L5E000224B</b>	soustava PDC - montáž
11	LAW 7	<b>L5E000223C</b>	soustava PUA
12	LAW 7	<b>L5E000223C 9B9</b>	soustava PUA - IP - nelektronické senzory - pro batyru Schwabe - magnet a Sennheiser - systém
13	LAW 9	<b>L5E000224C</b>	soustava PDC PUA - montáž
14	LAW 10	<b>L5E000250</b>	soustava MZ - 2.0
15	LAW 11	<b>L5E000228</b>	soustava VHP 2.0 - montáž
16	LAW 12	<b>5E6 807 417 XXX</b>	krytí NZ - bílý
17	LAW 13	<b>5E7 807 441</b>	krytka vnitřního oto
18	LAW 14	<b>5E6 971 104</b>	AD KABELOVÝ SVAZEK PDC
19	LAW 15	<b>5E6 971 104 A</b>	AD KABELOVÝ SVAZEK PDC + PUA
20	LAW 16	<b>5E6 971 104 E</b>	AD KABELOVÝ SVAZEK PDC + VP
21	LAW 17	<b>5E6 971 104 F</b>	AD KABELOVÝ SVAZEK PUA + VP

Obrázek 24: Výstřižek z tabulky *Přehled*

Zdroj: Magna

Jednotlivé položky v řádcích představují díly, které jsou v projektu použity. Může jít, jak již bylo řečeno, např. o nárazníky. Druhý sloupec v tabulce (tučně) představuje označení materiálu zákazníka. Každý zákazník má své specifické označení dílů. Tento kód má určitý formát. V závislosti na modifikaci tohoto kódu poznáme, o jakou variantu dílu jde. Např. kód 5E6 807 417 XXX představuje kód nárazníku, nespecifikované barvy – XXX znamená, že barva zde musí být dosazena. Jak vidíme ve zmíněném sloupci (obr. 24), kódy mají různé formáty. Některé obsahují mezery, jiné nikoli. Pracovník, který data kóduje v SAPu, potřebuje, aby měly díly správná označení. Pokud k němu dojdou data s chybou, musí je opravit. Vzhledem k variabilitě označení dílů je tento systém poměrně neefektivní a náchylný k chybám.

## Řešení

Pokud neproběhne upgrade systému kódování dílů na plnou automatizaci a pracovníci budou dále pracovat s excelovskými tabulkami, měl by se tento systém změnit tak, aby se upravilo uživatelské prostředí a bylo přívětivější jak pro zákazníka, tak i pro jednotlivé pracovníky, kteří s daty pracují, tzn., že by měla excelovská tabulka disponovat formulářovými prvky, pomocí kterých si může zákazník definovat libovolné díly a jejich varianty provedení. Data jsou pak skutečně ukládána v jiném listu. V SAPu lze naprogramovat různým způsobem funkcionalitu, pomocí které je možno importovat data z excelu přímo do něj. Kdyby byl excelovský dokument umístěn na cloudové úložiště, ke kterému má přístup jak zákazník, tak i pracovníci, pak by stačilo, aby obsluha SAPu provedla jednu triviální činnost, a to importovala CSV soubor do SAPu. Funkcionalita by musela ale obsahovat verifikaci dat, které jsou do SAPu ukládány.

### 5.8.4 Nastavení jobu

Výhodným se jeví nastavení jobu tak, aby jedenkrát týdně uzavřel k zákazníkovi prodejní plány, které mají status materiálu 99, což je zablokovaný materiál. Tímto se značně usnadňuje práce a chybovost se eliminuje, jelikož již není možné, aby zákazník obnovil požadavek na díl, který by se již neměl dodávat.

### 5.8.5 Inventarizace majetku

IT oddělení již pracuje na optimalizaci inventarizace majetku na základě požadavků firmy. Dřív byl tento proces řešen v excelovských tabulkách, což znamenalo značný prostor pro chybovost, nedostatečnou evidenci změn a autora změn. V rámci optimalizace funguje schvalování majetku, zamítnutí určitého majetku z důvodu nerealizovatelnosti daného zařízení či fotodokumentace.

### 5.8.6 Odvolávky

Pokud zákazník pošle odvolávku, která zahrnuje jiné složiště, než je nastaveno v plánu dodávek, mohla by existovat transakce, která by zjistila chybu, respektive změnu, a tu by provedla v prodejním plánu a následně by zaintegrovala odvolávku. Nicméně tato transakce ještě neexistuje, ale je to myšlenka, která by se mohla realizovat do budoucna.



## 6 Závěr

V této práci byla zkoumána pravděpodobnost lidské chyby. Zjistili jsme, že je přítomna všude, kde člověk manipuluje s daty. Těchto chyb se nelze vyhnout, jelikož jsou kauzální na určitých částech pracovní doby. Zjistili jsme totiž, že nejvíce pracovníci chybují kolem 15:00–16:00, kdy mohou být unaveni po celém pracovním dni. Vyšetřili jsme oblasti, kde se může chyba nejčastěji objevovat, a vytvořili pro ně optimalizace. Některé optimalizace byly navrhnuty jako koncept, jiné důkladněji zpracovány programovým návrhem. Firmy podobného charakteru by se měly co nejvíce snažit ctít koncept Průmyslu 4.0 a snažit se o automatizaci ve všech oblastech, aby nemohlo docházet k nežádoucím modifikacím, a tak tak byl co nejrychlejší.

## 7 Použité zdroje

ANDĚL, Jiří. *Základy matematické statistiky*. Vyd. 3. Praha: Matfyzpress, 2011. ISBN isbn978-80-7378-162-0.

EVERITT, Brian. *Cluster analysis*. 5th ed. Chichester: Wiley, 2011. Wiley series in probability and statistics. ISBN 978-0470749913.

HRON, Karel, Pavla KUNDEROVÁ a Ondřej VENCÁLEK. *Základy počtu pravděpodobnosti a metod matematické statistiky*. 4. doplněné vydání. Olomouc: Univerzita Palackého v Olomouci, Přírodovědecká fakulta, 2021. ISBN isbn978-80-244-5990-5.

HRŮZOVÁ, Helena. *Manažerské rozhodování*. 3. aktualizované vydání. Praha: Vysoká škola ekonomie a managementu, 2011. ISBN isbn978-80-86730-74-5.

BOROKOV, A.A. (2019). *Mathematical Statistics* (1st ed.). Routledge. <https://doi.org/10.1201/9780203749326>

CYHELSKÝ, Lubomír, Jana KAHOUNOVÁ a Richard HINDLS. *Elementární statistická analýza*. Vyd. 2., dopl. Praha: Management Press, 1999. ISBN ISBN80-7261-003-1.

KŘÍŽ, Oldřich, Jiří NEUBAUER a Marek SEDLAČÍK. *Popisná statistika a výběrová šetření: učební text pro distanční studium*. Brno: Univerzita obrany, 2009. ISBN isbn978-80-7231-707-3.

NEUBAUER, Jiří, Marek SEDLAČÍK a Oldřich KŘÍŽ. *Základy statistiky: aplikace v technických a ekonomických oborech*. 2., rozšířené vydání. Praha: Grada, 2016. ISBN isbn978-80-247-5786-5.

inggeo.fsv.cvut.cz. 2016. Ing Geo - portál inženýrské geodézie. [cit. 2016-06-01]. Dostupné z :[https://inggeo.fsv.cvut.cz/wiki/doku.php?id=04\\_teorie\\_chyb:0405\\_intervalove\\_odhad](https://inggeo.fsv.cvut.cz/wiki/doku.php?id=04_teorie_chyb:0405_intervalove_odhad)

MELOUN, Milan a Jiří MILITKÝ. *Kompendium statistického zpracování dat*. Praha: Karolinum, 2012. ISBN isbn978-80-246-2196-8. SVOZILOVÁ,

Svozilová, A. (2011). *Zlepšování podnikových procesů*. Grada.

Howard, R. M. (2002). *Principles of random signal analysis and low noise design: the power spectral density and its applications*. John Wiley.

TADDY, Matt. *Business Data Science: Combining Machine Learning and economics to optimize, automate, and accelerate business decisions*. New York ... etc.: McGraw Hill, 2019.

is.muni.cz. 2016. Statistika a pravděpodobnost. Dostupné z  
:https://is.muni.cz/do/rect/el/estud/prif/ps15/statistika/web/pages/regres-anal.html

VEBER, Jaromír. *Management: základy, moderní manažerské přístupy, výkonnost a prosperita*. 2., aktualiz. vyd. Praha: Management Press, 2009. ISBN 978-80-7261-200-0.

statsoft.cz Jak se pozná normalita pomocí grafů. Dostupné z:  
http://www.statsoft.cz/file1/PDF/newsletter/2013\_10\_09\_StatSoft\_Jak\_se\_pozna\_normalita\_pomoci\_grafu.pdf

Venables, W. N., & Ripley, B. D. (2002). *Modern Applied Statistics with S-plus*. Springer-Verlag.

PROQUEST, 2022. Databáze článků ProQuest [online]. Ann Arbor, MI, USA: ProQuest. [cit. 2022-09-30]. Dostupné z: <http://knihovna.tul.cz/>.

YAYICI, Emrah. *Business analysis methodology book*. B.m.: Emrah Yayici, 2015.