



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV INFORMATIKY

INSTITUTE OF INFORMATICS

OPTIMALIZACE PODNIKOVÝCH PROCESŮ POMOCÍ NÁSTROJŮ BUSINESS INTELLIGENCE

OPTIMIZATION OF BUSINESS PROCESSES USING BUSINESS INTELLIGENCE TOOLS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Erika Žáčiková

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Kříž, Ph.D.

BRNO 2024

Zadání bakalářské práce

Ústav:	Ústav informatiky
Studentka:	Erika Žáčiková
Vedoucí práce:	Ing. Jiří Kříž, Ph.D.
Akademický rok:	2023/24
Studijní program:	Manažerská informatika

Garant studijního programu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává bakalářskou práci s názvem:

Optimalizace podnikových procesů pomocí nástrojů Business Intelligence

Charakteristika problematiky úkolu:

Úvod
Cíle práce, metody a postupy zpracování
Teoretická východiska práce
Analýza současného stavu
Vlastní návrhy řešení
Závěr
Seznam použité literatury
Přílohy

Cíle, kterých má být dosaženo:

Cílem práce je využití nástrojů Business Intelligence pro analýzu různých aspektů organizačních procesů pro zvýšení kvality rozhodovacích procesů.

Základní literární prameny:

NOVOTNÝ, Ota, Jan POUR a David SLÁNSKÝ. Business intelligence: jak využít bohatství ve vašich datech. Praha: Grada, 2005, 254 s. ISBN 80-247-1094-3.

POUR, Jan; MARYŠKA, Miloš a NOVOTNÝ, Ota. Business intelligence v podnikové praxi. Praha: Professional Publishing, 2012. ISBN 978-80-7431-065-2.

PROVOST, Foster a FAWCETT, Tom. Data science for business: what you need to know about data mining and data-analytic thinking. Sebastopol: O'Reilly, 2013. ISBN 978-1-449-36132-7.

ŘEPA, Václav. Podnikové procesy: procesní řízení a modelování. 2., aktualiz. a rozš. vyd. Praha: Grada, 2007. Management v informační společnosti. ISBN 978-80-247-2252-8.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2023/24

V Brně dne 4.2.2024

L. S.

Ing. Jiří Kříž, Ph.D.
garant

doc. Ing. Vojtěch Bartoš, Ph.D.
děkan

Abstrakt

Závěrečná práce sa zaoberá optimalizáciou podnikových procesov a poskytnutím kvalitného podkladu pre manažérske rozhodovanie, ktoré samo o sebe predstavuje proces. V neskorších kapitolách predstavuje koncept Process Mining a v praktickej časti aj aplikáciu získaných poznatkov o procesnom dolovaní na podnikový proces Purchase to Pay. Cieľom tohto riešenia je odhalenie slabých článkov v procesnom toku, identifikácia deviácií od referenčného procesného modelu a získanie poznatkov o reálnom procesnom výkone. Na základe týchto poznatkov sú navrhnuté aspekty, ktoré je možné optimalizovať.

Klíčová slova

Data Science, Process Science, Data Mining, Process Mining, Business Intelligence, Business Process Management

Abstract

The final thesis deals with the optimization of business processes and the provision of a quality basis for managerial decision-making, which in itself represents a process. In later chapters, he presents the concept of Process Mining and, in the practical part, the application of acquired knowledge about process mining to the Purchase to Pay business process. The goal of this solution is to reveal weak links in the process flow, identify deviations from the reference process model and gain knowledge about real process performance. Based on this knowledge, aspects that can be optimized are proposed.

Keywords

Data Science, Process Science, Data Mining, Process Mining, Business Intelligence, Business Process Management

Bibliografická citace

ŽÁČIKOVÁ, Erika. *Optimalizace podnikových procesů pomocí nástrojů Business Intelligence* [online]. Brno, 2024 [cit. 2024-05-12]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/160732>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav informatiky. Vedoucí práce Ing. Jiří Kříž, Ph.D.

Čestné prohlášení

Prohlašuji, že předložená bakalářská práce je původní a zpracovala jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušila autorská práva (ve smyslu zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně dne 12. 5. 2024

Erika Žáčiková

autor

Pod'akovanie

Chcela by som vyjadriť svoju úprimnú vďaku vedúcemu práce Ing. Jiřímu Křížovi Ph.D. za jeho cenné usmernenia, odborné rady a trpezlivosť počas celej prípravy tejto bakalárskej práce.

OBSAH

ÚVOD	11
CIELE PRÁCE	12
1. TEORETICKÉ VÝCHODISKÁ.....	13
1.1 Data Science	13
1.2 Dáta.....	15
1.2.1 Štruktúrované dáta.....	15
1.2.2 Neštruktúrované dáta	15
1.3 Big data.....	16
1.4 Databáza.....	16
1.4.1 Relačná databáza	16
1.4.2 OLAP (Online Analytical Processing).....	17
1.4.3 OLTP (Online Transactional Processing).....	17
1.4.4 Systém riadenia bázy dát (DBMS).....	17
1.5 Dátový sklad	18
1.6 Proces ETL	19
1.7 Dátové trhy.....	19
1.8 Data mining.....	20
1.8.1 Metódy Data Miningu.....	20
1.9 Machine learning.....	22
1.10 Process Science.....	23
1.10.1 Proces	24
1.10.2 Obchodný proces	24
1.10.3 Základné členenie procesov.....	24
1.11 Business process management (BPM)	25
1.11.1 Návrh procesu	25

1.11.2	Životný cyklus BPM	26
1.11.3	Root cause analysis (RCA).....	27
1.12	Význam Process Miningu.....	28
1.12.1	Process Mining - definícia	28
1.12.2	Typy Process Miningu.....	29
1.12.3	Procesné modely.....	30
1.12.4	Zdrojové dáta.....	31
1.12.5	XES (Extensible Event Stream) formát	32
1.13	Business Intelligence.....	32
1.13.1	Vizualizácia a interpretácia.....	32
1.13.2	Microsoft Power BI.....	32
1.13.3	Celonis	33
2.	ANALÝZA SÚČASNÉHO STAVU	34
2.1	Organizačná štruktúra	34
2.2	Podnikový informačný systém	35
2.3	Súčasný stav Business Intelligence	35
2.4	P2P proces vo firme	35
2.5	Zhodnotenie súčasného stavu	36
3.	VLASTNÝ NÁVRH RIEŠENIA.....	37
3.1	Zdrojové dáta a ich úprava	37
3.2	Analýza a vizualizácie v prostredí Power BI.....	38
3.2.1	Zhodnotenie	44
3.3	Process mining.....	45
3.3.1	Zdrojové dáta a ich spracovanie.....	45
3.3.2	Skúmanie a filtrovanie dát	46
3.3.3	Analýza a vizualizácie v prostredí Celonis	47

3.3.4 Zhodnotenie	53
ZÁVER	54
ZOZNAM POUŽITEJ LITERATÚRY	55
ZOZNAM OBRÁZKOV	58

ÚVOD

V dnešnej dobe zahltenej dátami si výkonný management nemôže dovoliť ľahostajnosť voči novodobým riešeniam zameraným na optimalizáciu podnikových procesov pomocou rôznych nástrojov. Data-driven prístup je kľúčom úspechu pre mnoho spoločností a tým najpokročilejším poskytuje konkurenčnú výhodu, keďže prináša kvalitný podklad pre optimalizáciu rozhodovacích procesov.

Teoretická časť práce poskytuje základné definície a poznatky potrebné na porozumenie preberanej problematiky. Delí sa na 3 základné kapitoly a to Data Science, Process Science a Business Intelligence. V kapitolách Data a Process Science sa úvodom rozoberajú elementárne prvky týchto interdisciplinárnych odborov, ktoré sa postupne rozvetvujú na obsiahlejšie koncepty a subdisciplíny. Kapitola Business Intelligence sa zameriava najmä na koncept interpretácie, získavania poznatkov z dát, vizualizácie a podporu manažérskeho rozhodovania.

V praktickej časti je predstavená maloobchodná spoločnosť a jej súčasný stav využívania nástrojov Business Intelligence. Zistené nedostatky prechádzajú analýzou a v závere je načrtnuté možné riešenie problémových oblastí.

CIELE PRÁCE

Cieľom práce je využitie nástrojov Business Intelligence pre analýzu rôznych aspektov organizačných procesov pre zvýšenie kvality rozhodovacích procesov.

Záverečná práca sa zaoberá optimalizáciou podnikových procesov prostredníctvom strategického integrovania nástrojov Business Intelligence. Výskum sa sústreďuje na využitie nástrojov BI na analýzu a zlepšenie rôznych aspektov organizačných procesov s konečným cieľom pozdvihnúť kvalitu rozhodovacích procesov. Jej cieľom je na základe analýzy súčasného stavu maloobchodného podniku, najmä jeho súčasného využívania nástrojov Business Intelligence, identifikovať nedostatky a navrhnúť riešenie, ktoré poskytne podrobnejší pohľad na podnikové procesy a možnosti ich optimalizácie.

1. TEORETICKÉ VÝCHODISKÁ

V úvode tejto kapitoly budú definované základné stavebné prvky oblasti Data Science a predstavené niektoré z vybraných subdisciplín. Nasledujúca kapitola bude zameraná na oblasť Process Science a jej subdisciplíny. V závere sa práca zameriava na Business Intelligence a jej nástroje.

1.1 Data Science

Dáta zohrávajú v dnešnom svete úlohu dôležitého zdroja, ktorý umožňuje organizáciám získavať cenné informácie a poznatky využiteľné na lepšie porozumenie obchodného výkonu, zákazníckych segmentov, zlepšenie produktov a služieb a posilnenie konkurencieschopnosti na trhu. Fundamentálnu súčasť tohto data-driven prístupu tvorí Data science, ktorá poskytuje nástroje a metódy pre skúmanie a analýzu dát, kým data-driven prístup pretavuje tieto poznatky do konkrétnych akcií a stratégií.

Data science je interdisciplinárna oblasť, ktorej cieľom je premeniť dáta na skutočnú hodnotu. Tento cieľ je dosiahnutý pomocou zbierania, ukladania a spracúvania dát za účelom vyvodenia dôležitých poznatkov o skúmanom probléme alebo fenoméne. Dáta môžu mať rôzne štruktúry, veľkosť, formáty, môžu byť nekonzistentné, nekompletné či nesprávne. Jednoducho rôznorodé. Ich hodnota môže byť vyvodená vo forme predikcií, automatizovaného rozhodovania, dátových modelov, či vizualizácií. Data Science obsahuje niekoľko subdisciplín, ktoré sú načrtnuté na obrázku č.1. (Van der Aalst, 2016; SHAH, 2020)



Obrázok 1: Poddisciplíny data science

(Zdroj: Van der Aalst, 2016)

Data Science poskytuje odpovede na základné data-driven otázky:

- *Reporting*: Čo sa stalo?
- *Diagnostika*: Prečo sa to stalo?
- *Predikcia*: Čo sa stane?
- *Odporúčenie*: Čo je najlepšie čo sa môže stať?

(Van der Aalst, *n.d.*; Van der Aalst, 2016)

1.2 Dáta

Majú formu potenciálnej informácie, no vo svojej „surovej“ forme predstavujú iba údaj viazaný na reálny objekt. Bez interpretácie alebo kontextu majú dáta obmedzenú hodnotu. Informácia predstavuje správu alebo vnem, ktorý má definovanú sémantiku, syntax a je pre príjemcu relevantný. Po porozumení informácie získava užívateľ určitú znalosť. Transformácia informácie na dáta prebieha pri ukladaní tejto informácie, kedy mizne jej interpretačná podstata a napokon sa stáva iba zaznamenaným údajom viazaným na reálny objekt. (Koch, 2010)

Dáta rozlišujeme podľa štruktúry nasledovne:

1.2.1 Štruktúrované dáta

Jedná sa o dáta s definovaným dátovým typom, formátom a štruktúrou. Príkladom sú transakčné dáta, OLAP dátové kocky, tradičné RDBMS, súbory v csv formáte alebo tabuľkové procesory (spreadsheets). Sú to dáta, ktoré majú predvídateľný a často sa vyskytujúci formát. Štruktúrované dáta sú dobre definované, predvídateľné a riadené komplexnou infraštruktúrou. Väčšina dátových jednotiek je v štruktúrovanom prostredí jednoducho a rýchlo dostupná. (Inmon, 2014; SHAH, 2020; Inmon, 2014)

1.2.2 Neštruktúrované dáta

Sú nepredvídateľné a nemajú štruktúru, ktorá je detekovateľná počítačovým systémom. Neštruktúrované dáta sú ťažšie dostupné. Vyskytujú v mnohých formách a variáciách. Najbežnejšie vyskytovanou sa formou je text. Neštruktúrované dáta môžu pochádzať napríklad z e-mailov, PDF dokumentov, naskenovaného textu, obrázku alebo videa.

Drvivá väčšina podnikových rozhodnutí sa zakladá na analýze štruktúrovaných dát kvôli ich jednoduchej automatizácii a kompatibilitosti so štandardnými databázovými technológiami. Napriek náročnejšej manipulácii neštruktúrovaných dát sa v nich ukrývajú významné poznatky, ako napríklad úroveň spokojnosti zákazníkov zistená na základe analýzy recenzií. Dôraz na analýzu neštruktúrovaných dát môže poskytnúť spoločnostiam hlbšie pochopenie ich obchodného výkonu a viesť k zlepšeniu strategických rozhodnutí. (Inmon, 2014; SHAH, 2020; Inmon, 2014)

1.3 Big data

Predstavujú dáta, ktoré sú svojím rozsahom, rýchlosťou a rozmanitosťou príliš veľké pre tradičné systémy na spracovanie dát, a preto vyžadujú nové technológie spracovania. Vďaka svojmu obrovskému objemu a rozmanitosti poskytujú často presnejší a ucelenejší pohľad na špecifickú problematiku.

- *Rozsah* – objem uložených dát
- *Rýchlosť* – rýchlosť, akou dáta prichádzajú do systému a tiež potreba rýchleho spracovania dát
- *Rozmanitosť* – rozličné dátové formáty

(Coronel, [2019])

1.4 Databáza

Predstavuje organizovaný súbor vzájomne súvisiacich dát, typicky uložených v elektronickej podobe v počítačovom systéme, spravovaných systémom DBMS. Dáta v databáze sú typicky modelované vo forme riadkov a stĺpcov nachádzajúcich sa v tabuľkách s cieľom jednoduchého a efektívneho prístupu, správy, úpravy, kontroly a organizácie dát. (What Is a Database?, 2020)

V databáze sa uchovávajú end-user dáta (dáta koncového užívateľa) a tiež metadáta, takzvané dáta o dátach, ktoré popisujú charakteristiky a vzájomné vzťahy dát v databáze. Metadáta umožňujú integráciu a správu end-user dát. (Coronel, [2019])

1.4.1 Relačná databáza

Relačná databáza je zoskupením tabuliek, pričom každá tabuľka má svoj jedinečný názov. Tabuľka obsahuje množinu atribútov (stĺpcov alebo polí) a obvykle ukladá veľké množstvo záznamov (riadkov). Každý záznam v relačnej tabuľke reprezentuje objekt identifikovaný unikátnym kľúčom a opísaný súborom hodnôt atribútov. Na modelovanie relačnej databázy sa často využíva ER (entity-relationship) dátový model. Tento model reprezentuje databázu ako súbor entít a ich vzťahov. Relačné dáta sú prístupné pomocou databázových dotazov napísaných dotazovacím jazykom SQL. (Han, 2011)

1.4.2 OLAP (Online Analytical Processing)

OLAP je systémom určeným na vykonávanie multidimenzionálnej analýzy. Jeho základom je dátová kocka, ktorá je definovaná tabuľkou faktov a dimenzií. Tabuľka faktov obsahuje hlavne číselné údaje ako miery výkonu podniku, zatiaľ čo dimenzie popisujú tieto údaje. OLAP kocky umožňujú analyzovať dáta z rôznych uhlov, podporujú predvýpočty a umožňujú rýchly prístup k sumarizovaným dátam. Medzi tradične využívané operácie patrí napríklad Roll-up, Drill-down, Slice&Dice a pod. Využívané dáta zvyčajne pochádzajú z dátových skladov, dátových trhov alebo odlišného centralizovaného dátového úložiska. (Han, 2011, Van der Aalst, 2016)

1.4.3 OLTP (Online Transactional Processing)

OLTP systémy umožňujú spracovanie veľkého množstva transakcií v reálnom čase. Tieto systémy zahŕňajú väčšinu každodenne vykonávaných transakcií. OLTP využívajú relačné databázy na spracúvanie veľkého množstva zvyčajne jednoduchých transakcií ako napríklad vkladanie, úprava, či zmazanie dát. (Sinha, 2021)

1.4.4 Systém riadenia bázy dát (DBMS)

Systém riadenia bázy dát je softwarový systém určený na manipuláciu databáz. Je zodpovedný za organizáciu, správu a riadenie prístupov k databázam. DBMS podporuje niekoľko databázových jazykov na definíciu, manipuláciu a kontrolu dát. Systém využíva tiež nástroje na riadenie transakcií, riadenie paralelného spracovania dát, zabezpečenie integrity, obnovy a bezpečnosti dát. (Teorey, c2011)

Funkciou DBMS je tiež uchovávanie definície databázy a rôznych špecifikácií, či popisných informácií ako napríklad dátové typy, štruktúry, alebo obmedzenia dát, ktoré budú uložené v databáze. Tieto údaje sú uchovávané v DBMS vo forme databázového katalógu ako metadáta.

Dôležitou funkciou DBMS je tiež distribuovaný prístup k dátam a zabezpečenie konzistencie a bezpečnosti uložených dát aj v prípade pádu systému alebo pokusom o neoprávnený prístup.

(Han, 2011)

1.5 Dátový sklad

Dátový sklad je depozitár subjektovo orientovaných, integrovaných, časovo premenlivých, historických dát zhromaždených z viacerých zdrojov, uložených pod jednotnou schémou. Sú vytvorené pomocou procesu ETL. Ukladajú sa tu atomické a sumárne dáta. Ich cieľom je podpora analytického reportingu a manažérskeho rozhodovania.

Charakteristika znakov Dátového skladu:

Subjektovo-orientovaný

Je organizovaný so zameraním na konkrétne subjekty napr. zákazník, dodávateľ alebo produkt. Dátový sklad sa sústreďuje na modelovanie a analýzu pre podporu rozhodovania, a teda poskytuje pohľad na konkrétny subjektovo zameraný problém, pričom využíva iba dáta relevantné danému prípadu.

Integrovaný

Dátový sklad je zvyčajne zostavený integráciou rôznych heterogénnych zdrojov, napr. relačné databázy, operačné databázy alebo rôzne súbory. Dôležitým aspektom je teda zaistenie konzistencie a jednotnej koherentnej štruktúry. Toto je dosiahnuté čistením a zjednotením dát.

Časová variabilita

V dátovom sklade sa uchovávali historické dáta za účelom poskytnutia presnejšieho a ucelenejšieho pohľadu na problematiku a širšej časovej perspektívy. Každý kľúčový atribút obsahuje časový element.

Nemenný

Dátový sklad je udržiavaný oddelene od operačnej databázy. Operačné databázy zaisťujú súbežné spracovanie viacerých transakcií. Z tohto dôvodu sú pre ne potrebné mechanizmy riadenia súčasného prístupu a obnovy na zabezpečenie odolnosti a konzistencie databázy, ktoré však dátový sklad nepotrebuje. Dátový sklad na rozdiel od operačnej databázy nepotrebuje využívať ani metódy na spracovanie dát ako pridávanie, úprava alebo vymazanie dát, nakoľko sa tu dáta nemenia/nemažú, ale iba sa pridávajú nové. Zvyčajne sa v dátovom sklade využívajú iba 2 operácie: nahrávanie dát a prístup k nim (INSERT, SELECT). Časté zmeny odohrávajúce sa v operačných databázach sa v dátovom sklade vďaka ich oddeleniu neprejavujú. Dátový sklad je

na rozdiel od operačných databáz orientovaný najmä na analýzu. Procesovanie OLAP dotazov v operačných databázach by malo negatívny dopad na výkon operačných úloh. (Han, 2011) (Novotný, 2005a)

Pri návrhu podnikových dátových skladov sa typicky využíva multidimenzionálny dátový model. Na jeho zostavenie sa používa schéma hviezdy, vločky alebo súhvezdia. Jadrom multidimenzionálneho modelu je dátová kocka, ktorá pozostáva z tabuľky faktov a dimenzií. Dátová kocka poskytuje multidimenzionálny pohľad na dáta, umožňuje predvýpočet a rýchly prístup k sumarizovaným údajom. Tieto funkcionality dátovej kocky poskytujú podporu pre OLAP, ktorý umožňuje prezentáciu dát na rôznych úrovniach abstrakcie, napríklad operácie ako Drill-down alebo Roll-up poskytujú užívateľom možnosť hľadiť na dáta v rozličných stupňoch sumarizácie. Organizácie používajú informácie získané analýzou dát z dátového skladu na podporu rozhodovania napríklad so zameraním na zákazníka (analýza nákupných vzorcov), alebo analýza výkonu produktov porovnávaním tržieb na základe rôznych časových, geografických, či produktových dimenzií. (Han, 2011) (Lacko, 2003)

1.6 Proces ETL

ETL (Extraction, Transformation, Loading) proces, označovaný tiež pojmom „dátová pumpa“ slúži na prenos dát medzi dvoma alebo viacerými systémami. Skladá sa z troch hlavných častí:

- *Extrakcia dát* – zahŕňa získavanie a vyberanie dát zo zdrojových systémov
- *Transformácia dát* – úprava a čistenie dát
- *Loading (načítanie) dát* - nahrávanie dát do špecifických dátových štruktúr

(Novotný, 2005b)

1.7 Dátové trhy

Dátové trhy sú na rozdiel od dátových skladov určené pre menšie organizačné zložky ako napríklad jednotlivé oddelenia alebo divízie. Jedná sa v podstate o podmnožinu dátového skladu, ktorá môže slúžiť v budúcnosti ako podklad na vytvorenie dátového skladu. Dátové trhy sa občas využívajú aj po zavedení celopodnikového dátového skladu, kedy slúžia ako medzistupeň pri transformácii dát z produkčných databáz. Ich výhodou sú nižšie náklady na implementáciu, jednoduchšia implementácia a manipulácia. (Lacko, 2003; Novotný, 2005a)

1.8 Data mining

Data Mining (določenie dát) by sa dalo charakterizovať ako proces extrakcie zaujímavých, predom neznámych znalostí z veľkého množstva dát. Data Mining môže byť aplikovaný na akékoľvek dáta pokiaľ sú relevantné pre cieľové využitie. Základné formy dát vhodných pre aplikovanie data miningu zahŕňajú dáta z databáz, dátových skladov a transakčné dáta. Avšak data mining môže byť aplikovaný aj na ďalšie formy dát, ako napríklad sekvenčné dáta, dáta vo forme grafov alebo sietí, priestorové, textové, multimedialne dáta atď. (Novotný, 2005a)

1.8.1 Metódy Data Miningu

Data Mining využíva množstvo metód, nižšie budú vysvetlené tie najzákladnejšie.

Charakterizácia a diskriminácia dát

Charakterizácia dát spočíva v zhnutí všeobecných charakteristík alebo vlastností konkrétnej triedy údajov.

Diskriminácia dát predstavuje porovnanie všeobecných vlastností objektov z cieľovej triedy so všeobecnými vlastnosťami objektov z kontrastnej triedy, či viacerých kontrastných tried.

Klasifikácia a regresia

Klasifikácia a regresia sa radia medzi prediktívne metódy, ktoré vykonávajú indukciu na aktuálnych dátach s cieľom vyvodenia predpovedí. Obe metódy tiež patria do kategórie „učenia s učiteľom“, kedy sa algoritmus na základe tzv. tréningových dát, ktoré sú už klasifikované alebo majú priradenú cieľovú premennú, učí rozoznávať vzorce a neskôr tieto poznatky aplikovať na analýzu nových, nepoznaných dát a predikovať výstupy.

Klasifikácia je procesom vytvárania prediktívneho modelu, ktorý je schopný zaradiť neklasifikované objekty do existujúcich tried na základe ich vlastností alebo atribútov. Výsledný model môže mať formu klasifikačných pravidiel, rozhodovacích stromov, neurónových sietí a pod.

Regresia rovnako ako klasifikácia vytvára prediktívny model, ktorého úlohou je však predikcia spojitéch premenných. Funguje na princípe porozumenia vzťahov medzi závislou (cieľovou) a nezávislou (vysvetľujúcou) premennou. Cieľom je nájdenie matematickej funkcie alebo modelu, ktorý najlepšie vyhovuje dátam, pre vyvodenie čo najpresnejších predikcií.

V zásade, zatiaľ čo klasifikácia sa zaoberá identifikáciou kategorických tried, regresia sa zameriava na predikciu spojitéch premenných. (Han, 2011)

Zhlukovanie

Zhlukovanie spadá medzi deskriptívne metódy, ktoré charakterizujú vlastnosti dát v cieľovom datasete. Patrí tiež do kategórie „učenie bez učiteľa“, kedy algoritmus nemá definovanú cieľovú premennú, ani tréningové dáta a teda objavuje vzorce a poznatky sám, bez akéhokoľvek zásahu. Zhlukovanie spočíva v zoskupovaní sady objektov s podobnými vlastnosťami do tried alebo zhlukov. Záznamy nachádzajúce sa vo vnútri zhluku musia mať medzi sebou vysokú podobnosť, no v porovnaní s objektami v iných zhlukoch musia byť význame odlišné. Analýza na základe zhlukovania sa prakticky využíva v mnohých odvetviach, ako napríklad marketing, kde pomáha s rozlišovaním rozmanitých zákazníckych segmentov, zhlukovanie geopriestorových dát alebo detekcia finančných podvodov. (Bhatia, 2019)

Detekcia odľahlých hodnôt

Odľahlé hodnoty predstavujú objekty v datasete, ktoré nezodpovedajú všeobecnému správaniu alebo modelu dát a príliš sa odchyľujú od normy. Veľa metód v Data Miningu tieto objekty vynecháva, nakoľko môžu negatívne ovplyvniť výsledky analýzy. Existujú však prípady, pre ktoré sú odľahlé hodnoty špecificky zaujímavé ako napríklad odhaľovanie podvodov. Detekcia odľahlých hodnôt sa rovnako ako zhlukovanie radí medzi deskriptívne metódy. (Han, 2011)

Asociačné pravidlá

Asociačné pravidlá predstavujú ďalšiu deskriptívnu metódu z kategórie „učenie bez učiteľa“. Jedná sa o pravidlá hľadajúce asociácie medzi položkami množín. Skúmajú tiež frekventovaný výskyt súpravy prvkov v transakcii. Ich cieľom je objavenie zaujímavých vzťahov medzi položkami v databáze a vytvorenie silných asociačných pravidiel. Najbežnejším príkladom praktického využitia je analýza nákupného košíka.

(Provost, 2013; Van der Aalst, 2016)

Význam Data Miningu spočíva v schopnosti odhaliť skryté informácie a znalosti, ktoré by inak mohli zostať nepovšimnuté. Jeho praktické využitie sa prejavuje v mnohých odvetviach, vrátane obchodu, marketingu, zdravotníctva a financií, kde pomáha pri rozhodovacích procesoch, predikcii trendov, analýze trhu, personalizácii a mnoho ďalších.

1.9 Machine learning

Koncept Machine learning (strojové učenie) pramení z disciplíny umelej inteligencie za pomocou techník ako napríklad neurónové siete. Tento koncept funguje vďaka algoritmom, ktoré umožňujú počítačom získavať znalosti samostatne, bez explicitných zásahov programovania. Ide v podstate o učenie sa zo skúseností. Modely Machine learningu sú využívané spravidla na formovanie inteligentných data-driven rozhodnutí alebo predikcií. (Van der Aalst, 2016)


1.10 Process Science

Process Science (Procesná veda) predstavuje disciplínu, ktorá kombinuje znalosti z oblasti informačných technológií a managementu s cieľom správy a optimalizácie operačných procesov. Novým pohľadom na problematiku Process Science je tiež skúmanie procesov ako série zmien, či už vytvorených zásahom človeka alebo vyskytujúcich sa prirodzene. Dôležitým aspektom je porozumenie a ovplyvnenie tejto zmeny na požadované smerovanie. Tento pohľad vychádza z predpokladu, že procesy prechádzajú neustálymi zmenami a nikdy si exaktne nezachovávajú svoje pôvodné vlastnosti.

Základné princípy Process Science:

- Proces sa stáva stredobodom pozornosti
- Skúma procesy vedecky
- Prijíma perspektívy viacerých disciplín
- Snaží sa vplývať aktívnym formovaním priebehu procesov

(Van der Aalst, 2016; Vom Brocke, 2021; Vom Brocke, 2021)



Obrázok 2: Subdisciplíny Process Science

(Zdroj: Van der Aalst, 2016)

1.10.1 Proces

Existuje množstvo definícií procesu založených na rôznej abstrakcii skúmanej problematiky. Pre účel tejto práce bude využitá nasledujúca:

Proces predstavuje sled prepojených úloh a aktivít, ktoré sú iniciované ako odpoveď na udalosť, ktorej účelom je dosiahnutie špecifického výsledku pre užívateľa procesu. (Von Rosing, [2015].)

1.10.2 Obchodný proces

Je kolekciou úloh a aktivít pozostávajúcej zo zamestnancov, materiálov, strojov, systémov a metód, ktoré sú štruktúrované za účelom dizajnu, vytvorenia a dodania produktu alebo služby spotrebiteľovi. Obchodný proces by sa dal jednoducho definovať ako súhrn činností, ktoré pretvárajú vstupy na výstupy a sú vykonávané za účelom dosiahnutia konkrétneho obchodného cieľa. (Von Rosing, [2015].)

1.10.3 Základné členenie procesov

Riadiace procesy

Sú navrhnuté na plánovanie, meranie výkonnosti, monitorovanie a kontrolu obchodných aktivít. Zabezpečujú, že jadrový alebo podporný proces spĺňa prevádzkové, finančné, regulačné a právne požiadavky organizácie.

Jadrové procesy

Predstavujú hlavné činnosti, ktoré organizácia vykonáva na dosiahnutie obchodných cieľov a plnenie vízie. Ide o procesy, ktoré vytvárajú hodnotu pre externých zákazníkov, teda sú nevyhnutné pre podnikanie.

Podporné procesy

Pomáhajú jadrovým procesom poskytovaním zdrojov a infraštruktúry, ktoré sú potrebné na ich realizáciu. Na rozdiel od jadrových procesov neposkytujú priamo hodnotu externým zákazníkom (Vom Brocke, 2015; How to Classify Your Processes to Structure Your Business Process Architecture, *n.d.*)

Procesy si nezachovávajú svoje kvalitatívne vlastnosti naveky. Časom sa opotrebovávajú vplyvom interných či externých zmien ako napríklad vývoj nových technológií, zmena konkurencie, zmena potrieb zákazníkov. Procesný výkon postupne slabne a prichádza potreba optimalizácie alebo nahradenia procesu. (Vom Brocke, 2015)

Tento problém rieši hneď niekoľko procesne centrických metód. V nasledujúcej kapitole bude predstavený prístup BPM (Business Process Management).

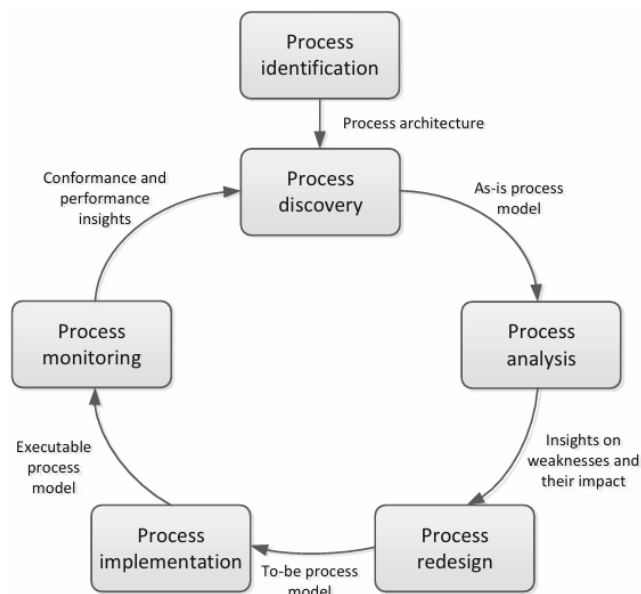
1.11 Business process management (BPM)

BPM je súbor zásad, metód a nástrojov na objavovanie, analyzovanie, prepracovanie, implementovanie a monitorovanie obchodných procesov s cieľom zabezpečenia ich konzistentne efektívneho výkonu. Prostredníctvom procesného managementu môže podnik vytvoriť vysokovýkonné procesy, ktoré fungujú rýchlejšie, presnejšie, flexibilne a s využitím nižších nákladov. Základom konceptu BPM je obchodný proces. Koncept BPM pramení z niekoľkých disciplín zdieľajúcich presvedčenie, že procesne centrický prístup vedie k významnému zlepšeniu podnikovej výkonnosti. (Vom Brocke, 2015; Dumas, 2018)

1.11.1 Návrh procesu

Základným stavebným prvkom pre vytvorenie výkonného procesu je kvalitne definovaný a spracovaný návrh procesu. Ten neskôr zjednodušuje detekciu dôvodov nedostatkov v procese. Pokiaľ proces nespĺňa očakávané požiadavky, problém korení v nesprávnom návrhu alebo nesprávnej realizácii procesu. Nesprávna realizácia procesu môže vyplývať z viacerých nedostatkov, ktoré je potrebné presne a rýchlo identifikovať. Po zistení príčiny stagnácie je problém zvyčajne jednoducho riešiteľný, na rozdiel od zistenia nedostatkov v návrhu procesu. Tu nastáva potreba kompletného prepracovania, čo môže byť zdĺhavou a tiež nákladnou úlohou. Nesprávny návrh procesu sa dá zväčša identifikovať rýchlo na základe konzistentne neuspokojivých výsledkov procesného výkonu. (Dumas, 2018; Vom Brocke, 2015)

1.11.2 Životný cyklus BPM



Obrázok 3: Životný cyklus BPM

(Zdroj: Dumas, 2018)

Process Identification

Je počiatočnou fázou BPM, kedy sa identifikujú procesy relevantné k danému problému a vzťahy medzi nimi.

Process Discovery

Jej typickým výstupom je „as is“ model procesu, ktorý popisuje súčasný stav procesov v organizácii a snaží sa podrobne vyobraziť ich reálne fungovanie a výkon. Jeho úlohou je identifikovať oblasti, ktoré vyžadujú optimalizáciu.

Process Analysis

Po dôkladnom porozumení „as is“ procesného modelu prichádza na rad hĺbková analýza problémových súčastí procesu. Jej cieľom je identifikácia, klasifikácia a porozumenie hlavnej príčiny stagnácie a následné navrhnutie riešenia, ktoré je schopné tieto nedostatky eliminovať alebo minimalizovať.

Process Redesign

Na základe porozumenia problémov vyskytujúcich sa v procese a navrhnutých riešení sa môže spoločnosť rozhodnúť pozmeniť proces. Vstupom pre túto fázu sa stáva „to be“ procesný model. Potenciálnych modelov môže existovať niekoľko, preto je dôležitá hĺbková analýza dopadov implementácie nového procesu a vybranie najvhodnejšieho z kandidátov.

Process Implementation

Zahŕňa praktickú aplikáciu nového procesného modelu a implementovanie zmien. V tejto fáze je dôležitá podpora IT systémov na zabezpečenie úspešnej realizácie implementácie procesu.

Process Monitoring

Po implementácii je naďalej nutné proces monitorovať, za účelom údržby a zabezpečenia efektívneho výkonu, keďže vplyvom času procesný výkon degraduje.


Všetky spomínané fázy sa časom kontinuálne striedajú a výstup získaný vo fáze monitoringu sa stáva vstupom pre fázu discovery. (Dumas, 2018)

1.11.3 Root cause analysis (RCA)

Analýza spočíva v identifikácii všetkých potenciálnych príčin vzniku problému a následnom zabezpečení aplikovania zmien cielených na zamedzenie opakovania daného problému. RCA analýza počína identifikáciou problému, ktorý sa ďalej skúma až do podstaty nájdenia a identifikovania najzákladnejšej „koreňovej“ príčiny problému. (Vom Brocke, 2015)

1.12 Význam Process Miningu

Procesne orientovaná perspektíva je v kontexte Data Science často opomenutá, kvôli procesne agnostickým prístupom tejto disciplíny. Prístupy Process Science sú zase zamerané na procesné modely bez využitia evidencie reálneho výkonu skrytej v dátach. Tento nesúlad rieši Process Mining, ktorý kombinuje tradičnú analýzu založenú na procesných modeloch a dátovo centrické analytické techniky. Process Mining vlastne predstavuje medzičlánok Data a Process Science. Gro Process Miningu spočíva v konfrontácii udalostných dát a procesných modelov.



Obrázok 4: Pozícia Process Miningu

(Zdroj: Van der Aalst, 2016)

1.12.1 Process Mining - definícia

Procesné dolovanie (Process Mining) je metóda, ktorá sa za využitia analýzy logov udalostí (event logs) snaží získať poznatky na dosiahnutie zlepšenia procesov. Process Mining v podstate predstavuje systém pre detekciu slabých článkov a odchýlok od plánovanej výkonnosti procesu. Spomínaná plánovaná výkonnosť vychádza z referenčného modelu procesu. Zatiaľ čo sa Data Mining zameriava na extrahovanie nových vzorov a poznatkov z rozsiahlych datasetov, snahou Process Miningu je poskytnutie poznatkov o skutočnom vykonávaní procesov a jeho odchýlok od referenčného modelu. (Van der Aalst, 2016)

1.12.2 Typy Process Miningu

Discovery (Objavenie)

Táto technika funguje na princípe vytvorenia procesného modelu, na základe procesného výkonu zaznamenaného v logoch udalostí, bez predchádzajúceho zadania referenčného modelu.


Conformance (Zhoda)

Existujúci procesný (referenčný) model je porovnaný s výkonom zaznamenaným v logoch udalostí. Conformance analýza sa používa na zhodnotenie dodržiavania referenčného modelu a tiež na detekciu rôznych deviácií procesu, kedy môže slúžiť na identifikovanie slabých článkov a odchýlok. V praktickom využití sa môže jednať napríklad o odhalenie podvodného správania, alebo identifikáciu neefektívnych odbočení od plánovaného procesného toku tzv. workarounds.

Enhancement (Vylepšenie)

Princípom je optimalizácia existujúceho procesného modelu na základe znalostí získaných analýzou logu udalostí. Kým conformance analýza porovnáva zhodu medzi referenčným a procesným modelom, enhancement analýza má za úlohu zmenu alebo rozšírenie referenčného modelu. (Van der Aalst, 2011)

Niektoré zdroje vnímajú spomínané typy Process Miningu skôr ako jednotlivé fázy kontinuálnej optimalizácie procesov. Indikujú, že Process Mining by mal ideálne fungovať ako cyklus s konštantným striedaním všetkým 3 fáz. V úvodnej discovery fáze je vytvorený procesný model slúžiaci ako chronologicky nadväzujúci prehľad reálneho fungovania procesu, ďalšou fázou je monitoring, ktorý porovnáva referenčný model vytvorený v discovery fáze s reálnym procesným modelom a posledná fáza optimalizácie sa zaoberá porovnávaním tzv. „as is“ modelu s „to be“ modelom. Vo fáze optimalizácie je možné skúšať rôzne simulácie dopadu rozhodnutí bez podstúpenia reálneho rizika. Pre biznis predstavuje predpoklad o dopade zmien (ako napr. automatizácia) na KPI a následných vyvolaných efektoch na chod biznisu.



Obrázok 5: Typy Process Miningu
(Zdroj: Process Mining Manifesto, 2011)

1.12.3 Procesné modely

Pre danú problematiku existuje množstvo využívaných procesných modelov, napríklad BPMN, Petriho siete, UML diagram aktivít a pod. Nižšie bude stručne načrtnutý prvý z vymenovaných.

Business Process Model and Notation

Business Process Modeling Notation (BPMN) slúži ako štandard grafickej reprezentácie procesov. Ich úlohou je zachytenie procesného toku. (Řepa, 2007)

V grafickej notácii sa vyskytujú 3 hlavné symboly :

- *Aktivita* – je označená ako zaoblený obdĺžnik
- *Brána* – má diamantový tvar a uprostred špecifický symbol, tzv. logický operátor, označuje vetvenie a tok procesu
- *Udalosť* – má tvar kruhu, označuje začiatočnú, koncovú alebo prechodnú udalosť (Dumas, 2018)

1.12.4 Zdrojové dáta

Event logs (Logy udalostí)

Sú digitálnym odtlačkom každej akcie vykonanej v informačnom systéme. Ich analýza umožňuje pozorovanie reálneho procesného výkonu vrátane odchýlok a slabých článkov vyskytujúcich sa v procese. Logy udalostí poskytujú informácie o výskyte špecifických udalostí, ich trvaní, či informácie o udalostiach vyskytujúcich sa pred, či po nich.

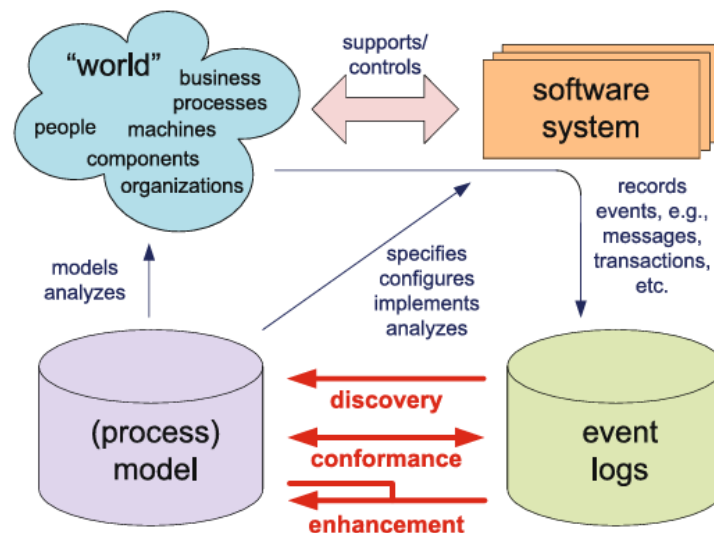
Každý riadok v tabuľke reprezentuje udalosť.

Každá udalosť sa v logu odkazuje na inštanciu procesu, nazývanú „prípado“.

Atribúty ako „case id“ a „activity“ predstavujú minimálne požadované hodnoty pre Process Mining, avšak väčšina dolovacích nástrojov vyžaduje zadanie aspoň 3 atribútov:

- *Case (prípado)* : odkazuje sa na inštanciu procesu
- *Activity (aktivita)* : odkazuje sa na operáciu, akciu alebo úlohu
- *Timestamp (časové razítko)* : časový údaj označujúci kedy sa odohrala udalosť

(Van der Aalst, 2011)



Obrázok 6: Process Mining model

(Zdroj: Van der Aalst, 2011)

1.12.5 XES (Extensible Event Stream) formát

Formát XES je oficiálnym štandardom pre uchovávanie udalostných dát. Tento formát je podporovaný väčšinou dostupných softwarov a nástrojov zameraných na procesné dolovanie. Jeho cieľom je umožniť plynulý prenos udalostných dát medzi rôznymi systémami. Formát XES pridáva dátam sémantiku, na rozdiel od ostatných súborových formátov. (Van der Aalst, 2022)

1.13 Business Intelligence

Aby spoločnosti dokázali efektívne riadiť svoj biznis a prosperovať, je pre nich kľúčové hlbšie pochopenie obchodného prostredia v ktorom sa nachádzajú. Či už ide o správanie zákazníkov, dynamiku trhu, zdroje alebo konkurenciu, technológie Business Intelligence predstavujú pre spoločnosti kvalitný podklad pre analýzu a plánovanie v oblastiach podnikového riadenia. Technológie BI umožňujú historický, súčasný a prediktívny pohľad na obchodné operácie poskytujúc širokospektrálny záber obchodného výkonu. (Han, 2011; Novotný, 2005)

Súčasný pokrok technológií, zvýšenie výkonnosti hardwaru, rozmach sofistikovaných algoritmov, či väčšia rozmanitosť dát, zmenili spôsob analýzy dát, umožňujúc získanie hlbších poznatkov ako kedykoľvek predtým. (Van der Aalst, 2016)

1.13.1 Vizualizácia a interpretácia

Vizualizácia údajov predstavuje grafické zobrazenie dát s cieľom uľahčiť porozumenie ich štruktúry, vzťahov a vzorov. V kontexte Data, či Process Science je vizualizácia neoddeliteľným prvkom, ktorý umožňuje užívateľom interpretovať výsledky.

1.13.2 Microsoft Power BI

Power BI je prostredie obsahujúce súbor nástrojov používaných na získavanie, ukladanie, modelovanie a vizualizáciu dát, vytvorené spoločnosťou Microsoft Corporation. Power BI ponúka široké spektrum analytických metód, od tvorby jednoduchých tabuliek a grafov cez zložité dashboardy a reporty až po možnosti využívania strojového učenia. (What is Power BI?, 2024)

1.13.3 Celonis

Predstavuje komerčný nástroj využívaný na analýzu a vizualizáciu udalostných dát. Celonis podporuje načítanie dát v niekoľkých formátoch napr. csv, xes alebo dokáže dáta načítať priamo z DBMS ako napríklad SAP HANA, Oracle, MYSQL a ďalšie. Udalostné dáta sa ukladajú do štruktúry podobnej OLAP. (Van der Aalst, 2016)

2. ANALÝZA SÚČASNÉHO STAVU

Nasledujúca analýza bude vykonaná na fiktívnom modeli B2C maloobchodu. Jednotlivé informácie sú inšpirované reálnym podnikovým prostredím a zaužívanými organizačnými vzorcami. Analyzovaná spoločnosť podniká v oblasti predaja spotrebnej elektroniky, kancelárskych potrieb a kancelárskeho nábytku. Taktiež je poskytovateľom služieb následnej starostlivosti ako sú záruky, inštalácia a podpora po predaji.

2.1 Organizačná štruktúra

Na najvyššej úrovni hierarchie operuje výkonné vedenie, ktorého úlohou je stanoviť strategické ciele a dohliadať na celkový chod podniku. Podriadené vrstvy zahŕňajú vedúcich oddelení zodpovedných za konkrétne funkcie ako sú marketing, financie, prevádzka, HR a IT.

Oddelenie Prevádzky

Dohliada na dodávateľský reťazec, riadenie skladu a logistiku. To zahŕňa obstarávanie, skladovanie a distribúciu, zabezpečujúc plynulý tok produktov od výrobcov k zákazníkom.

Oddelenie Financíí

Je zodpovedné za finančné plánovanie, rozpočtovanie a správu. Stará sa o finančné zdravie maloobchodu.

Oddelenie HR

Oddelenie ľudských zdrojov riadi nábor zamestnancov, ich vzdelávanie, rieši personálne záležitosti.

IT Oddelenie

Zameriava sa na správu a údržbu využívaných systémov, vývoj nových technologických riešení a kybernetickú bezpečnosť.

Oddelenie Marketingu

Sústredí sa na tvorbu a implementáciu stratégií na propagáciu produktov a služieb. To zahŕňa prieskum trhu, reklamné kampane, zviditeľnenie značky a oslovenie zákazníkov.

2.2 Podnikový informačný systém

Zástupcom ERP, CRM a SRM systému v podniku je software od nemeckej spoločnosti SAP. Dáta sú zo spomínaného softwaru exportované do programu Microsoft Excel vo formáte xls.

2.3 Súčasný stav Business Intelligence

V súčasnosti je zdrojovým systémom pre analýzu dát v podniku najmä ERP, CRM a SRM systém od spoločnosti SAP. Spracovanie dát počína ich exportom z programu SAP do prostredia Microsoft Excel. Následne sú tieto dáta konvertované do tabuliek, pričom manažér, nedisponujúci dedikovaným tímom zaoberajúcim sa dátovou analýzou alebo vytváraním reportov, je nútený vytvárať vlastné analytické výstupy. Reporty sú vytvárané najmä v Ad-hoc forme, kedy sú využívané pre špecifický jednorazový účel.

2.4 P2P proces vo firme

Purchase to Pay (P2P) proces je kľúčovým obchodným procesom zabezpečujúcim plynulú fázu obstarávania. Počiatočným bodom procesu je zadanie požiadavky na nákup v SRM (Supplier relationship management) software. V tomto prípade sa jedná konkrétne o aplikáciu v prostredí softwaru SAP. Požiadavky sú do systému zadané oprávnenými zamestnancami. Po vytvorení požiadavky nasleduje kontrola správnosti a úplnosti nákupného košíka. Následne požiadavka čaká na potvrdenie kompetentného zamestnanca z oddelenia prevádzky. V závislosti od výšky sumy objednávky môže byť osôb potrebných na verifikáciu viac. Po potvrdení požiadavky nasleduje zadanie objednávky u vybraného dodávateľa. Ten pošle faktúru finančnému oddeleniu, ktoré ju následne registruje do softwaru SAP. Faktúra je spárovaná s objednávkou. V prípade prítomnosti príjemky prebehne kontrola doručenia tovaru a finálne potvrdenie faktúry so záväzkom platby.

V procese sú okrem základných tokov obsiahnuté aj rôzne nežiadúce zásahy ako napríklad zmeny, zrušenie, zmazanie, reaktivácia, upomienky. Tieto zásahy vytvárajú v požadovanom slede procesu odchýlky, či prekážky. Výsledkom je neštandardne pomalé prevedenie procesu, ktoré nie je managementom spoločnosti bližšie adresované.

2.5 Zhodnotenie súčasného stavu

Pohľad na fungovanie spoločnosti, podnikové procesy a ich výkon nám poskytol informácie na základe ktorých sa dá konštatovať, že aktuálne riešenie je zastaralé a spoločnosť nedokáže efektívne využívať zdroje v podobe dát. Kvalitnejšie podklady pre rozhodovacie procesy v podobe komplexných reportov by vedeli odhaliť oblasti, ktorých optimalizáciou by spoločnosť dokázala prosperovať, šetriť náklady, efektívnejšie využívať ľudské zdroje, vylepšiť zákaznícky servis a posunúť svoje pôsobenie na vyšší level. Hlavným problémom je absencia tímu špecializovaného na dátovú analýzu, Business Intelligence, či reporting, čo vedie k zdĺhavej práci manažéra, ktorý sa musí venovať manuálnemu vytváraniu tabuliek a grafických vizualizácií. Okrem toho je samotný proces náchylný na chyby a neprehľadný, čo môže ovplyvniť kvalitu rozhodovacích procesov v organizácii. Ako negatívny faktor tiež pôsobí nedostatočná odbornosť a znalosť manažérov v problematike Business Intelligence, čo vytvára prekážky v implementácii efektívnejších riešení a využitií potenciálu dát v prospech podnikových cieľov. Problematika neefektívneho výkonu procesu Purchase to Pay je taktiež dlhodobo opomenutá, napriek jednoduchému prístupu k udalostným dátam, ktorých analýza by dokázala odhaliť možné príčiny stagnácie. Vzhľadom na dynamiku súčasného obchodného prostredia a potrebu vyrovnat' sa konkurenčným firmám, ktoré v dnešnej dobe kladú veľký dôraz na aplikovanie najnovších trendov v oblasti dátovej analýzy, je nevyhnutné, aby spoločnosť siahla po technologicky pokročilých riešeniach analytického spracovania a vizualizácie svojich podnikových dát. Ideálne by bolo tiež zavedenie pravidelného reportingu, ktoré poskytuje manažérom komplexný prehľad o obchodných výsledkoch. V nasledujúcej kapitole bude popísaný návrh riešenia Business Intelligence spolu s odporúčaniami na optimalizáciu konkrétnych oblastí podnikových procesov.

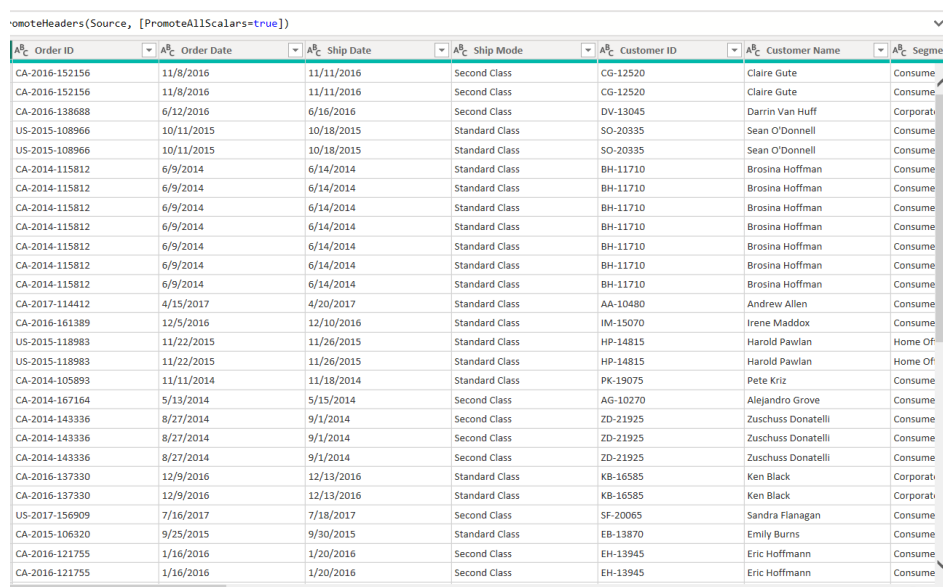
3. VLASTNÝ NÁVRH RIEŠENIA

Vzhľadom na problémy nastolené v predchádzajúcej kapitole vyplýva, že spoločnosť by dokázala všestranne optimalizovať prevádzkové rozhodnutia a nastavenie podnikových procesov pokiaľ by bola ochotná investovať finančné a ľudské zdroje do data-driven prístupu založeného na hĺbkovej analýze dát. Nasledujúca kapitola sa zaoberá návrhom takéhoto riešenia. Spočiatku poskytuje spoločnosti základný interpretačný rámec v podobe interaktívneho dashboardu s prehľadnými metrikami týkajúcimi sa obchodného výkonu a následne sa zameriava na optimalizáciu vybraného procesu. Konkrétne prechádza hlbšou analýzou proces Purchase to Pay, ktorý je podrobený procesnému dolovaniu. Účelom sa stáva zhodnotenie súčasnej výkonnosti a revitalizácia, či prípadne úplné odstránenie stagnujúcich súčastí procesu.

3.1 Zdrojové dáta a ich úprava

Na ilustráciu problému bol využitý verejne dostupný dataset vo formáte xls obsahujúci dáta viazané k objednávkam.

Dátový model v tomto prípade predstavuje iba jedna veľká tabuľka faktov.



Order ID	Order Date	Ship Date	Ship Mode	Customer ID	Customer Name	Segmen
CA-2016-152156	11/8/2016	11/11/2016	Second Class	CG-12520	Claire Gute	Consume
CA-2016-152156	11/8/2016	11/11/2016	Second Class	CG-12520	Claire Gute	Consume
CA-2016-138688	6/12/2016	6/16/2016	Second Class	DV-13045	Darrin Van Huff	Corporat
US-2015-108966	10/11/2015	10/18/2015	Standard Class	SO-20335	Sean O'Donnell	Consume
US-2015-108966	10/11/2015	10/18/2015	Standard Class	SO-20335	Sean O'Donnell	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2014-115812	6/9/2014	6/14/2014	Standard Class	BH-11710	Brosina Hoffman	Consume
CA-2017-114412	4/15/2017	4/20/2017	Standard Class	AA-10480	Andrew Allen	Consume
CA-2016-161389	12/5/2016	12/10/2016	Standard Class	IM-15070	Irene Maddox	Consume
US-2015-118983	11/22/2015	11/26/2015	Standard Class	HP-14815	Harold Pawlan	Home Of
US-2015-118983	11/22/2015	11/26/2015	Standard Class	HP-14815	Harold Pawlan	Home Of
CA-2014-105893	11/11/2014	11/18/2014	Standard Class	PK-19075	Pete Kriz	Consume
CA-2014-167164	5/13/2014	5/15/2014	Second Class	AG-10270	Alejandro Grove	Consume
CA-2014-143336	8/27/2014	9/1/2014	Second Class	ZD-21925	Zuschuss Donatelli	Consume
CA-2014-143336	8/27/2014	9/1/2014	Second Class	ZD-21925	Zuschuss Donatelli	Consume
CA-2014-143336	8/27/2014	9/1/2014	Second Class	ZD-21925	Zuschuss Donatelli	Consume
CA-2016-137330	12/9/2016	12/13/2016	Standard Class	KB-16585	Ken Black	Corporat
CA-2016-137330	12/9/2016	12/13/2016	Standard Class	KB-16585	Ken Black	Corporat
US-2017-156909	7/16/2017	7/18/2017	Second Class	SF-20065	Sandra Flanagan	Consume
CA-2015-106320	9/25/2015	9/30/2015	Standard Class	EB-13870	Emily Burns	Consume
CA-2016-121755	1/16/2016	1/20/2016	Second Class	EH-13945	Eric Hoffmann	Consume
CA-2016-121755	1/16/2016	1/20/2016	Second Class	EH-13945	Eric Hoffmann	Consume

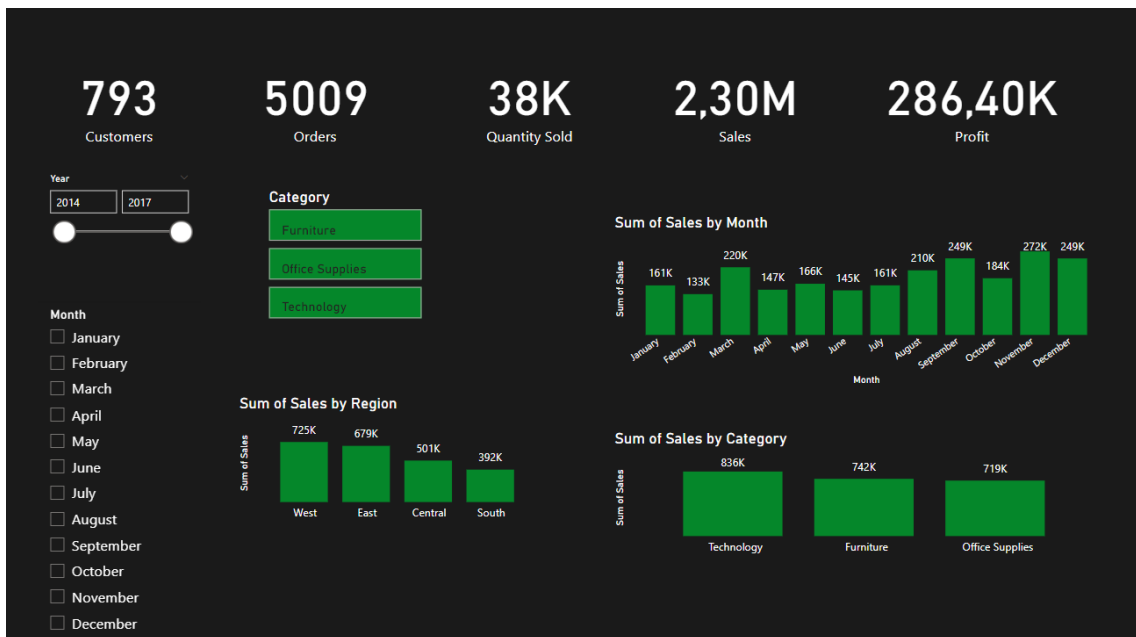
Obrázok 7: Dataset

(Zdroj: Vlastné spracovanie)

Pred samotnou analýzou bolo nutné vykonať niekoľko úprav ako napríklad prenastavenie atribútov na vhodné dátové typy alebo rozdelenie stĺpcov s časovými údajmi a nastavenie na formát vhodný pre účely analýzy.

3.2 Analýza a vizualizácie v prostredí Power BI

Vytvorený dashboard poskytuje základný prehľad o počte zákazníkov, objednávok, predaného tovaru a sume príjmov, či profitu. Následne sa dané metriky filtrujú na základe kategórie tovaru, či roku a mesiaca predaja. Grafy predstavujú pre manažerov prehľadný podklad pre získanie informácií o odbytovom výkone.



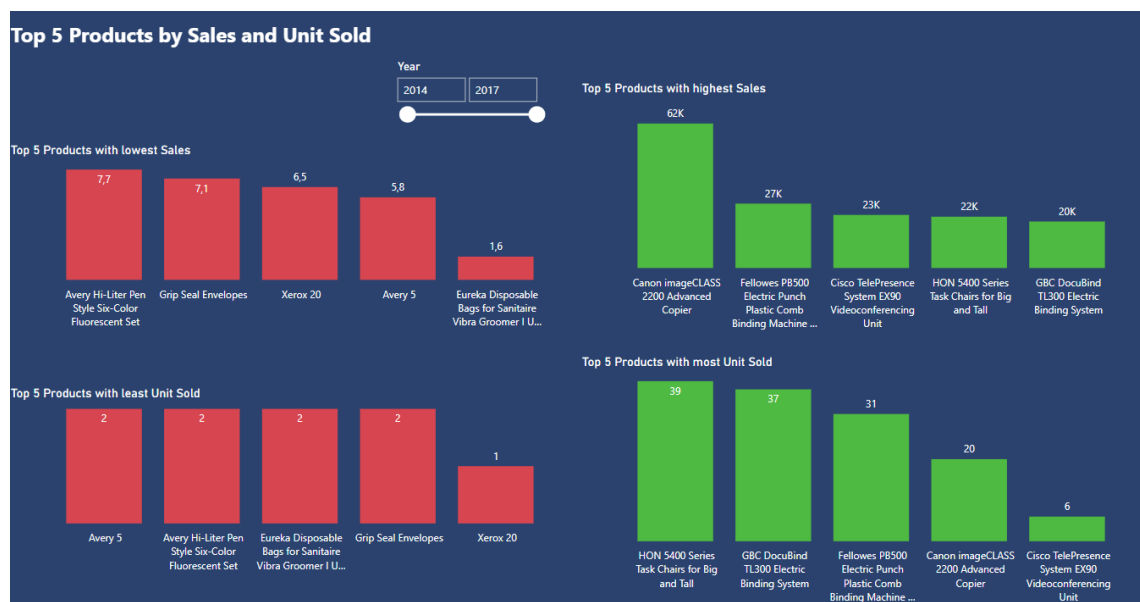
Obrázok 8: Dashboard č. 1

(Zdroj: Vlastné spracovanie)

Z dashboardu je možné získať hneď niekoľko dôležitých poznatkov, napríklad kategória technológií prináša spoločnosti najvyššie tržby, ale kancelárske potreby sa predávajú najviac podľa počtu objednávok a predaného množstva, a to najmä počas mesiaca september. Kategória technológie dosahuje zase najvyššie tržby v novembri, a teda záverom môže byť výrazné vplyvanie sezóny na odbyť. Spoločnosť by sa mohla zamerať napríklad na posilnenie marketingovej kampane v sezónach pred Vianocami, či pred začiatkom školského roka.

Informácie o produktoch, ktoré sa v spoločnosti predávajú najmenej a prinášajú najnižšie tržby by mali pre management spoločnosti predstavovať vhodný materiál na hlbšiu analýzu (napr. RCA) príčiny stagnácie. Či už ide o nekvalitné výrobky o ktoré zákazníci nemajú záujem, sú morálne zastaralé vplyvom technického pokroku, alebo nedostatočne propagované, pre spoločnosť by bolo vitálnym riešením zvolenie novej obchodnej taktiky. Tá by mohla predstavovať napr. úpravu cenotvorby pre dané výrobky pre zvýšenie dopytu, lepšiu propagáciu produktov alebo ich úplné vyradenie zo sortimentu za účelom šetrenia nákladov, či už obstarávacích alebo na skladovanie.


Naopak, najpredávanejšie a najvýnosnejšie produkty a ich odbytová politika môžu pre management slúžiť ako podklad pre analýzu preferencií zákazníkov, ich potrieb a trendoch na trhu. Inovácie a vylepšenia v oblasti odbytovej politiky môžu viesť k vytvoreniu konkurencieschopných produktov.



Obrázok 9: Dashboard č. 2

(Zdroj: Vlastné spracovanie)

Dashboard zobrazuje top 5 najviac a najmenej predávaných produktov v závislosti na tržbách a predanom množstve.



Obrázok 10: Dashboard č. 3
(Zdroj: Vlastné spracovanie)

Ďalší dashboard sa zameriava najmä na analýzu tržieb z rôznych uhlov pohľadu. Užívateľovi poskytuje možnosť filtrovania podľa subkategórie produktu a roku v podobe Slicerov. Interaktívne grafy zobrazujú zľava porovnanie úspešných a reklamovaných objednávok, porovnanie množstva objednávok na základe spôsobu dopravy a tržby filtrované podľa segmentu vyobrazené pomocou koláčového grafu. V dashboarde sa nachádza tiež interaktívna mapa zobrazujúca dosiahnuté tržby v jednotlivých štátoch pôsobenia spoločnosti. Pomocou vizuálu kariet sa užívateľ dozvedá informácie o metrikách ako priemerná doba trvania spracovania objednávky, počet objednávok a ponúkaných produktov, ktoré je tiež možné filtrovať podľa subkategórie produktu a roku. Na vypočítanie priemernej dĺžky spracovania objednávky bolo potrebné využiť metriku počítajúcu počet dní medzi jednotlivými dátumami.

DaysBetween Measure = `DATEDIFF(MIN('Sample - Superstore'[Order Date]), MIN('Sample - Superstore'[Ship Date]), DAY)`

Medzi získané poznatky patrí napríklad fakt, že priemerná doba spracovania objednávky sa v roku 2018 zvýšila oproti predchádzajúcim rokom o 1 deň, no celkový počet objednávok sa znížil. Dôvodom môže byť napríklad neefektívny proces spracovania objednávok alebo nedostatky v logistických procesoch.

Na vytvorenie dvoch nasledujúcich dashboardov bola použitá metrika YoY (Year over year). YOY vyjadruje medziročnú zmenu dvoch alebo viacerých porovnateľných období. Zvyčajne sa jedná o porovnanie finančných metrík v aktuálnom a predchádzajúcom roku vyjadrenom v percentách. Na vypočítanie ukazovateľa bolo najprv potrebné vytvorenie metriky Previous year.

Vytvorený DAX kód zameraný na tržby vyzerá nasledovne:

Previous year Sales = `CALCULATE(SUM('Sample - Superstore'[Sales]),DATEADD('Sample - Superstore'[Order Date].[Date], -1, YEAR))`

Ďalším krokom je vytvorenie metriky YoY:

YoY Sales = `(SUM('Sample - Superstore'[Sales])-[Previous year Sales])/[Previous year Sales]`

Rovnaký postup bol použitý aj pri vytvorení metriky pre Orders a Profit:


Previous year Orders = `CALCULATE(DISTINCTCOUNT('Sample - Superstore'[Order ID]),SAMEPERIODLASTYEAR('Sample - Superstore'[Order Date].[Date]))`

YoY Orders = `(DISTINCTCOUNT('Sample - Superstore'[Order ID])-[Previous year Orders])/[Previous year Orders]`

Previous year Profit = `CALCULATE(SUM('Sample - Superstore'[Profit]),DATEADD('Sample - Superstore'[Order Date].[Date], -1, YEAR))`

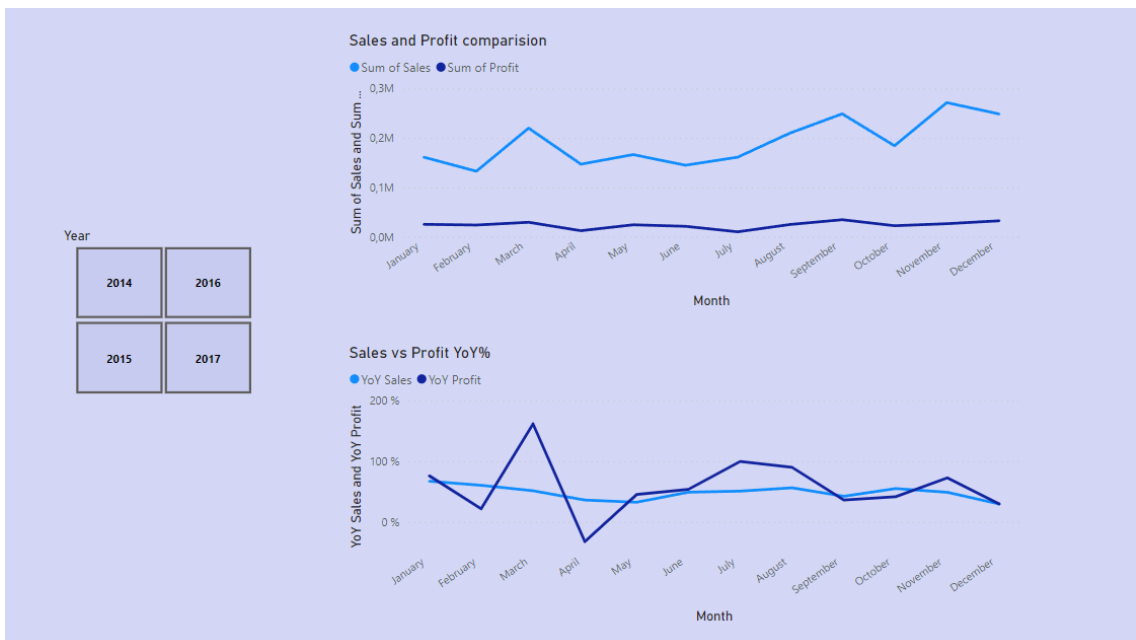
YoY Profit = `(SUM('Sample - Superstore'[Profit])-[Previous year Profit])/[Previous year Profit]`

Výsledkom sú spojnicové grafy znázorňujúce percentuálnu medziročnú zmenu tržieb, či počtu objednávok. Nasledujúci dashboard zase zobrazuje medziročnú zmenu v porovnaní tržieb so ziskom.



Obrázok 11: Dashboard č. 4

(Zdroj: Vlastné spracovanie)



Obrázok 12: Dashboard č. 5

(Zdroj: Vlastné spracovanie)



Obrázok 13: Dashboard č. 5, detail

(Zdroj: Vlastné spracovanie)

YoY metrika pôsobí ako stabilnejší ukazovateľ nakoľko zohľadňuje vplyvy sezónnych fluktuácií na analýzu. Predstavuje tiež kvalitný základ pre zhodnotenie dosiahnutia požadovaných KPIs (Key Performance Indicators).

V dashboardoch č. 4 a 5 je možné pozorovať napríklad nasledujúce skutočnosti:

- Pri porovnaní rokov 2017 a 2016 vyplýva, že najväčší medziročný percentuálny nárast tržieb bol dosiahnutý v mesiaci september a najnižší v mesiaci máj
- Pri objednávkach bol zaznamenaný najväčší medziročný nárast vo februári a najnižší v máji (rok 2017 a 2016)
- Celkový priebeh medziročných zmien má klesajú tendenciu v mesiaci máj, či už v kontexte tržieb alebo objednávok
- YoY zmena tržieb a profitu vykazuje v mesiaci máj negatívnu (mínusovú) zmenu

Tieto skutočnosti poskytujú spoločnosti možnosť stanovenia optimálnych KPI na mesiac máj za účelom zlepšenia obchodnej výkonnosti.

3.2.1 Zhodnotenie

Prvá časť praktického riešenia sa zaoberá vytvorením interaktívnych reportov slúžiacich ako podpora pre manažérske rozhodovanie a podklad na zhodnotenie obchodnej výkonnosti. Efektívne využívanie nástrojov Business Intelligence už dnes predstavuje pre spoločnosti nutné minimum. Mnohé siahajú po pokročilých metódach ako napríklad Machine learning alebo Data a Process Mining, za účelom získania hlbokých znalostí z dostupných dát. V dnešnom dynamickom dátovo orientovanom obchodnom prostredí je tím alebo pracovníci zameraní na dátovú analýzu, či problematiku Business Intelligence nevyhnutnosťou. Získavanie znalostí z dát iba v krajnej nutnosti na základe tzv. ad-hoc analýz neposkytuje pre spoločnosť požadované poznatky. Zlepšovanie procesov, či už obchodných alebo rozhodovacích musí prebiehať kontinuálne, ako nikdy nekončiaci cyklus.

3.3 Process mining

3.3.1 Zdrojové dáta a ich spracovanie

Využívaný dataset obsahuje logy udalostí (event logs) viazané na Purchase to pay (P2P) proces. Dataset sa nachádza vo formáte xes (extensible event stream). Log obsahuje 250 000 prípadov zahŕňajúcich 1 595 923 udalostí a 42 aktivít. Vykonaťateľmi aktivít sú užívatelia z dvoch skupín – human alebo batch user. Hodnota NONE indikuje neprítomnosť záznamu o užívatelovi.

Logy udalostí boli nahrané vo formáte xes do dolovacieho softwaru Celonis. Následne boli priradené 3 povinné atribúty :

- CaseID vytvorené zlúčením ID nákupného dokladu (purchase_document_id) a ID položky (item_id)
- Aktivita
- Timestamp

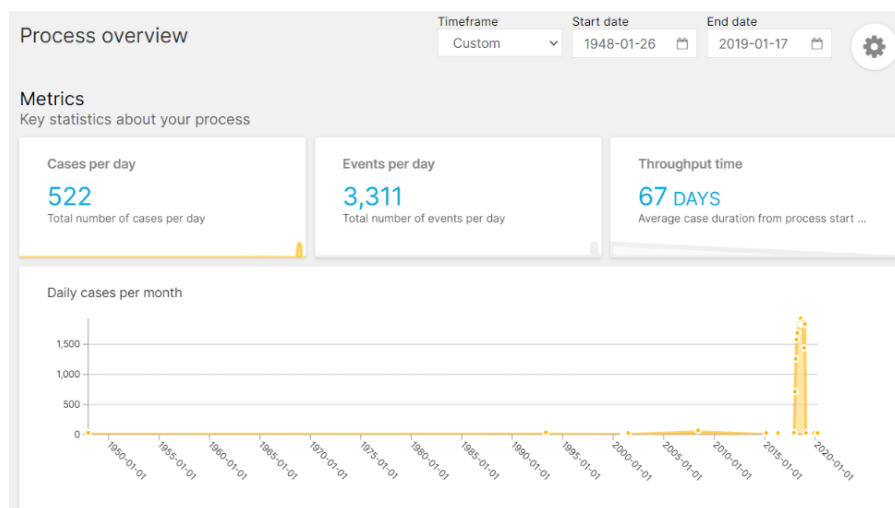
AR: User	AR: org:resource	AR: concept:name	1 ² 3 Cumulative net worth (EUR)	time:timestamp	AR: case:Spend area text	AR: case:Company
batch_00	batch_00	SRM: Created	298	1/2/2018, 12:53:00 PM	CAPEX & SOCS	companyID_000 ▲
batch_00	batch_00	SRM: Complete	298	1/2/2018, 1:53:00 PM	CAPEX & SOCS	companyID_000
batch_00	batch_00	SRM: Awaiting Approval	298	1/2/2018, 1:53:00 PM	CAPEX & SOCS	companyID_000
batch_00	batch_00	SRM: Document Completed	298	1/2/2018, 1:53:00 PM	CAPEX & SOCS	companyID_000
batch_00	batch_00	SRM: In Transfer to Execution Syst.	298	1/2/2018, 1:53:00 PM	CAPEX & SOCS	companyID_000
batch_00	batch_00	SRM: Ordered	298	1/2/2018, 1:53:00 PM	CAPEX & SOCS	companyID_000
batch_00	batch_00	SRM: Change was Transmitted	298	1/2/2018, 1:53:00 PM	CAPEX & SOCS	companyID_000
user_000	user_000	Create Purchase Order Item	298	1/2/2018, 1:53:00 PM	CAPEX & SOCS	companyID_000
NONE	NONE	Vendor creates invoice	298	1/2/2018, 10:59:00 PM	CAPEX & SOCS	companyID_000
user_000	user_000	Record Goods Receipt	298	3/6/2018, 6:44:00 AM	CAPEX & SOCS	companyID_000
user_001	user_001	Record Invoice Receipt	298	3/6/2018, 7:53:00 AM	CAPEX & SOCS	companyID_000
user_002	user_002	Clear Invoice	298	3/29/2018, 1:06:00 PM	CAPEX & SOCS	companyID_000
batch_00	batch_00	SRM: Created	557	1/3/2018, 8:49:00 AM	Marketing	companyID_000
batch_00	batch_00	SRM: Complete	557	1/3/2018, 9:49:00 AM	Marketing	companyID_000
batch_00	batch_00	SRM: Awaiting Approval	557	1/3/2018, 9:49:00 AM	Marketing	companyID_000 ▼

Obrázok 14: Dataset

(Zdroj: Vlastné spracovanie)

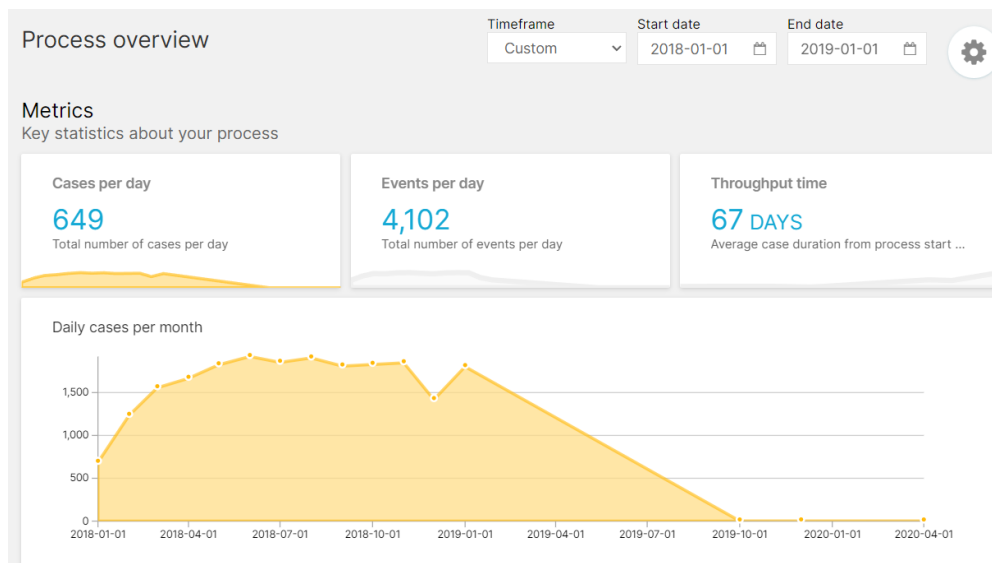
3.3.2 Skúmanie a filtrovanie dát

Pomocou nasledujúceho grafu získavame informácie o prípadoch vyskytujúcich sa počas celého časového obdobia/úseku zaznamenaného v logoch udalostí. Napriek prvému záznamu z roku 1948 je významný nárast prípadov zaznamenaný až začiatkom roka 2018. Dataset obsahuje tiež hodnoty z budúcich rokov, čo indikuje že niektoré z prípadov obsahujú chybné timestamps. Všetky tieto druhy záznamov budú vylúčené za účelom zachovania relevantnosti a presnosti analýzy. Dataset obsahuje tiež niekoľko neukončených prípadov, ktoré boli pravdepodobne v čase extrakcie dát v rozpracovanom stave. Tieto skutočnosti môžu ovplyvniť výsledky analýzy napríklad neprimerane dlhými priemernými časovými prechodmi medzi jednotlivými aktivitami. Z tohto dôvodu bude skúmané iba časové obdobie od 1. 1. 2018 do 1. 1. 2019 (relevantné pre čas vykonania extrakcie dát).



Obrázok 15: Process overview č. 1

(Zdroj: Vlastné spracovanie)

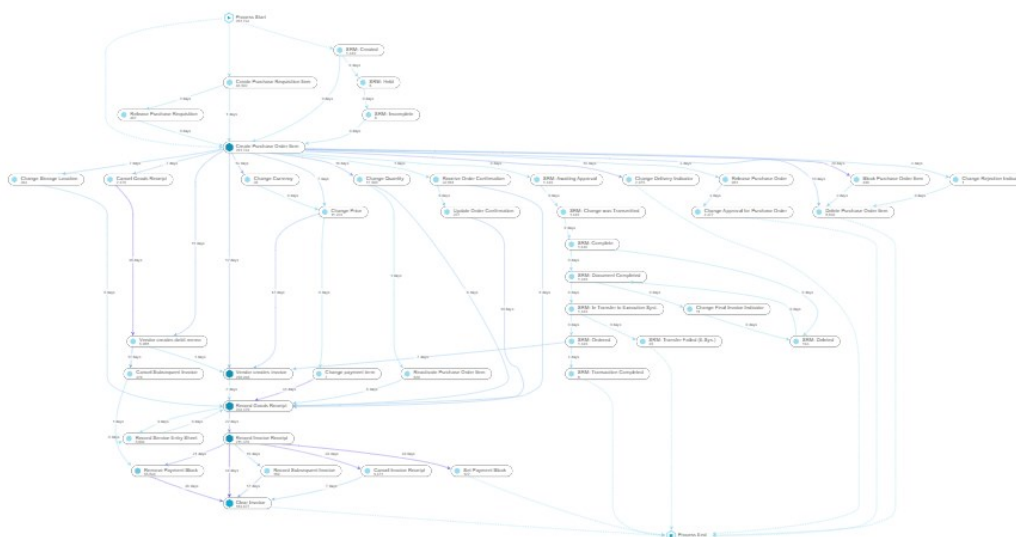


Obrázok 16: Process overview č. 2

(Zdroj: Vlastné spracovanie)

3.3.3 Analýza a vizualizácie v prostredí Celonis

Počiatočnú úlohu zohrali vizualizácie v štýle procesných máp, ktoré poskytli komplexný pohľad na proces a jeho odchýlky. Pomocou nastavenia rozsahu aktivít a spojení medzi nimi bolo možné pozorovať rôzne stupne rozvetvenia procesov a identifikovať neštandardné situácie. Zobrazením všetkých aktivít v procese vzniká neprehľadná štruktúra.

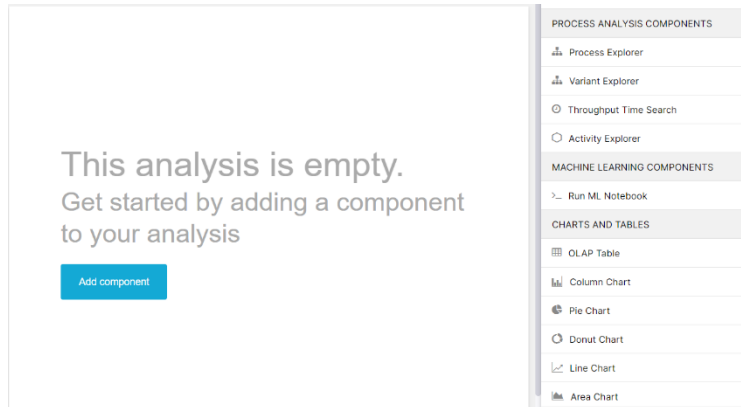


Obrázok 17: Procesná mapa

(Zdroj: Vlastné spracovanie)

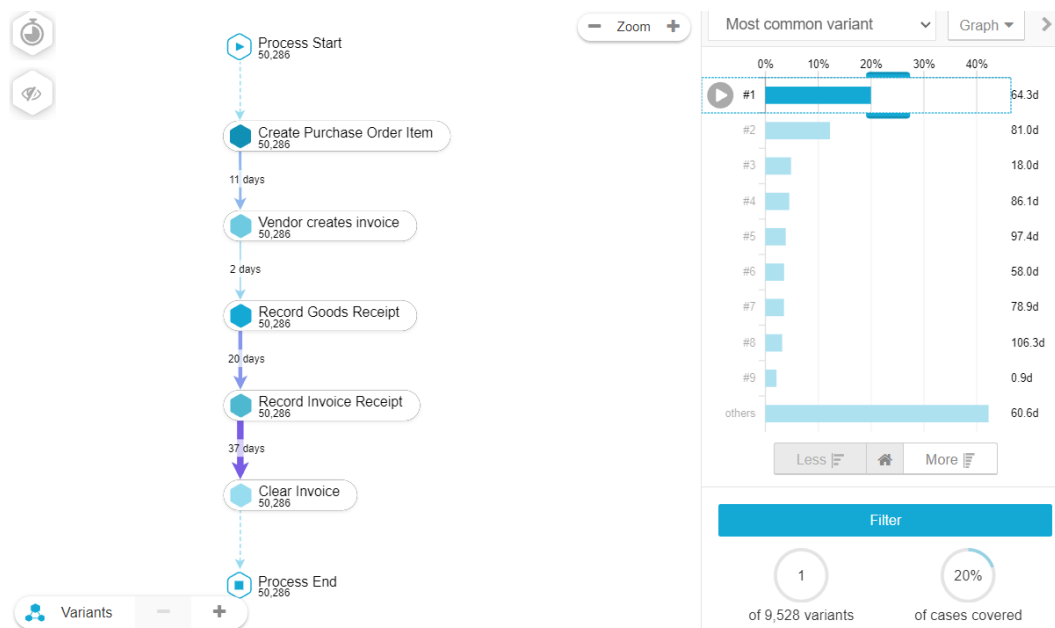
Discovery

Prvou vytvorenou analýzou bude Variant Explorer. Celonis poskytuje množstvo rôznych komponentov a analytických nástrojov na skúmanie procesného správania a jeho vizualizácie.



Obrázok 18: Celonis analýza

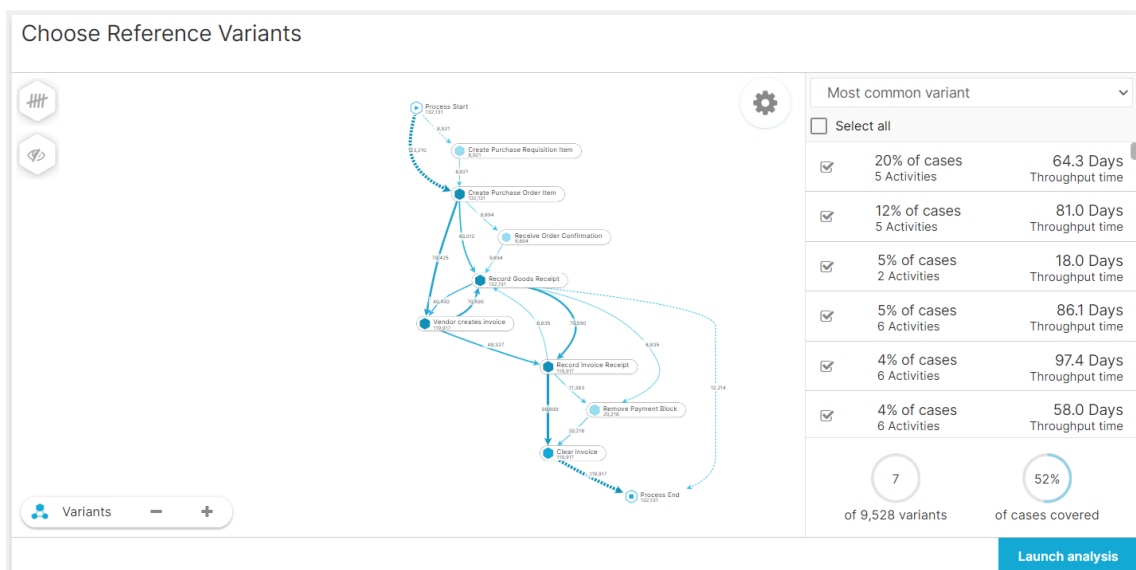
(Zdroj: Vlastné spracovanie)



Obrázok 19: Variant Explorer č. 1

(Zdroj: Vlastné spracovanie)


Analýza Variant Explorer poskytuje prehľad o najčastejšie sa vyskytujúcich variantách reálneho procesného modelu. Na obrázku je možné pozorovať procesný model, ktorý sa vyskytuje v logoch udalostí najviac. Model sa dá interaktívne upravovať pridávaním ďalších variantov alebo zobrazením každej varianty zvlášť. Konkrétny model uvedený vyššie zobrazuje chronologický prehľad fungovania procesu s vyznačenými hodnotami frekvencie daných prípadov. Medzi jednotlivými aktivitami je uvedený priemerný časový prechod z jednej aktivity na druhú. Do analýzy bolo vybraných prvých 7 najčastejšie sa vyskytujúcich variantov, ktoré dokopy pokrývajú viac ako polovicu všetkých prípadov.



Obrázok 20: Variant Explorer č. 2

(Zdroj: Vlastné spracovanie)

Procesný model vytvorený zo 7 najčastejšie sa vyskytujúcich variantov procesu.




Obrázok 21: Procesný model

(Zdroj: Vlastné spracovanie)

Conformance

Jedná sa o analýzu zhody, ktorá slúži na porovnanie modelovaného a pozorovaného správania. Pri conformance analýze bývajú často odhalené neoptimálne ad-hoc procesné zmeny, rôzne skratky a odbočenia od štandardného procesného toku. Keďže spoločnosť nedisponuje referenčným modelom definujúcim procesný tok, v tejto fáze bude využitý procesný model vytvorený vo Variant Explorer analýze.



Obrázok 22: Conformance analýza č. 1

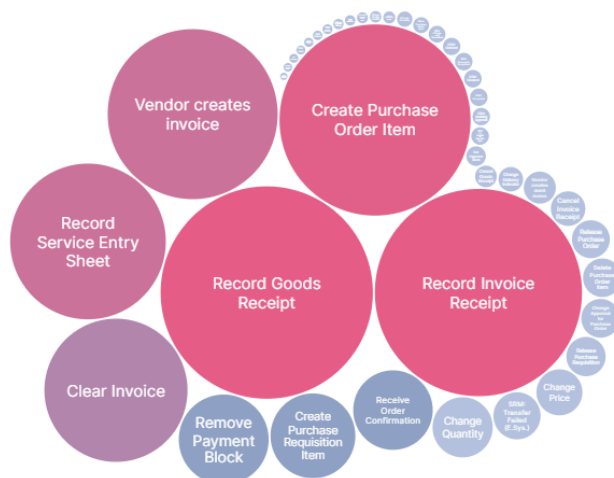
(Zdroj: Vlastné spracovanie)

Analýza zhody zistila, že 74% prípadov vyhovuje danému referenčnému modelu.

Avšak až 62 700 prípadov sa nezhoduje s referenčným modelom. Rozmanitejšie procesy ako Purchase to Pay nie sú definovateľné jednoduchým procesným modelom. Dôvodom môže byť napríklad rôznorodosť procesu párovania faktúr, či procesovania platby kvôli rôznym platobným metódam. Tieto procesy obsahujú množstvo aktivít, čo výrazne celý proces rozvetvuje.

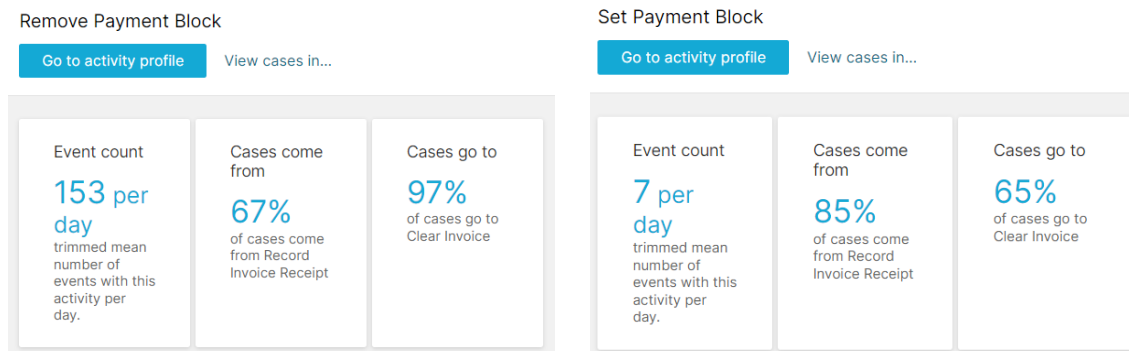
Počas analýzy zhody však boli objavené nežiadúce aktivity. Už na prvý pohľad vo vizualizáciách vyčnieva konkrétna často sa vyskytujúca aktivita – remove payment block. Táto aktivita sa vyskytuje aj v procesnom modeli vytvorenom v discovery fáze.

Vizuálny prehľad najčastejšie sa vyskytujúcich aktivít:



Obrázok 23: Vizualizácia aktivít

(Zdroj: Vlastné spracovanie)



Obrázok 24 a 25: Remove and Set payment block

(Zdroj: Vlastné spracovanie)

Aktivite remove payment block musí logicky predchádzať aktivita set payment block. Avšak aktivita Remove payment block sa vyskytla v prípadoch celkom 55 839 krát, zatiaľ čo set payment block iba 122 krát.




Obrázok 26 a 27: Remove and Set payment block počet prípadov
(Zdroj: Vlastné spracovanie)

Hlbšou analýzou bolo zistené, že významná časť prípadov obsahujúca aktivitu remove payment block obsahuje v zázname o vykonávateľovi aktivity hodnotu NONE. Ako bolo spomenuté skôr, hodnota NONE indikuje neprítomnosť záznamu o užívateľovi/vykonávateľovi aktivity. Manažment spoločnosti by mohol tieto skutočnosti preskúmať do hĺbky pomocou Root Cause Analýzy, na to je však potrebné detailné porozumenie konkrétneho P2P procesu a interných okolností. Pre účel tejto analýzy bude aktivita Remove Payment Block odstránená z procesného modelu.

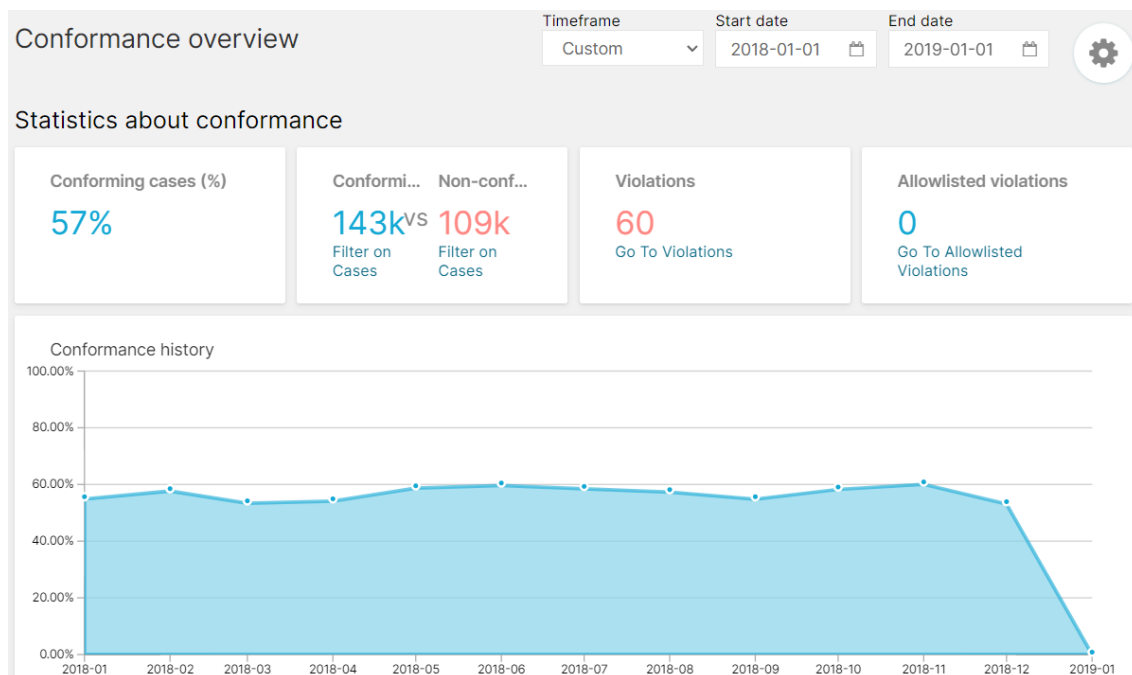
Enhancement

Referenčný model procesu vytvorený v Discovery fáze bude upravený na základe poznatkov získaných pomocou Conformance analýzy.

Upravený procesný model vyzerá nasledovne:



Obrázok 28: Referenčný model
(Zdroj: Vlastné spracovanie)



Obrázok 29: Conformance analýza č. 2

(Zdroj: Vlastné spracovanie)

Nový referenčný model sa zhoduje s 57% prípadov.

3.3.4 Zhodnotenie

V praktickom riešení bol aplikovaný koncept Process mining za účelom analýzy a poskytnutia podkladu na optimalizáciu procesu Purchase to Pay. Vo fáze Discovery bol vytvorený procesný model na základe procesných tokov zaznamenaných v logu udalostí. Následne boli vo fáze Conformance identifikované nedostatky a odchýlky tohto modelu. Fáza Enhancement odstránila konkrétny nedostatok z referenčného modelu a poskytla managementu spoločnosti návrh na bližšie preskúmanie zistenej problematiky. Pre mnohé spoločnosti predstavujú logy udalostí stále nevyužitý zdroj hlbšieho poznania procesnej výkonnosti, napriek svojmu nepopierateľnému potenciálu.

ZÁVER

Práca sa zameriava na problematiku optimalizácie podnikových procesov prostredníctvom strategického integrovania nástrojov Business Intelligence. Stanoveným cieľom bolo na základe analýzy využívania nástrojov Business Intelligence v maloobchodnom podniku identifikovať nedostatky a navrhnúť riešenie, ktoré poskytne podrobnejší pohľad na podnikové procesy a možnosti ich optimalizácie. Teoretická časť práce načrtla základné princípy Data Science, Process Science a Business Intelligence, ako hlavné východiská rozoberanej problematiky. Tie sa ďalej rozvetvovali na komplexnejšie koncepty ako Data Mining, Process Mining a Business Process Management. Praktická časť práce sa venovala predstaveniu maloobchodnej spoločnosti, jej organizačnej štruktúry a zhodnotením využívania nástrojov Business Intelligence. Zo zistených poznatkov vyplynuli značné nedostatky v dnes už bežne využívanom data-driven prístupe k riadeniu spoločnosti. Vo vlastnom návrhu riešenia boli vytvorené prehľadné a interaktívne reporty slúžiace ako podklad pre zhodnotenie obchodnej výkonnosti a manažérske rozhodovanie. Hlbšou analýzou prešiel aj konkrétny proces spoločnosti Purchase to Pay, ktorý bol analyzovaný pomocou metód Process Miningu.

ZOZNAM POUŽITEJ LITERATÚRY

1. SHAH, CHIRAG. *A Hands-On Introduction to Data Science*. Cambridge University Press, 2020. ISBN 978-1-108-47244-9.
2. NOVOTNÝ, Ota, Jan POUR a David SLÁNSKÝ. *Business intelligence: jak využít bohatství ve vašich datech*. Praha: Grada, 2005. Management v informační společnosti. ISBN 80-247-1094-3.
3. INMON, W.H. a Dan LINSTEDT. *DATA ARCHITECTURE: A PRIMER FOR THE DATA SCIENTIST Big Data, Data Warehouse and Data Vault*. Elsevier, 2014. ISBN 978-0-12-802044-9.
4. TEOREY, Toby J. *Database modeling and design: logical design*. 5th ed. Burlington: Morgan Kaufmann, c2011. Morgan Kaufmann series in data management systems. ISBN 978-0-12-382020-4.
5. CORONEL, Carlos a Steven MORRIS. *Database systems: design, implementation, and management*. 13e. Australia: Cengage, [2019]. ISBN 978-1-337-62790-0.
6. LACKO, Ľuboslav. *Databáze: datové sklady, OLAP a dolování dat s příklady v Microsoft SQL Serveru a Oracle*. Vyd. 1. Brno: Computer Press, 2003. ISBN 80-7226-969-0.
7. POUR, Jan; MARYŠKA, Miloš a NOVOTNÝ, Ota. *Business intelligence v podnikové praxi*. Praha: Professional Publishing, 2012. ISBN 978-80-7431-065-2.
8. ŠIMONOVÁ, Stanislava a Jan PANUŠ. *Databázové systémy I - Datová analýza: pro kombinovanou formu studia*. Vyd. 1. Pardubice: Univerzita Pardubice, 2005. ISBN 80-7194-811-X.
9. BHATIA, Parteek. *Data Mining and Data Warehousing: Principles and Practical Techniques*. Cambridge University Press, 2019. ISBN 978-1-108-72774-7.
10. HAN, Jiawei, Micheline KAMBER a Jian PEI. *Data Mining - Concepts and Techniques*. Third Edition. Elsevier, 2011. ISBN 978-0-12-381479-1.
11. PROVOST, Foster a Tom FAWCETT. *Data science for business*. Sebastopol: O'Reilly, 2013. ISBN 978-1-449-36132-7.

12. KOCH, Miloš a Bernard NEUWIRTH. *Datové a funkční modelování*. Vyd. 4., rozš. Brno: Akademické nakladatelství CERM, 2010. ISBN 978-80-214-4125-5.
13. DUMAS, Marlon, Marcello LA ROSA, Jan MENDLING a Hajo A. REIJERS. *Fundamentals of Business Process Management*. Second Edition. Springer, 2018. ISBN 978-3-662-56509-4.
14. VOM BROCKE, Jan a Michael ROSEMANN, ed. *Handbook on Business Process Management I*. Second Edition. Springer, 2015. ISBN 978-3-642-45099-0.
15. SAP. *Help Portal (Documentation)* [online]. [cit. 2024-01-02]. Dostupné z: https://help.sap.com/docs/SAP_BUSINESS_ONE/68a2e87fb29941b5bf959a184d9c6727/4505bc1f24a70489e10000000a155369.html
16. How to Classify Your Processes to Structure Your Business Process Architecture. In: *Viewpoint* [online]. [cit. 2024-04-24]. Dostupné z: <https://www.viewpoint.co.za/blog/how-to-identify-three-types-of-processes-in-your-organisation/>
17. SINHA, Tanmay. OLAP vs. OLTP: What's the Difference? In: *IBM* [online]. 2021 [cit. 2024-04-18]. Dostupné z: <https://www.ibm.com/blog/olap-vs-oltp/>
18. ŘEPA, Václav. *Podnikové procesy: procesní řízení a modelování*. 2., aktualiz. a rozš. vyd. Praha: Grada, 2007. Management v informační společnosti. ISBN 978-80-247-2252-8.
19. VAN DER AALST, Wil M. P. *Process Mining: Discovery, Conformance and Enhancement of Business Processes*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. ISBN 978-3-642-19345-3.
20. VAN DER AALST, Wil. *Process Mining - Data Science in Action*. Second Edition. Springer, 2016. ISBN 978-3-662-49850-7.
21. VAN DER AALST, Wil. *Process Mining, Data Science in Action* [online]. [cit. 2024-04-20]. ISBN 978-3-662-49851-4. Dostupné z: doi:10.1007/978-3-662-49851-4
22. VAN DER AALST, Wil M. P. *Process Mining Handbook* [online]. Springer, 2022 [cit. 2024-04-23]. ISBN 978-3-031-08848-3. Dostupné z: doi:10.1007/978-3-031-08848-3

23. Process Mining Manifesto. In: *Eindhoven University of Technology* [online]. 2011 [cit. 2024-04-19]. Dostupné z: <https://www.win.tue.nl/ieectfpm/downloads/Process%20Mining%20Manifesto.pdf>
24. VOM BROCKE, Jan, Wil MP VAN DER AALST, Thomas GRISOLD, et al. Process Science: The Interdisciplinary Study of Continuous Change. *SSRN Electronic Journal* [online]. 2021 [cit. 2024-04-10]. ISSN 1556-5068. Dostupné z: doi:10.2139/ssrn.3916817
25. VON ROSING, Mark, August-Wilhelm SCHEER a Henrik VON SCHEEL. *The complete business process handbook: body of knowledge from process modeling to BPM*. Waltham, MA: Morgan Kaufmann, [2015]. ISBN 978-0-12-799959-3.
26. What Is a Database? In: *Oracle* [online]. 2020 [cit. 2024-04-20]. Dostupné z: <https://www.oracle.com/database/what-is-database/>
27. Year-Over-Year (YOY): What It Means, How It's Used in Finance. In: *Investopedia* [online]. [cit. 2024-03-19]. Dostupné z: <https://www.investopedia.com/terms/y/year-over-year.asp>
28. What is Power BI? In: Microsoft [online]. 2024 [cit. 2024-04-28]. Dostupné z: <https://learn.microsoft.com/en-us/power-bi/fundamentals/power-bi-overview>
29. *2008 BPM and workflow handbook: methods, concepts, case studies and standards in business process management and workflow*. Editor Layna FISCHER. Lighthouse Point: Future Strategies, 2008. ISBN 978-0-9777527-6-8.
30. van Dongen, B. (2019). BPI Challenge 2019 (Version 1) [Data set]. 4TU.Centre for Research Data. <https://doi.org/10.4121/UUID:D06AFF4B-79F0-45E6-8EC8-E19730C248F1>
31. Sample - Superstore Sales (Excel).xls [online]. [cit. 2024-01-02]. Dostupné z: <https://community.tableau.com/s/question/0D54T00000CWeX8SAL/sample-superstore-sales-excelxls>
32. SAP. Help Portal (Documentation) [online]. [cit. 2024-01-02]. Dostupné z: https://help.sap.com/docs/SAP_BUSINESS_ONE/68a2e87fb29941b5bf959a184d9c6727/4505bc1f24a70489e1000000a155369.html

ZOZNAM OBRÁZKOV

Obrázok 1: Poddisciplíny data science (Zdroj: Van der Aalst, 2016)	13
Obrázok 2: Subdisciplíny Process Science (Zdroj: Van der Aalst, 2016).....	23
Obrázok 3: Životný cyklus BPM (Zdroj: Dumas, 2018).....	26
Obrázok 4: Pozícia Process Miningu (Zdroj: Van der Aalst, 2016).....	28
Obrázok 5: Typy Process Miningu (Zdroj: Process Mining Manifesto, 2011).....	30
Obrázok 6: Process Mining model (Zdroj: Van der Aalst, 2011).....	31
Obrázok 7: Dataset (Zdroj: Vlastné spracovanie).....	37
Obrázok 8: Dashboard č. 1 (Zdroj: Vlastné spracovanie).....	38
Obrázok 9: Dashboard č. 2 (Zdroj: Vlastné spracovanie).....	39
Obrázok 10: Dashboard č. 3 (Zdroj: Vlastné spracovanie).....	40
Obrázok 11: Dashboard č. 4 (Zdroj: Vlastné spracovanie).....	42
Obrázok 12: Dashboard č. 5 (Zdroj: Vlastné spracovanie).....	42
Obrázok 13: Dashboard č. 5, detail (Zdroj: Vlastné spracovanie)	43
Obrázok 14: Dataset (Zdroj: Vlastné spracovanie).....	45
Obrázok 15: Process overview č. 1 (Zdroj: Vlastné spracovanie)	46
Obrázok 16: Process overview č. 2 (Zdroj: Vlastné spracovanie)	47
Obrázok 17: Procesná mapa (Zdroj: Vlastné spracovanie)	47
Obrázok 18: Celonis analýza (Zdroj: Vlastné spracovanie)	48
Obrázok 19: Variant Explorer č. 1 (Zdroj: Vlastné spracovanie)	48
Obrázok 20: Variant Explorer č. 2 (Zdroj: Vlastné spracovanie)	49
Obrázok 21: Procesný model (Zdroj: Vlastné spracovanie).....	49
Obrázok 22: Conformance analýza č. 1 (Zdroj: Vlastné spracovanie).....	50
Obrázok 23: Vizualizácia aktivít (Zdroj: Vlastné spracovanie)	51
Obrázok 24 a 25: Remove and Set payment block (Zdroj: Vlastné spracovanie)	51
Obrázok 26 a 27: Remove and Set payment block počet prípadov (Zdroj: Vlastné spracovanie).52	

Obrázok 28: Referenčný model (Zdroj: Vlastné spracovanie).....	52
Obrázok 29: Conformance analýza č. 2 (Zdroj: Vlastné spracovanie).....	53