

# **Data mining**

## **Příprava projektu obchodně-analytického SW**

Bc. Jakub Šimůnek

---

Diplomová práce  
2018



Univerzita Tomáše Bati ve Zlíně  
Fakulta multimediálních komunikací

---

Univerzita Tomáše Bati ve Zlíně  
Fakulta multimediálních komunikací  
Ústav marketingových komunikací  
akademický rok: 2017/2018

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Jakub Šimůnek**  
Osobní číslo: **K16246**  
Studijní program: **N7202 Mediální a komunikační studia**  
Studijní obor: **Marketingové komunikace**  
Forma studia: **kombinovaná**

Téma práce: **Data mining: Příprava projektu obchodně-analytického SW**

Zásady pro vypracování:

1. V teoretické části definujte data mining v prostředí SME a proveďte rešerši (ne)veřejných zdrojů pro potřeby data miningu v oboru.
2. Stanovte cíle, metody a výzkumné otázky práce.
3. Charakterizujte vybranou společnost a strukturu využívaných dat pro její potřeby.
4. Na základě analýz sekundárních dat zhodnoťte aktuální podobu dostupných dat a navrhnete úpravy jejich struktury pro další využití. Pomocí kvalitativní analýzy zjistěte současná úzká místa využití data miningu v obchodním, marketingovém a personálním oddělení.
5. V rámci projektové části využijte získané informace a data pro přípravu komplexního projektu vytvoření druhé generace analytického softwaru společností včetně finanční a personální náročnosti, soustředte pozornost i na komunikaci projektu.
6. Formulujte závěry, limity a možnosti realizace projektu, odpovězte výzkumné otázky.

Rozsah diplomové práce:

Rozsah příloh:

Forma zpracování diplomové práce: **tištěná**

Seznam odborné literatury:

**Data mining and knowledge discovery handbook. 2nd ed. New York ; Dordrecht : Springer, 2010. xx, 1285. : ISBN 978-0-387-09823-4.**

**Petr, Pavel., Data mining / . Vyd. 2. Pardubice : Univerzita Pardubice, 2008-. sv. : ISBN 978-80-7395-098-9.**

**Novotny, Ota., Business intelligence : jak využít bohatství ve vašich datech / . 1. vyd. Praha : Grada, 2005. 254 s. : ISBN 80-247-1094-3.**

**Berka, Petr., Dobyvání znalosti z databází / . Vydání 1. Praha : Academia, 2003. 366 stran : ISBN 80-200-1062-9.**

**Nabareseh, Stephen. Predictive analytics: a data mining technique in customer churn management for decision making = Prediktivní analytika: technika data miningu pro rozhodování s využitím v řízení odchodu zákazníku : doctoral thesis summary / . Zlín : Tomas Bata University in Zlín, 2017. 40 stran : ISBN 978-80-7454-649-5.**

Vedoucí diplomové práce:

**Ing. Martina Juříková, Ph.D.**

Ústav marketingových komunikací

Datum zadání diplomové práce:

**31. ledna 2018**

Termín odevzdání diplomové práce:

**20. dubna 2018**

Ve Zlíně dne 3. dubna 2018

  
doc. Mgr. Irena Armutidisová  
děkanka



  
Mgr. Josef Kocourek, Ph.D.  
ředitel ústavu

## PROHLÁŠENÍ AUTORA BAKALÁŘSKÉ/DIPLOMOVÉ PRÁCE

Beru na vědomí, že

- odevzdáním bakalářské/diplomové práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, bez ohledu na výsledek obhajoby <sup>1)</sup>;
- beru na vědomí, že bakalářská/diplomová práce bude uložena v elektronické podobě v univerzitním informačním systému a bude dostupná k nahlédnutí;
- na moji bakalářskou/diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3 <sup>2)</sup>;
- podle § 60 <sup>3)</sup> odst. 1 autorského zákona má UTB ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- podle § 60 <sup>3)</sup> odst. 2 a 3 mohu užit své dílo – bakalářskou/diplomovou práci - nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- pokud bylo k vypracování bakalářské/diplomové práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tj. k nekomerčnímu využití), nelze výsledky bakalářské/diplomové práce využít ke komerčním účelům.

Ve Zlíně 18.4.2019

Jarob Šimůnek  
Jméno, příjmení, podpis

<sup>1)</sup> zákon č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů § 47b Zveřejňování závazných prací:

(1) Vysoká škola nevýdělečně zveřejňuje bakalářské, diplomové, disertační a rigorózní práce, u kterých proběhla obhajoba, včetně posudků oponentů a výsledku obhajoby prostřednictvím databáze kvalifikačních prací, kterou spravuje. Způsob zveřejnění stanoví vnitřní předpis vysoké školy. Vysoká škola disertační práce nezveřejňuje, byla-li již zveřejněna jiným způsobem.

(2) Bakalářské, diplomové, disertační a rigorózní práce odevzdané uchazečem k obhajobě musí být též nejmeně pět pracovních dnů před konáním obhajoby zveřejněny k nahlédnutí veřejnosti v místě určeném vnitřním předpisem vysoké školy nebo není-li tak určeno, v místě pracoviště vysoké školy, kde se má konat obhajoba práce. Každý si může ze zveřejněné práce pořizovat na své náklady výpisy, opisy nebo rozmnožiny.

(3) Platí, že odevzdáním práce autor souhlasí se zveřejněním své práce podle tohoto zákona, bez ohledu na výsledek obhajoby.

(4) Vysoká škola může odložit zveřejnění bakalářské, diplomové, disertační a rigorózní práce nebo jejich částí, a to po dobu trvání přezkoušky pro zveřejnění, nejdéle však na dobu 3 let. Informace o odložení zveřejnění musí být spolu s odůvodněním zveřejněna na stejném místě kde jsou zveřejňovány bakalářské, diplomové, disertační a rigorózní práce, již se týká odklad zveřejnění podle věty první, jeden výstisk práce k uchování v ministerstvu

<sup>2)</sup> zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů § 35 odst. 3:

(3) Do práva autorského také nezasahuje škola nebo školské či vzdělávací zařízení, u něhož nikoli za účelem přímého nebo nepřímého hospodářského nebo obchodního prospěchu k výuce nebo k vlastní vnitřní potřebě dílo vytvořené žákem nebo studentem ke splnění školních nebo studijních povinností vyplývajících z jeho právního vztahu ke škole nebo školskému či vzdělávacímu zařízení (školní dílo).

<sup>3)</sup> zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů § 60 Školní dílo:

(1) Škola nebo školské či vzdělávací zařízení mají ze obvyklých podmínek právo na uzavření licenční smlouvy o užití školního díla (§ 35 odst. 3). Odpírá-li autor takového díla udělit svolení bez vázání úřadu, mohou se tyto osoby domáhat nahrazení chybějícího projevu jeho vůle u soudu. Ustanovení § 35 odst. 3 zůstává nedotčeno.

(2) Není-li sjednáno jinak, může autor školního díla své dílo užit či poskytnout jinému licenci, není-li to v rozporu s oprávněnými zájmy školy nebo školského či vzdělávacího zařízení.

(3) Škola nebo školské či vzdělávací zařízení jsou oprávněny požadovat, aby jim autor školního díla z výdělku jim dosaženého v souvislosti s užitím díla či poskytnutím licence podle odstavce 2 přiměřeně přispěl na úhradu nákladů které na vytvoření díla vynaložil, a to podle okolností až do jejich skutečné výše; přitom se přihlídnou k výši výdělku dosaženého školou nebo školským či vzdělávacím zařízením z užití školního díla podle odstavce 1.



## **ABSTRAKT**

Cílem této diplomové práce je příprava projektu obchodně-analytického SW z pohledu data miningu. Práce se zabývá přístupnými daty v prostředí farmaceutického průmyslu, analyzuje současnou situaci a navrhuje, jakým způsobem je možné dostupná data využít pro zlepšení práce obchodních zástupců společností v terénu.

Práce je rozdělena do tří částí – teoretické, praktické a projektové.

V teoretické části jsou vysvětleny základní pojmy týkající se data miningu a CRM, nastoleny aktuálně používané metriky a přístupy k využití těchto dat.

V praktické části je představena společnost, pro kterou je SW vyvíjen, data, kterými disponuje a současné možnosti dostupné aplikace. Dále je proveden výzkum mezi zástupci společnosti zaměřený na novou verzi analytického SW.

Projektová část je shrnutím celého projektu a může být společností považována za programátorské zadání pro vývojářskou společnost.

Klíčová slova:

datamining, big data, CRM, databáze, farmaceutický průmysl, Google apps, Google refine, reporting, business intelligence, BI

## **ABSTRACT**

The aim of this thesis is the preparation of sales-analyst SW project in the field of data mining. Thesis search for available information in pharmaceutical industry, analyze current situation within company and propose ways in which should the data be used for enhancing work of sales representatives in field.

Thesis itself is divided in three main chapters – theoretical, practical and project.

In theory chapter the main keywords such as data mining and CRM are explained, same as the basic metrics and principles of using big data.

In practical chapter the company for which the SW is developer, available data and actual possibilities of application are introduced. Then there is a research between company's employees focused on new version of analytical SW.

Project part of the thesis focuses on resume of whole research, which could be used as assignment for developers.

Keywords:

Data mining, big data, CRM, database, pharmaceuticals, Google apps, Google refine, reporting, business intelligence, BI

Za spolupráci při vzniku této diplomové práce děkuji Ing. Martině Juřkové, PhD. za cenné poznatky a připomínky. Děkuji také společnosti AROMATICA CZ s.r.o. a jejím zaměstnancům za poskytnutí informací a součinnost při výzkumu pro potřeby této práce. A děkuji také své rodině a přítelkyni za trpělivost v době, kdy tato práce vznikala.

„Stay hungry, stay foolish“

- Steve Jobs

Prohlašuji, že odevzdaná verze bakalářské/diplomové práce a verze elektronická nahraná do IS/STAG jsou totožné.



# OBSAH

<b>ÚVOD.....</b>	<b>12</b>
<b>I TEORETICKÁ ČÁST.....</b>	<b>13</b>
<b>1 DATA JAKO TREND.....</b>	<b>14</b>
1.1 DEFINICE POJMŮ.....	15
1.1.1 Data mining.....	15
1.1.2 Big data.....	15
1.1.3 CRM.....	16
1.1.4 Reporting a Sales dashboard.....	17
1.2 ZDROJE DAT SME V PROSTŘEDÍ FARMACIE.....	18
1.2.1 Otevřené zdroje.....	18
1.2.2 Uzavřené zdroje.....	19
1.3 OBCHODNÍ A VÝKONNOSTNÍ METRIKY V PROSTŘEDÍ FARMACIE.....	20
1.3.1 Růst obrátu.....	20
1.3.2 Plnění cílů obrátu.....	21
1.3.3 Dosavadní prodeje.....	21
1.3.4 Výkonnost produktů / kategorií.....	22
1.3.5 Úspěšnost obchodníka.....	22
1.3.6 Kanibalizace produktů.....	23
1.3.7 Prodeje na obchodníka.....	23
1.3.8 Průměrná hodnota objednávky.....	24
1.3.9 Prodeje dle místa.....	24
1.3.10 Zbývající metriky.....	25
<b>2 DATAMINING A PRODEJE.....</b>	<b>26</b>
2.1 ANALÝZA NÁKUPNÍHO KOŠÍKU.....	27
2.2 PŘEDPOVĚĎ PRODEJŮ.....	28
2.3 PLÁNOVÁNÍ ON-SITE PODPORY.....	28
2.4 ZÁKAZNICKÁ LOAJALITA.....	29
<b>3 CÍLE, METODY A VÝZKUMNÉ OTÁZKY.....</b>	<b>30</b>
3.1 CÍLE VÝZKUMU.....	30
3.2 VÝZKUMNÉ OTÁZKY.....	31
3.3 METODY VÝZKUMU.....	31
<b>II PRAKTICKÁ ČÁST.....</b>	<b>33</b>
<b>4 PŘEDSTAVENÍ SPOLEČNOSTI.....</b>	<b>34</b>
4.1 ARODATA V0.1.....	35
4.2 ARODATA V1.....	36
4.3 ARODATA V1.5.....	36
4.4 ARODATA V1.9.....	37
<b>5 ZROJOVÁ DATA.....</b>	<b>39</b>

5.1	PHOENIX LÉKÁRENSKÝ VELKOOBCHOD S.R.O.....	39
5.2	ALLIANCE HEALTHCARE S.R.O. ....	40
5.3	PHARMOS A.S. ....	41
5.4	VIA PHARMA S.R.O.....	41
5.5	ZHODNOCENÍ STRUKTURY DAT.....	42
<b>6</b>	<b>ANALÝZA APLIKACE ARODATA.....</b>	<b>44</b>
6.1	PRŮZKUM VÝSLEDNÝCH POŽADAVKŮ .....	44
6.2	VYHODNOCENÍ PRŮZKUMU .....	45
6.2.1	Úvodní strana .....	45
6.2.2	Databáze obrátů lékáren.....	47
6.2.3	Databáze osobních obrátů a návštěv .....	48
6.3	KVALITATIVNÍ ANALÝZA DAT SPOLEČNOSTI .....	49
6.3.1	Kvalitativní analýza zdrojových dat.....	49
6.3.2	Kvalitativní analýza koncové databáze .....	51
6.4	ZÁVĚRY ANALÝZY A DOPORUČENÍ .....	54
<b>III</b>	<b>PROJEKTOVÁ ČÁST.....</b>	<b>55</b>
<b>7</b>	<b>ÚVOD K PROJEKTOVÉ DOKUMENTACI .....</b>	<b>56</b>
7.1	POPIS PROJEKTU .....	56
7.2	POPIS VÝCHOZÍCH BODŮ A EXISTUJÍCÍCH ZDROJŮ APLIKACE .....	57
7.3	TECHNOLOGICKÉ POŽADAVKY A ZÁKLADNÍ USE-CASES .....	59
7.3.1	Cílová skupina #1 – Obchodní manažer s PC .....	59
7.3.2	Cílová skupina #2 – Obchodní reprezentant s tabletem.....	60
7.3.3	Cílová skupina #3 – Pracovník marketingu/asistentka – PC .....	61
7.4	ÚPRAVA IMPLEMENTAČNÍHO ŘEŠENÍ VELKODISTRIBUČNÍCH DAT.....	62
7.5	IMPLEMENTACE PŮVODNÍCH DATABÁZÍ .....	65
7.6	PROTOTYP UŽIVATELSKÉHO ROZHRANÍ.....	67
7.6.1	Základní uživatelské prvky .....	67
7.6.2	Domácí obrazovka .....	68
7.6.3	Mapa odběratelů.....	70
7.6.4	Detail lékárny .....	71
7.6.5	Objednávkový formulář .....	72
7.6.6	Objednávkový formulář – velkodistribuce.....	75
7.7	IMPLEMENTACE DATABÁZE DO SYSTÉMU TŘETÍCH STRAN.....	76
7.8	ODHAD ČASOVÉ A FINANČNÍ NÁROČNOSTI, KOMUNIKACE PROJEKTU .....	76
7.8.1	Časová náročnost projektu .....	77
7.8.2	Finanční náročnost projektu .....	78
7.8.3	Komunikace projektu .....	79
	<b>ZÁVĚR .....</b>	<b>81</b>
	<b>SEZNAM POUŽITÉ LITERATURY.....</b>	<b>83</b>
	<b>SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....</b>	<b>87</b>

<b>SEZNAM OBRÁZKŮ .....</b>	<b>88</b>
<b>SEZNAM TABULEK.....</b>	<b>89</b>
<b>SEZNAM PŘÍLOH.....</b>	<b>90</b>

## ÚVOD

Diplomová práce se zabývá využitím data miningu v prostředí konkrétní malé společnosti, působící na poli výroby a distribuce přírodní kosmetiky a doplňků stravy. Jejím cílem je analýza aktuální situace na poli data miningu, dostupných dat společnosti a jejich aplikace.

V rámci výzkumné otázky se práce zaměřuje na definici data miningu pro prostředí malých společností, provádí rešerši (ne)veřejně dostupných strojově čitelných dat a představuje prostředí firmy a trh, na němž působí. V podkapitole metodiky shrnuje aktuální využívaná a další navrhovaná data a způsoby jejich analýzy.

Analytická část je věnována analýze aktuálního rozsahu dat společnosti, kriticky zhodnocuje jejich relevantnost (na kolik současné výstupy odpovídají realitě) a vymezuje kritické body využití dat společnosti.

Dále popisuje podobu a formát vstupních dat, které společnost aktuálně získává a zaměřuje se na praktické zkušenosti s přípravou dat na straně velkodistribucí, a implementací dat na straně společnosti.

Nakonec shrnuje způsob aktuálního využití dostupných dat z pohledu obchodního, marketingového, personálního a technického.

Součástí krátké projektové části bude příprava zadání projektu pro vytvoření druhé generace analytického software společnosti, zejména zadání základních funkcionalit importu dat (návrh zlepšení vazeb s cílem zvýšit relevanci dat) a exportu výsledků (návrh základních přehledových reportů s cílem snížit administrativní zátěž při sekundárním využití dat).

## **I. TEORETICKÁ ČÁST**

## 1 DATA JAKO TREND

Data jsou všude kolem nás. S rostoucí globalizací a možnostmi obyvatel země jsou to data, která ovlivňují budoucnost každé společnosti. Pokud má firma přežít, nemůže přijít pouze se zajímavým zbožím a dobrým marketingem. V době stále se zvyšující konkurence potřebuje mít pro zajištění svých obchodních aktivit správný data set, který je schopná správně využít ve prospěch svého marketingového oddělení. Největší společnosti se dnes nespolehají na náhodný výběr zboží zákazníky, ale díky věrnostním kartám jako je například Tesco Clubcard vědí, kdy si který zákazník přijde nakoupit to které zboží (Maksymiuk, 2015).

Konkrétní znalost zákazníka ovlivňuje pozitivním způsobem skladové hospodářství prodejen a řetězců. A to pouhým vědomím, že v chování zákazníků existují základní vzorce. Pokročilé zapojení AI změní pohled na oblast prodeje ještě zásadnějším způsobem, nejenže budou prodejci schopni odhadnout své zákazníky, naučí se díky umělé inteligenci předpokládat chování i těch, kteří v jejich obchodech ještě nenakoupili (Sinha, 2017).

Toto jsou fakta a předpoklady, která v současné podobě platí pro společnosti operující na internetu a které mají k datům přirozený přístup skrze chování (potenciálních) zákazníků ze svých internetových aplikací. Platí to také pro velké nadnárodní společnosti, které interní databáze budují dlouhodobě v rámci svých interních CRM systémů.

Jak je to ale s menšími společnostmi z kategorie SME? Tato diplomová práce se zaměřuje na využití otevřených a uzavřených dat ve společnostech, které doposud neměly tendenci nebo možnost svá data používat jinak než jako souhrn znalostí o zákaznících bez pokročilého vyhodnocování.

## 1.1 Definice pojmů

### 1.1.1 Data mining

*Data mining is the process of sorting through large data sets to identify patterns and establish relationships to solve problems through data analysis. Data mining tools allow enterprises to predict future trends.*  
(Rouse, 2017)

Definice podle serveru TechTarget.com jasně vysvětluje, co se pod pojmem data mining skrývá. Disciplína dolování dat je procesem, který třídí velké objemy dat za účelem hledání a identifikace vzorců a stanovení vztahů mezi daty. To vše za účelem vyřešení problémů skrze datovou analýzu. Nástroje dolování dat pomáhají společnostem předpovídat budoucnost.

Díky dolování dat tak můžeme hrubá data, na první pohled popisující pouze minulost (tj. fakta), použít k vytvoření modelů budoucího vývoje. Proces jako takový potom může sloužit mnoha účelům – vědci tyto modely používají například pro predikci globálního oteplování, politici pro vývoj jejich preferencí a společnosti, mimo jiné, pro odhad vývoje prodejů (Maderer, 2018).

### 1.1.2 Big data

Zatímco data mining je aktivita k zjištění vzorců a předpokládaného vývoje, big data je pojem směřující k samotnému základu data miningu – databázím obsahujícím hrubá data, nad kterými jsou modely tvořeny (Černý, 2013). Formát těchto dat je vždy kvantitativní a strojově zpracovatelný (tj. nejedná se o záznamy tvořené papírem a tužkou), zpravidla obsahuje časové údaje svého vzniku a definici lokality. Další podobnost mezi jednotlivými data sety jsou ale velice individuální. Zatímco při zkoumání globálního oteplování budou hlavními údaji teplota, chemické složení vzduchu a například měření ozonu v atmosféře pro jednotlivá měřící místa a časy měření, v případě sledování údajů o prodejích zmíněné Tesco Clubcard se bude jednat o název, množství a kategorii potraviny, čas nákupu a například také odhadovaný počet nakupujících osob podle množství nakupovaných produktů.

K jednomu účelu přitom nemusí být využíván pouze jeden data set big dat, ale zpravidla jde o kombinaci více vstupů, nad kterými se potom výsledné modely tvoří (De Mauro, 2016).

### 1.1.3 CRM

CRM neboli customer relationship management, je pojem vztahující se k prodejnímu/nákupčímu oddělení společnosti. V minulosti bylo možné představit si jej jako společný adresář odběratelů a dodavatelů, obsahující klíčové kontaktní údaje, historii společné komunikace a klíčové osoby druhé strany. Dnešní CRM umožňuje pokročilou správu společných projektů a úkolů, provázání na sociální sítě (nebo detailní informace o protistraně, znalost jejich zájmů a koníčků je klíčem k úspěšnějšímu jednání). (Papežová, 2004) Vývoj CRM lze v jednoduchosti ilustrovat na obrázku níže.



Obr. 1, Vývoj CRM systémů

Rychlý a podstatný vývoj vidíme nejen u CRM jako pojmu, který se z papírového adresáře (zkoumaná společnost, popisovaná v praktické části tento adresář ještě stále eviduje ve svých archivech) proměnil v počítačové a následně online nástroj, ale také v rámci vývoji CRM jako software samotného.

První náznaky privátních CRM systémů je možné v elektronické podobě najít u předchůdců dnešních chytrých telefonů – osobních asistentů neboli PDA značky Palm v roce 1997. Palm a jeho PalmPilot obsahovaly všechny nástroje, které umožňovaly (na svou dobu) veškeré řízení uživatelské agendy, včetně řízení vztahů se zákazníky v elektronické podobě (Palm.com, 1997). S rozmachem dalších výrobců PDA a následně MDA (skuteční předchůdci dnešních chytrých telefonů s možností být neustále online pomocí mobilních sítí) následoval Palm Microsoft se svým Microsoft Exchange Server, který z personálních CRM vytvořil elektronické celofiremní CRM systémy. Díky MES mohla celá společnost sdílet a filtrovat kontakty, informace k nim a později i zápisy ze společných jednání.



Díky stále se rozvíjícímu Microsoft Outlooku, který s každou další iterací získával další a další funkcionality, můžeme MES dodnes považovat za nejprůlomovější řešení CRM pro velké korporace.

S technologickým vývojem, kdy potřebu řešení obchodních kontaktů začaly řešit i společnosti menšího a středního rozsahu, pro které byla potřeba dedikovaného ME serveru a vlastních administrátorů systému překážkou.

V rámci SME tak dnes vedou hlavně cloudová řešení, jimiž zástupci jsou Google Apps for Work, Microsoft Office 365 for Business, případně méně robustní aplikace, mezi které můžeme zařadit Insightly.com, Zoho.com apod. (Williams, 2017)

#### 1.1.4 Reporting a Sales dashboard

Reportování je základem vykazování činnosti zaměstnanců. Historicky prvním systémem reportingu vykonané práce bychom mohli považovat evidenci odpracované doby, v moderním pojetí zastoupené „píchačkami“. Z pohledu managementu šlo o předávání podkladů k pracovní činnosti mezi nadřízeným a podřízeným v ústní či papírové formě.

S nástupem moderních technologií se pojem reporting značně rozrostl a v základních principech zrychlil a zjednodušil. „Píchačky“ byly nahrazeny elektronickými systémy přístupu, které evidují příchod zaměstnance současně s jeho bezpečným vpuštěním do prostor společnosti. Reporting prodeje se zjednodušil z papírových, a postupně elektronických, tabulek na elektronický systém zadávání prodeje minimalizující duplicitní zadávání dat. Zpracování dat se zmenšilo z ručního přepisování údajů do kontingenčních tabulek v tabulkových procesorech (Lymer, 2).

Sales dashboard, česky „prodejní nástěnka“ (nepoužívaný termín), je pojem podobně starý, jako reporting sám. V zásadě jde o místo (analogové nebo digitální), které poskytuje základní přehled o vývoji prodeje, počtu odběratelů a dalších ukazatelích. Oproti klasické tabulce prodeje se vyznačuje zaměřením na vizualizaci ukazatelů – nepracuje s čísly, ale grafy. Historicky se jednalo o papírové tabule, na které byly ručně dokreslovány informace o prodejích (týdenní, měsíční, kvartální), případně doplněné o predikce a cíle společnosti (Hetherington, 2009).

S elektronizací reportingu došlo k elektronizaci a automatizaci sales dashboardů a jejich přesunu do tabulkových procesorů a následně internetu. Nyní tak pod tímto termínem rozumíme přehledovou nástěnku agregovaných dat společnosti za účelem vizuální prezentace

stavu prodeje, plnění KPI, počtu oslovených odběratelů a dalších. Samotný dashboard má zejména kontrolní funkci pro nadřízené pracovníky, kteří pomocí něj jednoduše sledují práci svých podřízených. Pro podřízené pracovníky pak má primárně funkci pasivně motivační – v případě, že podřízený vidí, jak si stojí vůči svým kolegům, má podvědomě tendenci jejich prodeje dohnat nebo udržet vedení (Lymer, 44).

## 1.2 Zdroje dat SME v prostředí farmacie

Data jsou z podstaty základem jakéhokoliv dolování dat. Pro potřeby data miningu rozlišujeme data otevřená (open data) a uzavřená, získaná společnostmi či zakoupená od třetí strany.

### 1.2.1 Otevřené zdroje

Česká republika není etalonem e- a open-governmentu. Přesto, zejména díky Českému statistickému úřadu, poskytuje alespoň základní data ve strojově čitelné podobě (formáty XLS a CSV). Na stránkách czso.cz je poměrně snadné se základně zorientovat a dostat se do potřebných databází.

Pro potřeby základního data miningu a našeho dalšího zpracování jsou k dispozici kompletní sociodemografické údaje podle NUTS až po úroveň 5. Těmi jsou zejména počty obyvatel, rozloha území a HDP regionu NUTS (Czso.cz, 2018).

Dalším zdrojem užitečným pro datamining farmaceutické společnosti je registr lékáren SÚKL. Ten je k dispozici na webu sukl.cz a umožňuje stažení informací o všech aktuálně fungujících lékárnách na českém území. Kromě základních dat jako je adresa provozovny také doplňuje IČO provozovny, číslo SÚKL registrace a jména odpovědných osob (Sukl.cz, 2018).

Posledním relevantním zdrojem v oblasti farmacie jsou databáze firem soukromých společností jako je Seznam.cz nebo Google.com. Přestože tyto společnosti neumožňují přímé stažení podkladů o uložených firmách formou strojově čitelných dat, díky technice zvané scraping, která, zjednodušeně řečeno, provádí automatizované hledací dotazy, jejichž výsledky následně ukládá ve formě tabulky, je možné i z těchto zdrojů získat základní data, která potřebují pouze zběžnou kontrolu.

**Systematické zařazení zdrojů dat:**

1. Český statistický úřad – [www.czso.cz](http://www.czso.cz) – základní sociodemografické údaje o státu, krajích, okresech a obcích ve smyslu obyvatelstvy, nezaměstnanosti a HDP
2. Česká pošta – [www.cpost.cz](http://www.cpost.cz) – informace o PSČ, použitých pro zařazení obcí do logických celků jednotlivých regionů
3. Státní ústav pro kontrolu léčiv – [www.sukl.cz](http://www.sukl.cz) – informace o odběratelích s povolením pro prodej farmaceutických prostředků (typicky lékáren, OOVL a lékárenských e-shopů)
4. Google/Seznam – [www.google.cz](http://www.google.cz), [www.seznam.cz](http://www.seznam.cz) – informace o ne-farmaceutických odběratelích (typicky zdravých výživách a prodejnách zdravé stravy)

### 1.2.2 Uzavřené zdroje

Mezi uzavřené zdroje počítáme takové databáze, které jsou neveřejné. To mohou být databáze třetích stran dostupné za úplatu nebo měsíční poplatek (tyto data nabízí například společnost Datová agentura INFOPHARM s.r.o. ve formě strukturované databáze lékáren s dalšími doplněnými údaji), data získaná z velkoobchodních vztahů na základě smlouvy o spolupráci (mezi ně patří například data o prodejích poskytované velkodistribucemi), nebo data, které společnost získá vlastní prací např. obchodních zástupců v terénu.

Obecně lze, alespoň ve farmaceutickém průmyslu, říct o datech získaných od třetích stran, že jsou pro potřeby data miningu daleko lépe strukturovaná.

#### Systematické zařazení zdrojů dat:

1. Velkodistributoři farmaceutického zboží (PHOENIX lékárenský velkoobchod, s.r.o., Alliance Healthcare s.r.o., Pharmos a.s., ViaPharma s.r.o.) – informace o konkrétních prodejích výrobků společnosti na konkrétní odběratele
2. Data Agentura INFOPHARM s.r.o. – [www.infopharm.cz](http://www.infopharm.cz) – agregované informace o lékárnách na základě hodnocení prodejů 60+ spolupracujících společností (výkonost lékárny, trend obrátů lékárny)
3. PHARMDATA s.r.o. – [www.pharmdata.cz](http://www.pharmdata.cz) – detailní informace o všech výrobcích registrovaných pro prodej přes farmaceutické velkodistributory
4. Vlastní data získaná společností

### 1.3 Obchodní a výkonnostní metriky v prostředí farmacie

Pro vytvoření CRM systému 21. století nestačí pouze vhodně získat kontakty a výkonnostní data k nim. K tomu, abychom byli schopní využít CRM systém nejen pro zjištění faktů, ale pro relevantní odhalení problémů a příležitostí, potřebujeme znát metriky, podle kterých budeme data porovnávat a které budeme zobrazovat na Sales dashboard případně v dalších dílčích reportech.


O metrikách mluvíme v prostředí nastavování a sledování cílů jako o KPI = Key Performance Indicators. V rámci sales dashboard budeme tyto přepočítané hodnoty porovnávat proti ostatním členům týmu anebo proti zadaným cílům, které stanovila společnost, respektive obchodní manažer.

Zjednodušeně lze metriky rozdělit na přímé a nepřímé. Přímé metriky jsou ty, u nichž lze s jistotou říct, že jejich zvyšování zvyšuje výkon obchodních reprezentantů a zlepšuje výsledky společnosti. V naší zkrácené prohlídce světa obchodních metrik najdeme pouze jednu přímou metriku – zisk v korunách (resp. jiné měně). Jestliže má firma jasně stanovené přímé a nepřímé výdaje na jeden prodaný kus produktu, pak je zisk nejvyšší možnou metou hodnotícího systému. Ve většině případů je však přesné stanovení nepřímých výdajů složité, respektive nemožné, a proto čistý zisk obchodních reprezentantů používá spíše jako pomocná metrika a většina ostatních metrik používá jako vstup obrat obchodního zástupce.

Podle Katyi Zeisig z Dalhousie University, která pracuje pro společnost Klipfolio, vytvářející aplikaci pro provoz metrik nad vlastními daty, můžeme v současné době vysledovat 12 nejpoužívanějších KPI, která se u většiny společností opakují. (Zeisig, 2017)

#### 1.3.1 Růst obratu

Porovnáním obrátů YTD (=Year to date) získáváme představu o výkonnosti a úspěšnosti obchodního týmu v meziročním měřítku. Základním měřítkem všech společností je totiž růst. Metrika jednoduše porovnává obraty za posledních 12 měsíců s těmi předchozími. Submetrikou pak je metrika porovnávající MTD (=Month to date), která porovnává obraty pouze meziměsíčně. Je ovšem více volatilní a vzhledem k obecně zažitě představě „jednoho obchodního roku“ méně vypovídající.




Obr. 2, Graf růstu obratu

### 1.3.2 Plnění cílů obratu

V situaci, kdy má obchodní tým jasně stanované obrátové cíle (ať už osobní nebo celkové), může jeho práci pomoci sledování úroveň naplňování jeho cílů. V této metrice poměrujeme současný obrat za prozatímní část roku s přepočtem cílového obratu k tomuto datu. Například pokud má obchodní reprezentant za cíl splnit celkový obrat 12 000 000 Kč za rok, je mu v grafu vyznačena na konci března hodnota 3 000 000 Kč jako jeho předpokládaného obratu a současně hodnota jeho skutečného obratu.


Současně může být cílem absolutní počet uzavřených obchodů za dané časové období obchodním reprezentantem (tj. bez ohledu na počet návštěv)



Obr. 3, Graf plnění cílů

### 1.3.3 Dosavadní prodeje

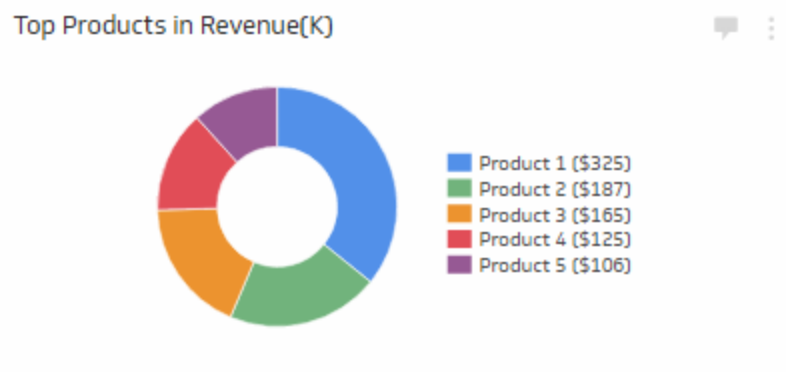
Rychlá analýza srovnává (většinou měsíční) agregaci prodejů jednoho obchodního reprezentanta proti ostatním nebo proti svému stínu (tj. vývoji svých prodejů v minulém měsíci nebo stejném měsíci minulého roku). Tato metrika je především motivační, ukazuje obchodnímu reprezentantovi, že „to šlo“, případně že si vede nad očekávání a má své tempo udržet.



Obr. 4, Graf růstu dosavadních prodejů

### 1.3.4 Výkonnost produktů / kategorií

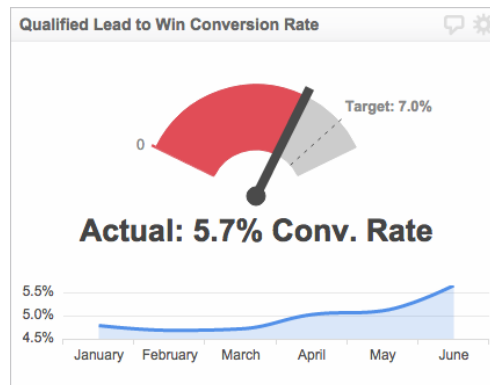
Obchodníci se většinou nezabývají pouze jedním produktem, ale celým sortimentem společnosti. Zeisigová ve své práci navrhuje běžný koláčový graf rozložení prodejů do produktů, respektive kategorií. Já naopak doporučuji jít dále a použít pavučinový graf, ve kterém budou zaneseny prodeje za předchozí období – to umožní obchodnímu zástupci lépe pochopit hrozby a příležitosti, které se v jeho aktuálních prodejích nachází. Snadno tak může přijít na to, že některou kategorií nevědomě opomíjí a zaměřit se na ni.



Obr. 5, Graf prodejů po kategoriích

### 1.3.5 Úspěšnost obchodníka


Metrika, která hodnotí obchodníka skrz jeho úspěšnost v dosažení objednávky. Poměruje počet uskutečněných jednání proti počtu uskutečněných objednávek. Může být také spojená se zadaným výkonnostním cílem.



Obr. 6, Graf konverzního poměru

### 1.3.6 Kanibalizace produktů


Tato metrika se navzdory svému názvu nezabývá kanibalizací různých variant produktu mezi sebou, ale zaměřuje se na novinky versus starší produkty v portfoliu. Prodat novinku je ve většině případů u zavedených zákazníků lehčí, než prodat „starý známý“ produkt, který již ve svém sortimentu obchodník měl. Proto mají obchodní reprezentanti tendenci zaměřovat se spíše na novinky a starý sortiment upozadřovat. Výsledkem často bývá, že společnost, i přes rozšíření portfolia směrem, kde nové produkty svým určením nemohou kanibalizovat ty staré, nenavýšuje svůj obrat. Tato metrika, která cílí na obchodní reprezentanty, se snaží tento problém odhalit a cíleně jej eliminovat, když porovnává prodeje novinky a původního sortimentu.



Obr. 7, Graf kanibalizace starých produktů

### 1.3.7 Prodeje na obchodníka


Jednoduchá metrika porovnávající měsíční prodeje obchodníků mezi sebou. Je možné do její vizualizace zapojit cíl měsíčních prodejů pro další motivaci práce obchodního reprezentanta. Z vlastní zkušenosti autor doplňuje, že je k této metrice přistupovat s obezřetností, jelikož pro velmi motivované obchodníky slabších regionů může být tato metrika spíše demotivační.



Obr. 8, Graf prodejů dle obchodníků

### 1.3.8 Průměrná hodnota objednávky

Dle Zeisigové jedna z nejefektivnějších metod, jak sledovat práci obchodníků a pomáhat jim zlepšovat svou práci. Sleduje a porovnává počet prodejů a hodnotu obchodů obchodního reprezentanta v korunách (či jiné měně) a vizuálně zdůrazňuje pokles nebo růst ve sledovaném období.

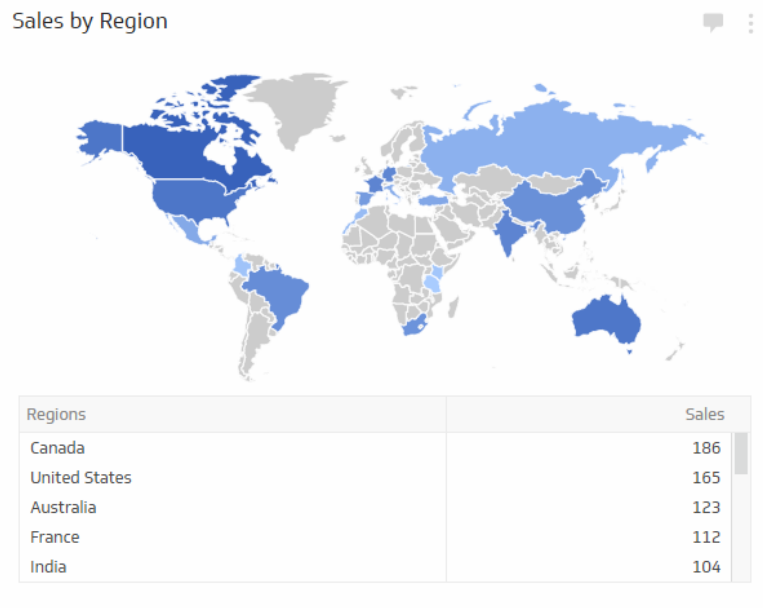


Obr. 9, Graf hodnoty objednávky

### 1.3.9 Prodeje dle místa

Metrika sleduje prodeje dle míst (států, krajů, okresů, měst, ...) a sdružuje je do jednotlivých celků. Pomáhá odhalit silná a slabá místa v regionu obchodního reprezentanta tak, aby věděl, na které oblasti svého regionu nasměrovat svou pozornost. Je možné z ní vyjít a do srovnání přidat poměrové hodnocení dle počtu lékáren nebo počtu návštěv či objednávek pro další zlepšení informovanosti obchodního zástupce.





Obr. 10, Graf prodeje dle regionu

### 1.3.10 Zbývající metriky

Vedle výše uvedených devíti metrik Zeisig uvádí metriky:

- Využívání příležitostí – Sledování uzavřených případů proti otevřeným příležitostem
- Vyskladňovací poměr – sledování úspěšnosti obchodníků včas vyskladňovat zásoby ve skladu
- Délku obchodního případu – jak dlouho trvá obchodníkovi uzavřít obchod se potenciálním klientem

Vzhledem k irelevanci použití těchto metrik ve farmacii jsou tyto metriky ze seznamu vypustil a dále s nimi nebude pracováno.

## 2 DATAMINING A PRODEJE

Znalost zákazníka je mantrou napříč všemi obory zabývajícími se (nejen) odbytem. Z pohledu marketérů to byly nejprve cílové skupiny, transformující se v posledních letech do person – univerzálních, leč velmi detailně zpracovaných profilů jednotlivců, na které se reklamou snaží zapůsobit. SEO a retargeting, poslední velké techniky, které zahýbaly světem (internetové) reklamy jsou vlastně data miningem v praxi. Druhá zmiňovaná se pak díky CRM dostává do světa off-line prodeje – kupující projeví zájem o produkt, ale v poslední chvíli z objednávky sejde z některého z běžných důvodů (vysoká cena, špatné aktuální finanční podmínky kupujícího atd.). Při příští off-line návštěvě pak obchodní reprezentant díky znalosti předchozích jednání retargetuje – přijde s upravenou nabídkou, slevou, zárukou za prodej zboží, či jakýmkoliv jiným argumentem, který mu má pomoci překonat počáteční nejistotu kupujících (Columbus, 2016).

Z čistě obchodního pohledu potom nemusíme chodit daleko a můžeme se zastavit u zlínského podnikatele Tomáše Bati a jeho výroku „náš zákazník, náš pán“. Sám Baťa také poznamenal, že „dobrý obchod je takový, kde jsou spokojení všichni zúčastnění“.

Zákazník je náš pán a my z toho důvodu musíme dělat vše proto, abychom mu prodali co nejvíc, ale aby to byl nakonec on, kdo se bude cítit spokojený. Touto parafrází se dá zjednodušeně popsat nejdůležitější vliv data miningu v oblasti prodeje. Dolování dat nám v tomto případě neslouží k nalezení skulin, jak zákazníkům podstrčit více produktů, které mu pak budou ležet doma (v případě koncových zákazníků) nebo v regálu (v případě maloobchodníků). Data mining nám slouží k zjištění potenciálu zákazníka a k odhalení možností, které nám spolupráce s ním nabízí tak, aby to byl zákazník, který si spolupráci s naší společností bude pochvalovat.

To je zásadní rozdíl oproti původním přístupům ke zlepšování prodejních dovedností, které prodejce v zásadě učily, jak prodat to, co zákazník nechce. V dnešní vysoce konkurenční době, kdy i sebemenší trhy obsahují vysoké procento konkurence a kdy je změna dodavatele pro odběratele velice jednoduchá, je pro obchodníky důležité budovat dlouhodobě stabilní a oboustranně prospěšné vztahy. Jak píše Herbert Edelstein ve své knize *Introduction to Data Mining and Knowledge Discovery*, data mining skvěle slouží ke zvyšování retence zákazníků a k rekonfiguraci produktu tak, aby dosahoval vyššího zisku a obrátů a zmenšení ztrát způsobených špatnými nabídkami a chybami.

Data mining ovšem neslouží pouze k odhalení potenciálu odběratelů. Jak Edelstein zmiňuje dále, pokročilý data mining pomáhá odhalit cenové potenciály kupujících a přizpůsobit jim konečnou cenu tak, aby obě strany byly spokojeny. Modelový příklad z lékárenského trhu mohou být dvě lékárny, které mají standardně nastavenou odlišnou maloobchodní marži (například 25 a 20 procent), ale *ceteris paribus* netrvají na nejnižší výsledné ceně. V případě jednotné tržní ceny produktu nakoupí za shodnou cenu a druhá lékárna bude zboží ve výsledku prodávat zboží s nižší koncovou cenou, přestože to nebylo jejím cílem. V případě, že oběma lékárnám nabídne společnost odlišnou kupní cenu, která svým rozdílem vyrovná rozdíl v maržích 5procentních bodů, bude konečná cena pro zákazníka shodná, a i druhá lékárna bude spokojená, protože prodává zboží za průměrnou tržní cenu a společnost na tom díky znalosti svých zákazníků získá nejvyšší potenciální zisk.

Neil Patel, mimochodem účastník prvního ročníku českého Marketing Festivalu, spoluzakladatel Neil Patel Digital, navrhuje 10 základních metrik, jejichž realizaci je schopná zjistit většina firem kategorie SME s tím, že většinu dat tyto firmy již dávno mají. Ty z nich, které jsou relevantní pro společnosti ve farmaceutickém průmyslu jsou představeny níže.

## 2.1 Analýza nákupního košíku

Analýza částečně zmiňovaná v úvodu diplomové práce může být aplikována nejen na zákazníky supermarketů, ale můžeme ji použít i na obchodní partnery – velkoobchodní partnery. Z pohledu data miningu je možné zjistit clustery, podobné skupinky zákazníků, a na jejich základě upravit nabídku konkrétním odběratelům. Zjednodušeně řečeno – pokud víme, že statisticky vysoké procento zákazníků pravidelně odebírá výrobky A, B, C a D a pošleme obchodního zástupce k odběrateli, který odebírá výrobky A, C a D, existuje vysoké procento pravděpodobnosti, že odběratel akceptuje nabídku na odběr výrobku B a bude s ním spokojen (Han, 2012, s. 244).

Analýza nákupního košíku nám může pomoci i v daleko jednodušší podobě – ostatně e-shopy tuto techniku používají již dlouhou dobu. Z prodejních dat není nutné zjišťovat pokročilé clustery zákazníků – je možné jednodušeji a rychleji zjistit clustery produktů. Pokud se dva a více produktů prodávají často dohromady, je možné patřičným způsobem upravit prezentaci (osobní, nebo telefonickou), se kterou obchodní reprezentanti na maloobchodní prodejny přicházejí. Vhodná návaznost produktů napříč sortimentem může opět zvýšit pravděpodobnost prodeje větší šíře portfolia.

A naopak – tato technika může jít ještě hlouběji a neporovnávat informace jako plochá data. Existují zákazníci, kteří si určitý čas po zakoupení produktu X zakoupí automaticky a bez pobízení produkt Y? Pokud ano, pak společnost pro produkt Y nemusí tvořit slevové akce a zvýší svou marži.

## 2.2 Předpověď prodeje

Křišťálová koule je od pradávna jedním z nesplněných vánočních přání mnoha obchodníků – výrobců i prodejců. Schopnost odhadnout, kolik přesně kusů zboží je potřeba vyrobit, či nakoupit pro uspokojení poptávky zákazníků, je jedním z nejsložitějších posláních plánovačů výroby a nákupu. I to, že obchodník všechno zboží nakonec prodá, neznamená, že bylo výrobní/nákupní plánování úspěšné. Cashflow společnosti je nekompromisní a ovlivňuje ekonomiku firmy, i situaci obchodního zástupce vůči maloobchodníkovi. Pokud obchodní reprezentant neodhadne reálné možnosti obchodníka, a přesto ho přesvědčí, že má odebrat určitý objem zboží, které potom „leží“ v regálech maloobchodníka, ovlivňuje to jeho vyjednávací pozici při dalších jednáních, kdy maloobchodník dostává do ruky protiargument, že „vašeho zboží zde má ještě dost“. A to i v případech, kdy obchodní reprezentanti přichází s nabídkou zcela odlišného sortimentu.

Obchodní reprezentant by proto měl být schopný, v případě že je vybaven dostatečnými daty a informacemi, odhadnout schopnosti maloobchodníka a optimalizovat svou nabídku tak, aby při své příští návštěvě byla většina zboží již odprodaná, a on mohl použít pozitivní argumentaci o dobře prodejném zboží.

V případě skutečné předpovědi prodeje se jedná zejména o průběžnou korekci prodeje konkrétních výrobků na trhu a násobení minulých prodeje maloobchodníka tímto koeficientem.

## 2.3 Plánování on-site podpory

Znalost pohybu zboží na maloobchodu nejen formou sell-in, tedy nákupu, ale dolováním dat zpracovaný odhad sell-out, odporeje, umožňuje společností lépe plánovat dodatečnou podporu prodeje na místě.

V případě, že obchodní reprezentant na základě odhadovaného sell-outu lékárny odhalí problémové zboží, může odběrateli nabídnout některou z možností, jak zboží v jeho obchodě pomoci – ať už přímou podporou ve formě promoakce, letákovou akci, nebo nepřímo pomocí dodatečných rabatů za účelem ponížení původní prodejní ceny. To může majitel využít

bud' pro snížení ceny pro koncové zákazníky, nebo naopak pro zvýšení motivační složky pro magistry a farmaceuty.

## 2.4 Zákaznická loajalita

Jak bylo řečeno v úvodu této kapitoly – v době stále rostoucí konkurence a minimálních nákladech na přechod k jinému dodavateli, je budování zákaznické loajality jedním z předních cílů obchodních reprezentantů.

Kissmetrics ve svém článku zmiňují z pohledu maloobchodu zejména Lifetime Customer Value, tedy hodnotu, kterou zákazník přinese společnosti během doby spolupráce, a která umožňuje lépe optimalizovat náklady na získání zákazníka.

Z pohledu obchodních zástupců a plánování jejich práce je pro obchodního manažera důležité znát, bez jakýchkoliv předchozích obchodních styků s potenciálním odběratelem, jak moc času má věnovat obchodní reprezentant na jeho přesvědčení ke spolupráci. Zda se má ještě snažit čtvrtou návštěvou zlomit rozhodnutí (anebo nerozhodnost) majitele nespolupracovat, anebo zda má raději hledat možnosti navázání nových obchodních styků někde jinde.

Stejně důležitá je i optimalizace počtu návštěv u dobrých a loajálních zákazníků. Loajalitu totiž buduje nejen pravidelný kontakt, ale i umožnění druhému „vydechnout“. Obchodníci mají někdy ve zvyku být se zákazníkem v příliš častém kontaktu, jelikož to pro ně je VIP zákazník. Svůj čas potom nevěnují novým nebo „horším“ zákazníkům, které by mohli častější návštěvou oslovit a vytvořit z nich své nové VIP klienty. Datamining na základě dat o kontaktech a obratech umí podat vysvětlení, nakolik je obrat zákazníka ovlivněn četností návštěv obchodního reprezentanta. Umí také poskytnout statistické informace o kolik klesne obrat maloobdberatele, pokud s ním bude obchodní reprezentant v kontaktu pouze jednou za 2 týdny namísto jednou týdně a zároveň o kolik vzroste obrat u jiných lékáren, u kterých zvýší četnost z jedné návštěvy za 2 měsíce na jednu návštěvu za měsíc.

### 3 CÍLE, METODY A VÝZKUMNÉ OTÁZKY

V rychle se rozvíjející (národní) společnosti přestává pro fungování (soukromé) společnosti stačit metoda „tužky a papíru“. Zatímco dříve, v době o poznání pomalejší, byl obchod zejména o navazování funkčních a dlouhodobě udržitelných vztahů s odběrateli, dnešní doba si žádá detailní znalost prostředí a potenciálu jednotlivých prodejců.

Obchodním zástupcům již nestačí využívat informace uložené v hlavě. V terénu potřebují mít neustále k dispozici veškeré dostupné informace o svých obchodních partnerech, a proto všechny společnosti postupně přecházejí na vlastní nebo krabicové systémy CRM, pomáhající jejich obchodním reprezentantům v terénu.

#### 3.1 Cíle výzkumu

Cílem tohoto výzkumu je příprava projektu pokročilé verze CRM pro potřeby obchodních reprezentantů v terénu. Její základ vychází ze současného systému Arodata, který společnost v současné době využívá, ale bere si za cíle eliminovat problémy, které současný systém neřeší.

Výsledkem práce tedy je zadání vhodné pro předání programátorům s cílem vytvoření software podle získaných poznatků a dat.

##### **Díličními cíli práce jsou:**

- Zvýšení úrovně vyhodnocování dat společností.
- Zkvalitnění a zpřesnění reportovaných dat.
- Zvýšení úrovně prodejních dat poskytovaných obchodním reprezentantem.

**Pre-analýzovou byly vyhodnoceny základní (předpokládané) problémy, se kterými se bude výzkum zabývat. Těmi jsou:**

- Nejednoznačnost získávaných dat
- Zdvojování seznamu odběratelů na základě nedokonalého určení odběratele systémem.
- Složitost současného systému pro hlubší analýzu při využívání laickým uživatelem.

### 3.2 Výzkumné otázky

Odvozením od tří dílčích cílů práce, kterým se budeme věnovat primárně, získáváme otázky, které budou pro mou práci nejkritičtější.

- Jaké informace jsou nejdůležitější pro jednotlivé úrovně managementu?
- Zisk jakých informací tvoří největší překážku ke zvýšení relevance reportů?
- Jak zlepšit UX a UI software a zpřístupnit tak relevantní data v co nejširší formě i méně technicky zdatným uživatelům?

První dvě můžeme označit za analytické, zabývající se relevancí dat a důležitostí jednotlivých výzkumů dat pro jednotlivé pozice ve společnosti. Třetí výzkumná otázka se zabývá UX aplikace a zkoumá, zdali je aplikace přístupná i méně počítačově zdatným uživatelům, popřípadě jak největší neduhy odstranit a proměnit ve výhodu.

### 3.3 Metody výzkumu

Pro výzkum jednotlivých výzkumných podotázek byly zvoleny částečně rozdílné metody. Jako nit se všemi otázkami vine metoda řízeného rozhovoru. Zkušenost s prací v systému a znalost jeho slabých míst je alfou a omegou tohoto výzkumu. Klíčoví zaměstnanci firmy se jsou v rámci kvalitativního výzkumu dotazováni na podstatné informace, které z aplikace získávají a na způsob jejich další práce s nimi (např. využití kontingenčních tabulek v Excelu). Stejně tak se práce zajímá o problémová místa databáze, tj. zda existují informace, které aplikace v současné době neposkytuje, anebo poskytuje pouze s nízkou úrovní relevance. Všichni dotazovaní zaměstnanci mají s aplikací dlouholeté zkušenosti, a proto bude jejich názor užitečný také z pohledu přístupu k UX a UI aplikace. Mezi dotazovanými jsou jak pracovníci z kanceláří, tak lidé z terénu, přičemž obě skupiny lidí k aplikacím přistupují z jiných zařízení (PC versus tablet) a v jiných situacích.

V otázce kvality dat pak práce provádí kvalitativní analýzu současných dat a jejich relevance a pokouší se spolu s odpovědnými osobami navrhnout a evaluovat možné upravené modely importu dat společnosti formou brainstormingu.

Uživatelské rozhraní je silně odbornou záležitostí a jen tato samotná otázka by byla schopna vydat na celou diplomovou práci. Věnovat se mu tedy bude pouze okrajově se zaměřením na ty nejdůležitější části celé aplikace. Vedle řízeného rozhovoru bude zdrojem informací zejména současný proud přístupu k UX – odborné internetové zdroje spolu s řešerší cizích

CRM systémů, které mohou, vzhledem k omezeným zdrojům na vlastní celkovou studii UX, posloužit jako mustr základních prvků.



## **II. PRAKTICKÁ ČÁST**

## 4 PŘEDSTAVENÍ SPOLEČNOSTI

Pro tuto diplomovou práci byla vybrána společnost AROMATICA CZ s.r.o.. Rodinná firma ze Šlapanic u Brna se již 26. rokem věnuje výrobě doplňků stravy a přírodní kosmetiky. Její aktuální portfolio čítá přes 80 produktů, které vyrábí pod značkami Aromatica, Kosmin a Bebutter. Zároveň se společnost věnuje zajišťování smluvní výroby zejména v oblasti lihových doplňků stravy.

Personálně společnost čítá na 25 interních a externích zaměstnanců. Interně společnost řeší vše od výzkumu a vývoje, přes výrobu a logistiku, až po zajištění obchodního zastoupení na lékárnách a prodejnách se zdravou výživou v České republice. Externě řeší pouze účetnictví, IT a právní zastoupení. Na Slovensku, kde je Aromatica také etablovanou značkou, využívá služeb externího partnera, který ji zajišťuje obchodní tým „na klíč“.

Obchod, na který je tato diplomová práce velké části zaměřena, realizuje v terénu 5 obchodních zástupců, kteří mají Českou republiku rozdělenou do regionů. Ty zjednodušeně kopírují Prahu (a střední Čechy), východní a severní Čechy, západní a jižní Čechy, jižní Moravu a severní Moravu.

Prodeje realizují obchodní reprezentanti buď tzv. transferovými objednávkami (tj. zboží z lékárenských „e-shopů“ objednávají dané lékárně sami svým jménem) anebo objednávkami přímo od lékárny. Druhé uvedené je v době stále větší snahy o kontrolu cash-flow lékáren stále častější. Na základě obou těchto skupin objednávek jsou potom obchodní reprezentanti hodnoceni prémiei ze mzdy.

Tato společnost byla pro potřeby diplomové práce vybrána hned z několika důvodů. Za prvé se jedná o firmu otce autora práce, který ji také před 25 lety zakládal, ve které autor sám osobně pracuje na pozici jednatele se zaměřením na obchod a projektový management. Za druhé se firma pohybuje na dynamickém farmaceutickém trhu, který v uplynulých letech doznal mnoha změn a který jasným příkladem důležitosti využívání data miningu i v relativně konzervativních a tradičních odvětvích. Za třetí pak společnosti již má zkušenosti s interním CRM systémem, interně označovaným jako Arodata, který jejím zaměstnancům zprostředkovává základní údaje o prodeji u jednotlivých odběratelů. V práci tak je možné vycházet z reálných zkušeností se současným systémem a zároveň pracovat s relevantnějšími požadavky na verzi novou.

## 4.1 Arodata v0.1

Jak bylo zmíněno v úvodu, společnost Aromatica již aktuálně využívá jednoduchý CRM systém pro sledování prodeje. Na následujících řádcích se pokusím popsat transformaci od původního zadání vývojářům do současného stavu.

Pro pochopení směru vývoje Arodat se potřebujeme vrátit do roku 2010. Do té doby evidovala společnost pouze osobní (transferové) objednávky obchodních zástupců pomocí XLS tabulek, které obchodní reprezentanti pravidelně zasílali obchodnímu manažerovi. Hodnocení potom byli z větší části fixně a z menší podle skutečně realizovaných transferových objednávek.

První desetiletí třetího tisíciletí bylo dějištěm velké transformace do té doby roztržitého velkodistribučního trhu léčiv, a proto nebylo možné ani s alespoň přibližnou relevancí přistupovat k hodnocení obchodních reprezentantů na základě objednávek jednotlivých regionálních velkodistributorů.

S obměnou managementu firmy přesto začalo sílit volání po zajištění relevantního a spolehlivého systému, který by dokázal odlišit prodeje na jednotlivých lékárnách. Velkodistributoři již sami začínali nabízet exporty svých databází za pravidelnou úplatu v řádu jednotek až desítek tisíc korun za kvartál. Potíž byla ve formátu souborů (viz výše), kdy VD nenabízely (ať už proto, že nemohli, nebo nechtěli) data ve formátu čitelném pro „běžné smrtelníky“. Ve spojení s firemními IT techniky, kteří se starají o zabezpečení firemních počítačů a počítačové sítě se proto společnost rozhodla vytvořit jednoduchou webovou aplikaci, která by byla soubory ve formátu DBF automaticky importovala do databáze, ze které by byly následně pomocí GUI dostupné i méně počítačové zdatným uživatelům.

Grafická podoba se bohužel nedochovala, a proto pouze pro představu přikládám část výpisu dat ze systému. Tato pro společnost zásadní a přelomová funkcionality byla také v podstatě jeho jedinou.

ID lékárny	Název	Město	Region	Název výrobku	Počet ks	Obrat
001	Lékárna pod dubem	Brno	5	Kosmín na rty	5	250 Kč
001	Lékárna pod dubem	Brno	5	Echinaceové kapky	3	391 Kč
002	Lékárna u Orla	Praha	1	Měsíčková mast	10	490 Kč

Tab. 1, Ukázka dat ze systému

První verze SW tak byla spíše chytrým tabulkovým procesorem než klasickým CRM softwarem. Z pohledu společnosti a jejího povědomí o odběratelích ale šlo o obrovský průlom.

## 4.2 Arodata v1

Jak se zaměstnanci postupně adaptovali na GUI nového systému a nový systém práce s lékárnami obecně, začala společnost, již za autorova přispění, pracovat na dalších dílčích vylepšení reportingu získaných dat.

Do systému přibyly další automaticky generované výkazy na bázi jednoduchých databázových úkonů jak souhrn obrátů jednotlivých lékáren, souhrn počtu prodaných kusů za období.

Současně byly v systému postupně vylepšovány možnosti karet zákazníků, kdy bylo k jednotlivým odběratelům (lékárnám či ZV) možno přiřazovat i jiné údaje, než které byly uloženy v adresářových datech VD, namátkou telefonní spojení, mail či dodací adresa (VD evidují dle fakturační).

Přibyla i podpora exportu do XLS a CSV pro další zpracování dokumentů formou kontingenčních tabulek v aplikacích Microsoft Office.

## 4.3 Arodata v1.5

Z pohledu této diplomové práce přišla další stěžejní funkcionality spolu s verzí systému 1.5.

Do této verze aplikace pouze interpretovala data, která společnost získala od distributorů a osobní objednávky stále evidovala v podobě excelové tabulky. S přechodem na nový obchodní model, ve kterém se společnost nezaměřovala pouze na lékárny, ale začala hledat také nové potenciální odběratele z řad zdravých výživ a občůdků s přírodní tematikou, přestával tento model reportování dat stačit. Data prodeje, které byly expedovány napřímo mezi společnostmi a odběratelem nebylo kde zaznamenávat a také reporting v podobě XLS souboru přestával být s příchodem nových produktových řad přehledný a dostačující.

Proto společnost nechala do nové verze Arodat přidat modul sledující osobní objednávky obchodních reprezentantů, který zároveň sloužil jako reportovací spojnice mezi obchodními reprezentanty a obchodním manažerem.

Tato funkcionality potom umožnila evidovat nejen prodeje vyskladněné z VD, ale také prodeje, které společnost expedovala napřímo a které se díky reportu automaticky propisovaly do prodejů jednotlivých regionů.

**aromatica Arodata** Verze: 1.97 (20. 11. 2017)  
© VIKTORIN Computers, 2011 - 2018

Přihlášený uživatel: **Jakub Šimůnek** | Můj profil | Odhlásit...

Úvod | **Návštěvy/objednávky** | Přehledy | Import dat | Číselníky | Nastavení

**NÁVŠTĚVY/OBJEDNÁVKY**

- Vložit novou návštěvu/objednávku
- Přehled návštěv/objednávek
- Přehled objednaných položek
- Denní přehled
- Přehled vystavených výrobků
- Vložit novou interní objednávku
- Přehled interních objednávek
- Souhrn interních objednávek

**VLOŽIT NOVOU NÁVŠTĚVU/OBJEDNÁVKU**

**Datum:**

**02. 03. 2018** (zvoďte kliknutím do kalendáře)

<< březen 2018 >>						
Po	Út	Stř	Čt	Pá	So	Ne
		1	2	3	4	
5	6	7	8	9	10	11
12	13	14	15	16	17	18
19	20	21	22	23	24	25
26	27	28	29	30	31	

**Lékárna:**

Hledat lékárnu (min. 2 znaky):

Název:  Ulice:  Město, obec:  IČ:  DIČ:

**Bohumín - Natural Bohumín, Studentska 1233**

**Datum poslední návštěvy/objednávky:**

**14. 02. 2018**

**Bebutter - sleva 10 %:**

**NE**

**Informace o distributorovi:**

Distributor: **--- nezvolen ---**

**Objednávka:**

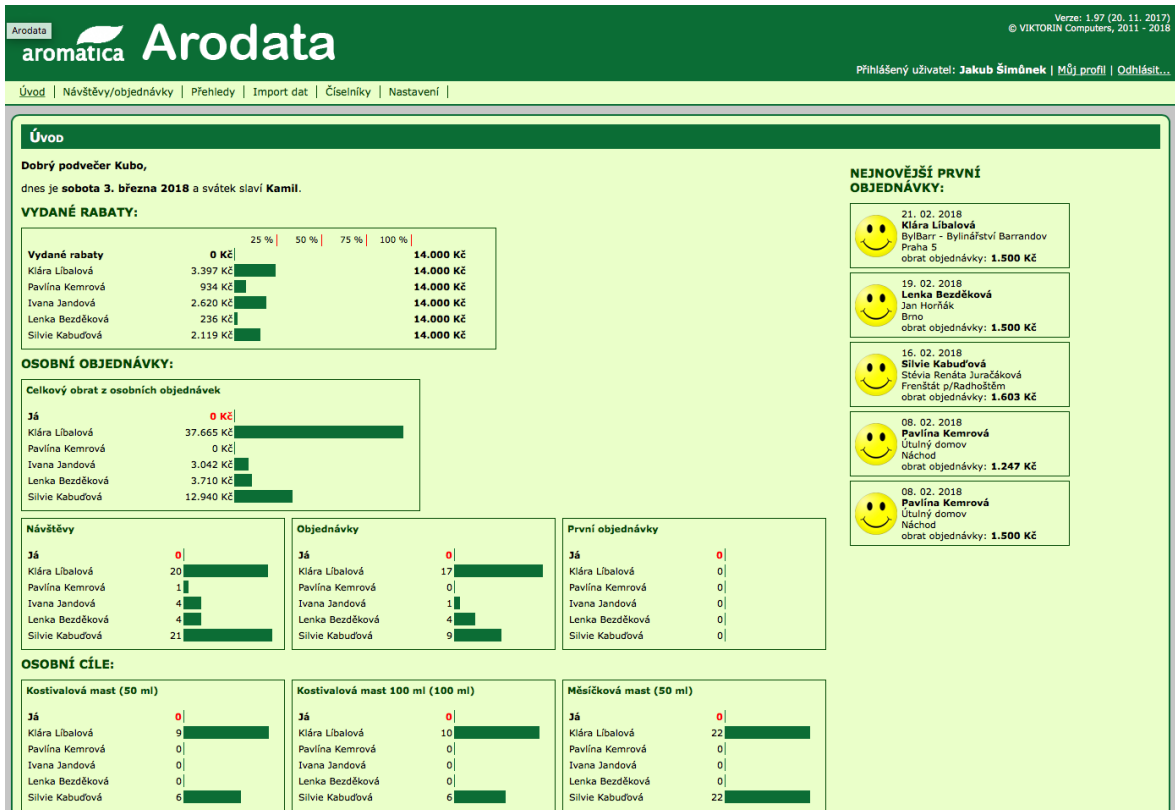
Číslo	Výrobek	Množství	Cena	Obrat	Rabat	Výměna expirace	Vystaveno
1	Kostivalová mast s kafrem (50 ml):	0 ks	49,30 Kč	0,00 Kč	0 ks	0 ks	<input type="checkbox"/>
4	Kostivalová mast (50 ml):	0 ks	47,20 Kč	0,00 Kč	0 ks	0 ks	<input type="checkbox"/>
55	Kostivalová mast 100 ml (100 ml):	0 ks	76,70 Kč	0,00 Kč	0 ks	0 ks	<input type="checkbox"/>

Obr. 11, Obrazovka zadání nové objednávky

#### 4.4 Arodata v1.9

V zatím poslední verzi přibyla mezi několika kosmetickými úpravami také zcela přepracovaná úvodní obrazovka, která z několika málo možností, jenž jí původní systém nabízí, aspiruje na základní Sales dashboard. Na této obrazovce obchodní reprezentant vidí, jak si stojí v osobních prodejkách, kolik absolvovali návštěv a kolik z nich bylo úspěšných. Stejně tak může obchodní manažer každý měsíc vybrat několik produktů, které jsou pro obchodní reprezentanty daný měsíc klíčové, a jejichž stav prodejků vidí obchodní reprezentanti při každé návštěvě Arodata, a to i v porovnání s konkurenčními regiony.

V této verzi bylo také přidáno několik dalších parametrů pro filtrování prodejků koncových prodejců jako jsou sítě, typ prodejny (lékárna/ZV) nebo kategorizace odběratelů podle prodejků za posledních 12 měsíců.



Obr. 12, Náhled úvodní stránky

## 5 ZROJOVÁ DATA

V této kapitole ve zkratce popíšete strukturu dat, která společnost dostává od svých velkodistributorů.

Jak bylo zmíněno výše, všechna data jsou ve formátu dBase s příponou \*.dbf. Všechny využívají kódování UTF-8. Zde ale veškerá podobnost končí a struktura je bohužel u všech velkodistribucí odlišná.

### 5.1 PHOENIX lékárenský velkoobchod s.r.o.

Největší český velkodistributor Phoenix data dělí do 3 souborů, z nichž každý obsahuje část dat, která se při importu na pozadí aplikace kombinují.

#### Art.dbf

První soubor obsahuje seznam produktů včetně jejich unikátních čísel, které se potom spojují s jednotlivými případy prodeje v hlavním souboru.

Databázová struktura je následující:

- KOD (Interní kód produktu, shodný s APA kódem)
- EAN (Mezinárodní 13místné identifikační číslo produktu)
- NCENA (Nákupní cena)
- PCENA (Prodejní cena)
- NAZ\_OBCHOD (Obchodní název produktu)
- KOD\_SUKL (Kód registrace SÚKLu)
- IS\_SUKL (Interní číslo SÚKLu)
- MJ (Měrná jednotka)
- SK (Interní označení skupiny produktů)

#### Odb.dbf

Druhý soubor je sborníkem odběratelů VD. Opět, s pomocí interních kódů identifikuje odběratele u jednotlivých prodejních případů.

Databázová struktura je následující:

- CISPART (Partnerské číslo odběratele)
- ICO (IČO odběratele)
- NAZEV (Název odběratele)

- TYP (Interní označení skupiny odběratelů)
- PSC (Poštovní směrovací číslo odběratele)
- OBEC (Obec, ve které se odběratel nachází)
- ULICE (Ulice, na které odběratel sídlí)

**Prod\_XX.dbf** (XX = zkratka obchodního centra)

Databázová struktura je následující:

- KOD (Cross-referenece zboží)
- CISPART (Cross-referenece odběratele)
- RET (Neznámá proměnná)
- MNOZ (Množství prodaného zboží)
- CENA (Prodejní cena pro konkrétního odběratele)
- DATUM (Datum prodejního případu)
- SARZE (Šarže u zboží registrovaného SÚKLeM)

## 5.2 Alliance Healthcare s.r.o.

Data dodávaná společností Alliance Healthcare jsou dodávána po jednom souboru za každé obchodní centrum. Tento soubor obsahuje všechny údaje k všem obchodním případům, které dané OC řešilo.

Databázová struktura je následující:

**Aro\_XXYY.dbf** (XX = zkratka obchodního centra, YY = měsíc)

- KODPR (Interní číslo produktu)
- SUKL (Kód registrace SÚKLu)
- PDK (Kód registrace PDK)
- NAZEVPR (Název produktu)
- VYR (Identifikace výrobce)
- ZEM (Identifikace země původu)
- MNOZ (Množství prodaného zboží)
- DATUM (Datum prodejního případu)
- KODSU (SÚKL kód lékárny)
- NAZEVSU (Název odběratele dle SÚKLu)



- ULICE (Ulice, na které odběratel sídlí)
- MÍSTO (Obec, ve které se odběratel nachází)
- PSC (Poštovní směrovací číslo)
- ICO (IČO odběratele)

### 5.3 Pharmos a.s.

Stejně jako Alliance Healthcare, také Pharmos dodává všechna data v jednom souboru pro každé své obchodní centrum zvlášť.

Databázová struktura je následující:

**PhaXXXYY.dbf** (XXX = zkratka obchodního centra, YY = měsíc)

- C\_LEK (Interní číslo odběratele)
- LEKARNA (Název odběratele)
- UL\_CIS (Ulice, na které odběratel sídlí)
- MÍSTO (Obec, ve které se odběratel nachází)
- PSC (Poštovní směrovací číslo odběratele)
- VYROBCE (Identifikace výrobce)
- NAZ\_LEKU (Název produktu)
- SUKL (Kód registrace SÚKLu)
- KUS (Množství prodaného zboží)
- CASTKA (Celková cena prodejního případu)
- DATUM (Datum prodejního případu)
- ICO (Identifikační číslo odběratele)
- KODPDK (Kód registrace PDK)

### 5.4 ViaPharma s.r.o.

Poslední velkodistributor v nedávné minulosti změnil formát dat, respektive s přechodem na nový systém začal data posílat po vzoru Pharmosu a Alliance Healthcare v jednom souboru pro každé obchodní centrum. Zároveň jako jediný posílá data ve formátu \*.txt, byť strukturně jde o stejnou podobu dat, jako v případě \*.dbf souboru. Technická struktura dat je stejná jako u ostatních dodavatelů.

Databázová struktura je následující:

- KOD (Kód registrace PDK)
- SUKL (Kód registrace SÚKLu)
- NAZEV (Název produktu)
- MNOZSTVI (Množství prodaného zboží)
- CENA (Nákupní cena zboží)
- DATUM (Datum prodejního případu)
- KODODB (Partnerské číslo odběratele)
- ODBERATEL (Název odběratele)
- ULICE (Ulice, na které odběratel sídlí)
- OBEC (Obec, ve které se odběratel nachází)
- PSC (Poštovní směrovací číslo odběratele)

## 5.5 Zhodnocení struktury dat

Jak je patrné z tabulky níže, přestože jsou data ukládána ve stejných či podobných formátech, obsah jednotlivých databázových souborů skýtá několik zásadních problémů. Některé z nich jsou pouze technické, některé ovšem mohou zásadně ovlivnit relevanci výsledných dat.

<b>Velkodistribuce</b>	<b>Phoenix</b>	<b>Alliance Healthcare</b>	<b>Pharmos</b>	<b>ViaPharma</b>
Název produktu	X	X	X	X
APA	X			
PDK		X	X	X
EAN	X			
Nákupní cena	X			X
Prodejní cena	X			
Měrná jednotka	X			
Název odběratele	X	X	X	X
Ulice	X	X	X	X
Obec	X	X	X	X
PSC	X	X	X	X
Číslo SÚKL registrace lékárny		X		

Interní číslo odběratele	X		X	X
IČO	X	X		
Datum prodeje	X	X	X	X
Množství ks	X	X	X	X
Obrat (celkem)			X	

Tab. 2, Přehled datových polí v souborech velkodistributorů

Důležité pro vývoj této, i dalších nových verzí, aplikace je zvolení všech dat, která by do budoucna mohla být v dalších iteracích užitečná, přestože nenajdou své uplatnění hned.

## 6 ANALÝZA APLIKACE ARODATA

### 6.1 Průzkum výsledných požadavků

Abychom mohli získávaná data hodnotit z pohledu relevance a navrhnout řešení, potřebujeme znát jednotlivé stupně extrakcí dat, která na základě vstupních importů požadujeme.

Pro zjištění daných požadavků jsem vycházel ze svých zkušeností formou auto-interview a dále potom rozhovory s obchodním manažerem společnosti, Tomášem Bartuskem, marketingovou pracovnící Kateřinou Kozlovou a také majitelem společnosti Ladislavem Šimůnkem.

Všechny rozhovory byly koncipovány tak, aby jednotliví uživatelé, kteří Arodataby využívají k jiným účelům, nejprve zhodnotili, v čem jsou jim Arodataby oporou – tj. která data z aplikace získávají a ke kterým účelům. Následně subjektivně hodnotili, nakolik jim data připadají relevantní a pokusili se zhodnotit proč. Na základě těchto dat bude vytvořen zjednodušený model současné aplikace, ve které budou nepoužívané metriky odstraněny. V další otázce byli vyzváni k nadnesení dalších metrik, které nad tvrdými daty používají (tj. jak data po stažení dále využívají). Tyto informace budou následně použity pro doplnění současných metrik do aplikace. Do aplikace potom budou doplněny i informace, které si ze současných dat jednotliví uživatelé ani nejsou schopní vytáhnout sami pro neznalost postupů dolování dat, ale které pro ně mohou být/jsou relevantní a důležité. Poslední kmenovou otázkou byla zkušenost uživatelů s přehledností aplikace. Vycházím přitom z premisy, že se nevyplatí měnit něco, co funguje. Pokud se na aplikaci koukáme metrikou běžných uživatelů, kteří si vytvořili návyky používat natolik specifickou aplikaci vlastním způsobem, je lepší jim základní pracovní návyky zachovat a zjednodušit nové UX tak, aby se v něm intuitivně vyznali i po přepracování jeho front-endu.

Základní okruhy polo strukturovaných rozhovorů byly:

1. Arodataby jako vzhled do prodejů společnosti – Základní otázka: *V čem jsou vám Arodataby nyní oporou, ve smyslu, které informace z nich získáváte?*
2. Arodataby jako zdroj dat pro další zpracování – Základní otázka: *Pracujete s daty dále? Tj. stahujete si „hrubá“ data, která dále zpracováváte například v Excelu?*
3. Informace, které nyní neumíte získat – Základní otázka: *Co byste z Arodataby chtěli vědět dál a třeba nevíte, jak na to?*

4. Uživatelská přívětivost aplikace – Základní otázka: *Jak se vám s aplikací pracuje? Přijde vám přehledná? Co se vám líbí a co ne?*

## 6.2 Vyhodnocení průzkumu

Arodata jsou dnes komplexním systémem, budovaným s různými požadavky 4 obchodních manažerů během posledních 8 let, přesto průzkum ukázal, že aktivně využívaný je pouze zlomek jeho funkcionalit. Uživatelé, dále označovaní pouze iniciály (Jakub Šimůnek, JŠ, Tomáš Bartusek, TB, Kateřina Kozlová, KK a Ladislav Šimůnek, LŠ), se k základním prvkům a funkcionalitám vyjadřovali následovně.

### 6.2.1 Úvodní strana

Homepage aplikace, která doplňuje základní obchodní dashboard slouží hlavně TB, jakožto obchodnímu manažerovi, JŠ jako jednateli a LŠ jako majiteli společnosti. Všichni se shodují, že jim základní přehled současných prodejů (osobních objednávek) a zároveň přehled uskutečněných návštěv a objednávek pomáhají zjistit aktuální výkonnost obchodního týmu a současně v zárodku identifikovat slabá místa jednotlivých obchodních reprezentantů (klesající výkonnost, problém regionu atd.).

Současně ovšem TB upozorňuje, že aktuální data jsou sice důležitá, ale vypovídající hodnotu mají pouze v případě, že uživatel zná jejich kontext. Tím je srovnání „startovní pozice“ jednotlivých regionů (obchodní manažer například ví, že Praha je silnější region než Ostrava díky kupní síle), historický vývoj osobních obrátů v regionu (YTY, QTQ, MTM) a také strukturální složení prodejů v jednotlivých regionech (zdánlivě vyrovnané regiony Prahy a Hradce v období březen – srpen, kdy si jsou struktury prodaných výrobků podobné, se výrazně mění v období prodeje Echinaceových kapek, základního produktu společnosti, pro který je baštou Praha a střední Čechy). Pro neznalého tedy mohou být data na první pohled zavádějící a závěry z nich vyvozené nepřesné.

Pro zlepšení této informační nerovnosti proto TB spolu s JŠ navrhuje zahrnutí historických dat do dashboardu, například formou srovnávacích grafů.



Obr. 13, Návrh úpravy grafu osobních objednávek

Tento graf by lépe reflektoval skutečný stav regionu pro potřeby obchodního manažera, jelikož by zahrnoval osobní objednávky z předchozího roku k danému dni.


Další možností vylepšení, kterou navrhuje JŠ, je normalizace osobních (a dále i celkových) objednávek k potenciálu regionu. Jak již bylo výše zmíněno, z historických a geografických důvodů, nejsou všechny regiony stejné. V některých je celková kupní síla obyvatel slabší než v jiných. Například přepočtem obyvatel na km<sup>2</sup> jednoznačně vede pražský region, zatímco ten východočeský se bude potýkat s územím „nikoho“ mezi Plzní a Českými Budějovicemi, ve kterém je hustota osídlení nízká.

Varianty řešení jsou v zásadě dvě. První je přepočet obratu podle jednoho z klíčových ukazatelů regionu – těmi jsou počet obyvatel (*tedy metrika CZK / obyvatel*), hrubý domácí produkt regionu (*resp. parita kupní síly, HDP / CZK*), případně výkonnost lékáren (*CZK / počet aktivních odběratelů vs. CZK / počet všech potenciálních odběratelů*). Druhou možností je subjektivní stanovení poměru regionů, jeho stanovení a průběžné upravování. Zatímco první možnost bude relevantnější a přesnější, vystavujeme se v případě jejího použití několika rizikům, zejména špatnému pochopením struktury obyvatelstva a odběratelů. Jelikož společnost nedisponuje sociology a statistiky, byla proto zvolena první možnost. Po interní analýze byl objeven vzorec prodeje v jednotlivých regionech napříč lety (každý region má specifický cyklus, který se v uplynulých letech opakuje). Tato statistická data proto mohou být použita pro základní analýzu výkonu regionů s přihlédnutím k jejich výkonnosti.

Do systému tedy může být zapracovaná tabulka s proměnnou *výkon*, podle které bude normován obrat regionu vůči ostatním tak, aby měl obchodní manažer základní přehled, jak si region stojí a zda se v něm neobjevují problémy.

Posledním vylepšením, které navrhuje LŠ je vyhodnocení prodeje podle kategorií produktů. Společnost Aromatica aktuálně eviduje 10 interních kategorií produktů (kapky, čaje, masti, ...) a těchto 10 kategorií je na základě dat schopná porovnávat meziročně.

V této analýze dochází k agregaci prodejů podle výše zmíněných kategorií a jejich porovnání s dalšími regiony, respektive metrikami YTY a QTQ. Pro vizualizaci byla zvolen pavučinový graf s logaritmickou osou, v náhledovém případě srovnávající prodeje s předchozím rokem.



Obr. 14, Náhled pavučinového grafu

### 6.2.2 Databáze obrátů lékáren

Původní část Arodat, databáze lékáren, byla vyhodnocena TB, JŠ a LŠ jako největší problém. V databázi se nachází mnoho duplikovaných lékáren, u kterých není možné určit, která instance je poslední aktuální. V případě nákupních center pak na jedné adrese sídlí více prodejen a duplikáty, respektive vyřazené lékárny není možné určit ani automatizovaně.

Problémům a jednoznačné identifikaci lékáren v databázi se budu věnovat v další části práce, proto se nyní zaměříme pouze na funkčnost jako takovou.

Základní práci plní Arodata spolehlivě. Vyhledávání v databázi je jednoduché a podporuje všechny potřebné kategorie filtrování. Rychlost aplikace se s přechodem na novější verzi PHP zlepšila, a proto po stránce základní funkcionality není aplikaci co vytknout. Drobným problémem, se kterým se TB a JŠ setkávají, je horší podpora exportovaných souborů na počítačích Mac, ale zde se jedná pravděpodobně jen o potřebu rekonfigurovat exportní mechanismy.

Aktuální dostupné přehledy a jejich využívání jsou následující:

- **Přehled prodeje** – tabulka obsahující importovaná data z DBF souborů. Jeden řádek značí jeden prodej jednoho konkrétního přípravku na jednu konkrétní lékárnu. Tento přehled využívá JŠ a TB hlavně pro export dat a další zpracování, jelikož se jedná o surová data. KK tento přehled používá při kontaktu se zákazníky, kteří hledají dodavatele našich produktů v blízkosti jejich bydliště, přičemž zákazníkovi může nabídnout lékárnu, která konkrétní produkt běžně odebírá.
- **Souhrn prodeje** – tabulka agregující počet prodaných kusů produktů v jednotlivých regionech za zvolené časové období. Tuto funkcionalitu využívá zejména JŠ pro přehled o celkové prodejnosti produktů a volbě další obchodní strategie společnosti. TB tuto tabulku používá pro zjištění silných a slabých stránek regionu a pro sledování úspěšnosti zavádění nových produktů na trh v jednotlivých regionech.
- **Přehled obrátů** – tabulka agregující obrát jednotlivých lékáren za zvolené časové období. TB tento export používá pro zpětný reporting výsledků obchodních reprezentantů. Ti mají možnost projít si jednotlivé lékárny a porovnat skutečný prodej s jejich dojmy a historickými fakty.
- **Měsíční přehled obrátů** – tabulka agreguje obrát jednotlivých lékáren za zvolené časové období po měsících. Tento export byl přidán předchozím obchodním manažerem a vzhledem ke své nepřehlednosti je nyní bez využití.

### 6.2.3 Databáze osobních obrátů a návštěv

S odhlédnutím od chyb v databázi lékáren, na kterou jsou osobní obraty navázány (obchodní reprezentant přiřazuje svou návštěvu vždy ke konkrétní lékárně z databáze lékáren), je databáze osobních objednávek hodnocena nejpozitivněji jak TB, tak JŠ.

Jednoduchá struktura s pokročilými možnostmi prohlížení dat dává najevo, že jde o poslední velkou databázi přidanou do Arodat.

V současnosti se databáze rozděluje do těchto přehledů:

- **Přehled návštěv/objednávek** – základní pohled, ve kterém se řádek rovná jedné návštěvě obchodního reprezentanta na konkrétní lékárně. Z tohoto přehledu je možné si otevřít detail jednotlivých objednávek. Tento přehled využívají JŠ a TB pro další práci nad databází v Excelu. Mezi základní využití patří agregování návštěv na úroveň měst (příprava heatmap s pokrytím regionu obchodních reprezentantů), agregování na úroveň data (kontrola práce obchodní reprezentant v terénu nebo kontrola



úspěšnosti obchodních reprezentantů v terénu), případně ke kontrole příliš velkého/malého počtu návštěv na lékárně.

- Přehled objednaných položek – obdoba Přehledu prodeje, v tomto případě zobrazující data osobních prodejů na konkrétních lékárnách. TB používá pro další analýzy, zejména se zaměřením na zhodnocení poměru osobních/celkových prodejů v jednotlivých kategoriích.
- Denní přehled – součet počtu návštěv, objednávek, obratu a počtu prodaných ks.

### 6.3 Kvalitativní analýza dat společnosti

Jak bylo řečeno výše, společnost systém na současném principu využívá již osm let. Za tu dobu eviduje v databázi následující počty položek:

- Přehled prodejů na lékárny: 1 431 751 záznamů
- Přehled návštěv lékáren: 62 327 záznamů
- Přehled osobně objednaných položek: 212 387 záznamů
- Počet lékáren (brutto<sup>1</sup>): 7061 záznamů
- Počet lékáren (netto<sup>2</sup>): 5079 záznamů

S ohledem na výzkum kvality údajů lze tento počet záznamů považovat za relevantní.

Tzv. čištění lékáren proběhlo naposledy v srpnu 2017, přičemž jde o manuální činnost spojenou s telefonickými objednávkami na lékárnách.

Přiřazení správných prodejů správným lékárnám zařazených do správných obchodních regionů je alfou a omegou celého CRM systému. Pro potřeby kvalitativní analýzy si nyní rozeberme současný stav tak, abychom byli z technického hlediska schopní pochopit silná a slabá místa.

#### 6.3.1 Kvalitativní analýza zdrojových dat

Relevanci hrubých dat získaných od VD můžeme hodnotit dvojitým způsobem.

---

<sup>1</sup> Brutto = celkový počet lékáren a ZV zaznamenaný z dat VD

<sup>2</sup> Netto = lékárny a ZV ručně očištěné o duplicity a zavřené provozovny

Prvním je hodnocení reálnosti/pravdivost dat o prodeji mezi VD a koncovou lékárnou. Pokud se tyto obchodní případy přesně shodují s daty poskytnutými společností velkodistributorem, pak je relevance dat 100%. Odpověď na tuto otázku je mírně zavádějící, ale s ohledem na tvorbu dat jednoduché – společnost nezná skutečné prodeje mezi VD a koncovými zákazníky a neexistuje ani žádná možnost, jak ověřit, že se data s reálnými prodeji shodují. Na druhou stranu však můžeme hodnotit postup vzniku exportů dat – ty sestávají z tzv. dumpu databáze s vybranými prodeji dle dodavatele. Tato data jsou tvořena automatizovaně bez zásahu lidského faktoru. To, že data jsou tvořena metodou dumpu databáze, zaručuje s velice vysokou pravděpodobností, že informace o prodeji na lékárně se neliší od skutečných prodejů velkodistributorem. Tato skutečnost byla navíc empiricky ověřována porovnáním prodejů ze společnosti na VD a z VD na lékárně, kdy v dlouhém období by data měla být shodná, resp. velice podobná (VD prodá vše to, co od firmy nakoupí). Na 5letém vzorku dat z účetního softwaru a z aplikace Arodata byla zjištěna shoda prodejů s jistotou 99,73 %.

Druhým způsobem, jak se můžeme koukat na relevanci dat o prodeji je, zda zboží, zakoupené lékárnou také končí v nabídce lékárně, pro kterou je obchodní případ veden. Tedy zda je počet kusů zakoupených lékárnou A roven počtu kusů, který daná lékárně skutečně prodá přímo koncovým zákazníkům. V tomto případě je situace s hodnocením relevance dat složitější z několika důvodů:

- Jako ve všech ostatních oborech, i v oboru farmacie jsou podnikatelé, kteří vlastní více než jednu lékárně. Jelikož se obchodní přírůžky velkodistributorů odvíjí od celkové výše ročního obrátu odběrného místa (= lékárně), je pro některé majitele více lékáren výhodnější odebírat produkty na jedné lékárně, tím si snížit obchodní přírůžku velkodistributora, a produkty následně distribuovat vlastními silami do dalších lékáren.
- V některých případech se toto děje i u lékáren, které jsou vlastněny více majiteli, ale z pohledu SÚKLu jsou formálně propojeny. Jedná se především o lékárně a tzv. OOVL, odloučené oddělení výdeje léčiv. V minulosti šlo zejména o detašovaná pracoviště lékáren v městech a obcích bez dostupnosti „klasické“ lékárně. Nyní se některé OOVL osamostatnily, a přestože jsou fakticky stále svázané s mateřskou lékárnou, mohou mít jiné majitele a nabízet i další, nefarmaceutický sortiment. Prodeje se v některých případech připisují (správně) jim, v některých jsou ale stále vedeny na mateřskou lékárně.

- Nakonec i v případech nespojených samostatných lékáren se najdou případy, kdy se spřátelení lékárníci snaží ušetřit na obchodních přírážkách a pro nakupují zboží společně na jednu lékárnou, a to si mezi sebou následně distribuují za nákupní ceny.
- Posledním případem, který snižuje relevanci dat, jsou příhraniční lékárny, které tzv. reexportují doplňky stravy do lékáren v zahraničí. Tato aktivita sice postupně ustupuje, ale obchodní reprezentanti společnosti čas od času narazí na lékárnou, která si vyžádá texty na překlad do cizí řeči a na vlastní náklady a nebezpečí dále prodává zboží lékárnám a prodejnám v zahraničí.

Rozklíčování těchto prodejů je bez znalosti obchodních vztahů na lékárnách prakticky nemožné. Pro alespoň částečnou analýzu jsem obchodní reprezentant firmy pověřil subjektivní kvalitativní analýzou prodejních dat jednotlivých lékáren.

Všichni dlouholetí obchodní reprezentanti mají v povědomí, jak se produktům společnosti daří na konkrétních lékárnách. Toto povědomí je pouze subjektivní – obchodní reprezentanti ví, že se některým lékárnám daří lépe než ostatní, že mají zastoupení cca tolik a tolik procent ze sortimentu společnosti a že obrat jedné lékárny je zřejmě nižší/stejný/vyšší než druhé.

Pro ověření dat obchodní reprezentanti dostali seznam lékáren ve svém regionu včetně obrátů za rok 2017 a byli pověřeni k tomu, aby zaznačili ty lékárny, které z jejich zažité představy vybočují. V seznamu měli lékárny, které měly řádově vyšší obrat, než na kolik by je obchodní reprezentanti sami odhadli a objevili i dobré lékárny, na kterých dělají pravidelné objednávky, s téměř nulovým celkovým obratem.

Po vyčištění lékáren o lékárenské e-shopy, jsem metodou poměru subjektivně „správných“ obrátů vůči subjektivně „špatným“ obrátům dospěl k hodnotě 98,24 % správnosti. Jinými slovy na vzorku 5079 lékáren bylo subjektivně (!) odhaleno 90 lékáren, jež vykazovaly atypický obrat dle názoru obchodních zástupců.

*Závěrem můžeme říct, že relevance vstupních dat po stránce správnosti reflektované skutečnosti ze strany velkodistributora je i přes určité odchylky vysoká.*

### **6.3.2 Kvalitativní analýza koncové databáze**

Pro analýzu koncové databáze, tedy toho, z čeho aplikace odvozuje další údaje, se nejprve podíváme na proces importu dat.

Import probíhá na základě DBF souborů velkodistributorů, jehož struktura byla vysvětlena výše. Veškeré importování je čistě automatické, jediný zásah uživatele je vyžadován pro zvolení dat k importu a následně kontrole importovaných dat.

Technický proces importu se u jednotlivých velkodistributorů částečně odlišuje (zejména v závislosti na faktu, zda jsou všechna data v jednom souboru, anebo napříč více soubory), pozadí je ale vždy stejné. Systém zaznamená nový řádek a dle nastavení v řádku vyhledá identifikační údaje o lékárně (název, ulici a město). Ty se, jednu po druhé pokusí porovnat se současnou databází a najít shodu. Pokud najde shodu u názvu, pokračuje v hledání shody u ulice.

Jakmile systém identifikuje lékárnu, přiřadí konkrétní prodejní případ do jejích prodejů v databázi.

V tomto bodě zaznamenáváme první problém. Systém není založen na žádné pokročilé „inteligenci“, data porovnává v hrubé podobě, přestože využívá alespoň základní převod textových informací – z „Lékárna Pod dubem“ vytvoří „lekarna pod dubem“, jenž následně porovnává se stejně upravenými daty ve své databázi. To sice eliminuje chyby napříč velkodistributory, kdy některý má danou lékárnou uloženou jako „Lékárna Pod dubem“ a někdo jako „Lekarna pod dubem“. Neporadí si ale například s „Lékárna Pod dubem s.r.o.“, kterou bude považovat za jiný subjekt. Stačí proto, aby lékárná změnila právní formu nebo vstoupila do sítě lékáren (a tudíž změnila název) a v systému je obratem označena jako nová, na stejné adrese se objeví duplicitní lékárná bez historie a dříve získaných informací (kontaktní osoby apod.). To má za následek 2 věci:

- Obchodní reprezentant přijde u nové lékárně o přehled dříve odebíraných produktů a kontaktní osoby. Tyto informace v systému sice dále zůstávají, ale musí je „hledat“ pod více instancemi lékárně na jedné adrese. To jej zdržuje od práce a vytváří zmatky v reportování návštěv, kdy obchodní reprezentant realizuje návštěvy na „zastaralé“ lékárně, přičemž prodeje se přiřazují k nové lékárně.
- Obchodnímu zástupci se uměle zvyšuje počet lékáren v regionu, což negativně ovlivňuje procento navštívených lékáren za 12 měsíců, což je jeden z jeho KPI. Obchodní reprezentant se stará o cca 1000 lékáren a ZV ve svém regionu a pokud během roku „nasbírá“ 100 staro-nových lékáren, jeho úspěšnost se tímto uměle snižuje o 10procentních bodů.

Data jako celek – tedy součet prodaných kusů, obchodních případů a obratu – zůstávají konzistentní, vše ostatní ale při přibližování do větších detailů na své relevanci ztrácí.

Pro analýzu kvality koncové databáze byla zvolena metoda kombinace kvantitativních a kvalitativních metod.

Nejprve jsem stejně jako v případě analýzy zdrojových dat stáhnul kompletní přehled lékáren v jednotlivých regionech spolu s jejich adresou a celkovým ročním obratem za rok 2017. Následně jsem za pomoci software Google Refine a Google Maps Geolocation API získal standardizované adresy pro jednotlivé provozovny.

Google Maps Geolocation API funguje na (zjednodušeně) jednoduchém principu – je mu odeslána adresa tak, jako by ji uživatel zadával do klasické aplikace Google Maps. Stejnou adresu tak může zadat jako „Masarykovo náměstí 101, Šlapanice“ nebo jako „Masarykovo nám. 101/3, Šlapanice u Brna“. API jakýkoliv z těchto zadaných názvů vezme a na pozadí aplikace ji prožene Google Maps. Ty následně v otevřeném formátu JSON vrátí adresu ve formátu používaném Googlem spolu se souřadnicemi. Obě výše zmíněné varianty adres tak dostanou podobu „Masarykovo nám. 101/3, 664 51, Šlapanice“. Tímto způsobem eliminují chybovost pouhého vyhledávání duplicit například pomocí tabulkového procesoru Excel.

Data ve vyčištěném formátu byly dále převedeny do klasické tabulkové podoby s rozdělenými ulicemi, PSČ a názvem obce. Nad těmito daty potom byly hledány duplicity.

Tímto jsme získali seznam lékáren sídlících na stejné adrese. V tomto seznamu se tak vyskytovaly tři druhy lékáren:

- Lékárny, které v uplynulém roce zanikly a nahradily je lékárny nové (změna majitele)
- Lékárny, které sídlí v obchodních centrech, ve kterých se vyskytuje více než jedna lékárna, ale jejíž provozovny mají jednu shodnou adresu (například na pražském OC Chodov nebo v brněnské Olympii)
- Lékárny, které během roku nezměnily majitele, ale u nichž například jeden z velko-distributorů změnil registraci a přidal/odebral právní formu či je z jiného důvodu upravil kontaktní údaje lékárny, a kterou aplikace Arodata vyhodnotila jako novou.

Pro rozlišení, o který druh lékáren se v tomto případě jedná, dostali obchodní reprezentanti za úkol projít seznam takto duplicitních lékáren ve svém regionu a označit, do které ze tří výše zmíněných skupin lékárny patří.

## 6.4 Závěry analýzy a doporučení

Z výše uvedené analýzy vyplývá, že relevance vstupních dat je na vysoké úrovni. Klíčovým faktorem pro vylepšení věrohodnosti a použitelnosti aplikace je tedy zlepšení způsobu, jakým aplikace data přijímá a přiřazuje je jednotlivým odběratelům.

Dále z provedených rozhovorů vyplynulo, že stěžejním bodem přípravy nového systému musí být vytvoření/zavedení zjednodušeného rozhraní pro přístup k nejběžnějším metrikám prodeje společnosti tak, aby se k detailnějším údajům dostali i méně počítačově zdatní uživatelé, případně uživatelé s omezeným přístupem ke klasickému PC (typicky obchodní reprezentant v terénu z tabletů).

Z pohledu personalistky je možné do aktualizované aplikace zabudovat přímý export dat pro potřeby tvorby mezd a pro sledování plnění interních cílů obchodních reprezentantů.

### **III. PROJEKTOVÁ ČÁST**

## 7 ÚVOD K PROJEKTOVÉ DOKUMENTACI

Tato projektová dokumentace shrnuje zjištěné poznatky a požadavky z minulých kapitol. Její struktura je koncipována tak, aby jako celek mohla být předána vývojářské společnosti k naprogramování.

Součástí projektové dokumentace je:

- Stručný popis projektu
- Popis výchozích bodů a existujících zdrojů z aplikace verze 1.9 včetně současné databázové struktury
- Popis požadavků na technologii aplikace včetně základních uživatelských případů
- Návrh na úpravu řešení implementačního systému dat velkodistributorů do databáze aplikace
- Popis přepokládané implementace staré databáze do nového systému
- Prototyp uživatelského rozhraní pro mobilní zařízení
- Návrh implementace databázové struktury do systémů třetích stran
- Předběžný popis časového harmonogramu úpravy aplikace včetně lidských a finančních zdrojů.

### 7.1 Popis projektu

Zamýšlený projekt je aktualizovanou verzí CRM systému Arodata společnosti AROMATICA. Záměrem projektu je vylepšení funkcionality systému o pokročilé obchodní metriky a zlepšení uživatelského rozhraní aplikace. Současně je cílem vytvoření webového rozhraní aplikace pro využití v mobilních zařízeních – tabletech a chytrých telefonech.

Zadavatel si od projektu slibuje zvýšení komfortu uživatelů při práci se systémem, větší výtežnost dat a tím posílení obchodního podílu společnosti.

V rámci projektu předpokládá využití současných databázových struktur anebo návrh nových struktur tak, aby byly schopny pojmout současné informace o prodejkách a odběratelích ze současné verze aplikace.

V případě, že bude po konzultaci s vývojářskou společností rozhodnuto o zachování struktury databáze, je jednou z priorit také optimalizace databáze tak, aby bylo možné připojit se k ní z aplikací třetích stran tak, aby i tyto aplikace byly schopny získávat a zpracovávat data



o zákaznících a prodejích společnosti. Tedy přepracovat současnou databázi takovým způsobem, že bude data skladovat ve standardizovaných datových formátech, které budou strojově zpracovatelné.

## 7.2 Popis výchozích bodů a existujících zdrojů aplikace

Celý projekt je zamýšlen jako další verze aplikace, nikoliv jako budování SW od začátku. Jako výchozí bod tedy poslouží aplikace Arodata ve své poslední verzi 1.98.

Poslední setinová iterace byla vydána 3. 4. 2018 jako dílčí verze obsahující několik drobných vylepšení exportů. Se všemi předchozími verzemi sdílí základní jádro i všechny ostatní moduly.

Aplikace Arodata běží na sdíleném webovém serveru společnosti Czechia.cz s hostingem Linux PROFI v jeho veřejně dostupné specifikaci, tedy s 40 GB pro webové aplikace a 10GB limitem pro databáze. Hosting podporuje nejnovější verzi PHP 7 a nabízí nativní podporu databázím MySQL 5.7.x s limitem 1000 databází pro jeden účet. Paměťový limit (*memory\_limit*) je 256 (512) MB, maximální velikost nahrávaného souboru (*upload\_max\_filesize*) je 32 (64) MB a maximální čekací čas úkonu (*max\_execution\_time*) je 30 (180) sekund. Hodnoty před závorkou jsou nastaveny standardně, hodnoty v závorce je možné nastavit po domluvě s administrátory. Hosting nabízí také možnost připojení SSL certifikátu a přepojení aplikace na HTTPS.

Z pohledu vývoje internetové aplikace tak hosting nabízí standardní prostředí pro běh všech potřebných rozhraní a aplikací.

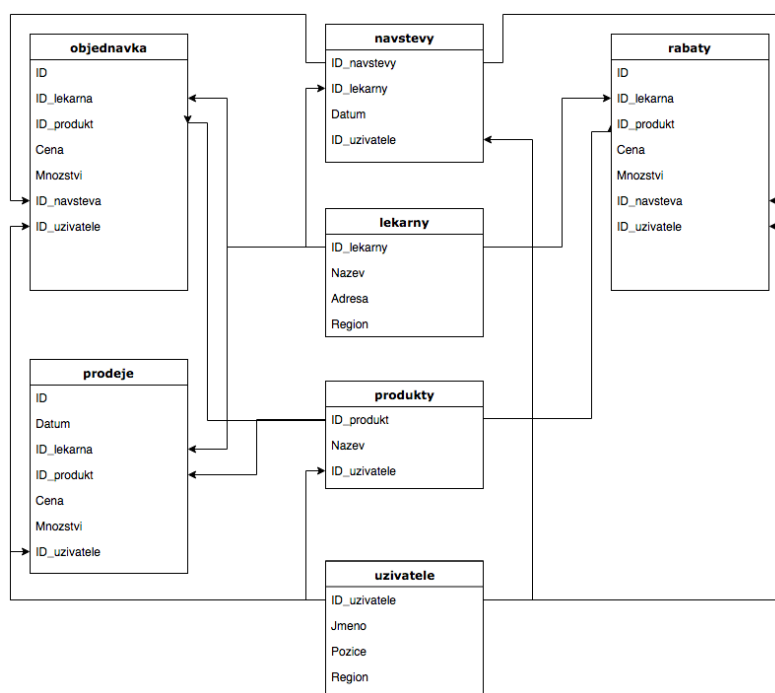
Jelikož aktuální aplikace na daném hostingu běží, její prostředí kopíruje nabízené možnosti.

Používá webový server Apache ve verzi 2.2.16 (Debian) a PHP nižší podporované verze 5.2.17-0. MySQL využívá v nativní verzi 5.7 a HTTP ve verzi 1.1. Dostupná je skrz základní HTTP port 80. Z rozšiřujících knihoven využívá pouze Excelgen Class (v1.0), PHPXBase (v Jan2005) a Crypto-JS (v2.2.0).

Mezi jediný zdroj současné aplikace tak patří cca 2,5GB databáze rozdělená do několika tabulek. Celkový počet tabulek v databázi je přes 20, ale aktivně je používáno následujících 8 tabulek:

- prodeje – Přehled obchodních případů importovaných z velkodistribucí. Tabulka obsahuje podobně jako v datech VD Phoenix pouze křížové odkazy na návazné tabulky „produkty“ a „lekarny“.
- produkty – Seznam produktů společnosti, včetně unikátního ID pro navázání produktů do dalších tabulek a zmenšení velikosti databáze.
- lekarny – Seznam odběratelů společnosti, včetně unikátního ID pro navázání produktů do dalších tabulek a zmenšení velikosti databáze.
- navstevy – Přehled osobních návštěv lékáren uskutečněných obchodním reprezentantem. I zde má každá návštěva unikátní ID pro další propojení napříč systémem.
- objednávky – Přehled objednaných položek při osobních objednávkách. Principiálně stejná tabulka jako „prodeje“, pouze navázaná na ID „navsteva“.
- rabaty – Přehled vydaných rabatu, stejně jako „objednavky“ navázaný na „navsteva“.
- uzivatele – Seznam uživatelů včetně zahashovaných přístupových hesel. Unikátní ID jednotlivých uživatelů je logováno při každé operaci v dalších tabulkách.
- log – Automatický log systémových zpráv.

Náhled provázanosti základních tabulek je zobrazen níže. Zobrazeny jsou pouze nejdůležitější tabulky a jejich nejdůležitější sloupce.



Obr. 15, Současná databázová struktura, zjednodušený model

### 7.3 Technologické požadavky a základní use-cases

Tato část specifikuje zejména základní typy využití a jejich technologické požadavky.

Zatímco původní aplikace Arodata byla navrhována pro použití na osobních počítačích a možnosti využití v jiných typech zařízení jsou omezené (například neoptimalizovanou klávesnicí pro zadávání číselných hodnot, nová verze by měla cílit mimo jiné i na uživatele mobilních zařízení.

#### 7.3.1 Cílová skupina #1 – Obchodní manažer s PC

Základním a co do času stráveného v aplikaci nejvyužívanějším případem využití aplikace zůstane dle předpokladů firmy přístup k aplikaci z PC. Verze určená pro klasické počítače bude mít největší uživatelskou základnu a na tuto verzi také budou kladeny nejvariabilnější požadavky na zpracování a vyhodnocení dat.

Nejtypičtějším uživatelem bude v případě PC verze obchodní manažer, který bude aplikaci používat několikrát denně ke kontrole obchodních zástupců, vyhledávání rizik a příležitostí a vyhodnocování prodejů společnosti. Mezi jeho nároky bude patřit rychlost systému, zjištění nejdůležitějších údajů o výkonnosti obchodních zástupců tzv. „na první pohled“, snadná práce s časovými kontexty, a hlavně co nejrelevantnější seznam skutečných odběratelů.

Mimo již dostupných dat v aplikaci, mezi které patří:

- Přehled osobních prodejů za aktuální měsíc,
- Počet návštěv obchodních reprezentantů na lékárnách a ZV,
- Počet objednávek obchodních reprezentantů na lékárnách a ZV,
- Počet nových odběratelů,
- Suma vydaných rabatů,
- Přehled prodaných ks u sledovaných produktů,

a které by nově měly obsahovat i časový kontext (tj. srovnání se stejným obdobím stejného měsíce před rokem), by měl mít přístup k novým metrikám, které bude aplikace sledovat a počítat automaticky z dat, které v databázi má.

Těmi jsou:

- Suma jedinečných navštívených odběratelů a její vývoj v čase od začátku roku (v této metrice se každý navštívený odběratel počítá v průběhu roku pouze 1), která mu umožní sledovat naplňování stanoveného cíle obchodních reprezentantů.

- Agregovaný obrat jednotlivých obchodních reprezentantů za posledních 12 měsíců proti přechozím 12 měsícům.
- Agregovaný obrat jednotlivých obchodních reprezentantů a celku za současný kalendářní rok proti minulému kalendářnímu roku.
- Velikost kanibalizace nových produktů vůči zavedenému portfoliu v rámci osobních objednávek včetně grafu vývoje za celkový obrat společnosti.

Tento front-endový dashboard poskytne obchodnímu manažerovi všechny podstatné informace na jednom místě bez toho, aby je musel dolovat z databáze v Excelu.

V rámci všech agregovaných pohledů (tj. přehledu počtu prodaných kusů jednotlivých produktů, přehledu obratu odběratelů atd.) by měl mít nově k dispozici možnost zvolit ze dvou časových období, pro které se přímo v aplikaci zobrazí agregovaná data vedle sebe. To mu zjednoduší práci při porovnávání dvou časových období, pro které nebude muset agregovaná data stahovat z aplikace do Excelu a nad nimi tvořit kontingenční tabulky.

Relevance seznamu odběratelů je alfa a omegou již z definice CRM systému a jejímu zlepšení se budu věnovat v následujících částech.

### 7.3.2 Cílová skupina #2 – Obchodní reprezentant s tabletem

Absolutně nejčastěji (co do počtu přístupů) budou aplikaci nejvíce využívat obchodní reprezentanti.

Ti mají k dispozici firemní PC, respektive notebooky, a nově také tablety iPad. Ty v současnosti využívají zejména pro prezentování portfolia produktů na lékárnách, ale cílem společnosti je naučit je využívat je jako mobilní kancelář a většinu administrativy, včetně reportování a transferových objednávek, vyřizovat přímo z terénu hned po návštěvě lékárny. Kromě ekonomických důvodů (tablety jsou pro společnost levnějším řešením než notebooky) jde také o snahu zvýšit kvalitu reportů z lékáren. Cílem obchodních reprezentantů je vést o lékárnách detailní zájmy pro potřeby své nebo zaměstnanců, kteří je v jejich regionu nahradí a s přibývajícím návštěvami, které nastanou mezi jednou lékárnou a jejím zápisem do systému klesá kvalita vzpomínek, o čem obchodní reprezentant na lékárně jednal.

Největší překážkou je pro obchodní reprezentanty nyní neoptimalizovanost systému pro menší displeje, obtížné zadávání záznamů a celková zdoluhavá práce se systémem, který díky JavaScriptu načítá data ad-hoc. I přes zlepšování kvality mobilních sítí, k nimž jsou

tablety nonstop obchodních reprezentantů připojeny, je to stále úzké hrdlo používání tabletu jako administrativního zařízení v terénu.

V terénu potřebují obchodní reprezentanti zejména detailní a rychle dostupné informace o lékárně, kterou se chystají navštívit. Stejně tak, s ohledem na strategii navštěvování všech odběratelů v regionu alespoň jednou ročně, potřebují vědět o všech lékárnách v okolí, ve kterém se právě nacházejí.

Pro jejich potřeby tak bude potřeba, kromě zrychlení aplikace zrušením automaticky načítaných dat, kompletní přepracování uživatelského rozhraní s fokusem na jejich aktuální výkonnost a odběratele v okolí. Nový by měl být také objednávkový formulář, který by měl být použitelný i přímo na lékárně, aby obchodní reprezentant ušetřil svůj čas přepisováním objednávky do reportu z objednávkových listů.

Na obchodnickém prodejním dashboardu potřebuje mít obchodní reprezentant podobné informace jako obchodní manažer s tím, že společnost po zkušenostech s demotivací obchodních reprezentantů při konfrontaci s některými výsledky preferuje u většiny ukazatelů meziroční srovnání konkrétního obchodního reprezentanta, namísto srovnávání aktuální výkonnosti všech obchodních reprezentantů.

Kromě současných ukazatelů, které vidí obchodní reprezentant v aplikaci nyní, a které jsou shodné s údaji uvedenými v use-case #1 (s rozdílem, že obchodní reprezentant vidí pouze výsledky svoje s výjimkou prodejů jednotlivých produktů) by tak na obchodnický dashboard měly přibýt metriky:

- Suma jedinečných navštívených odběratelů a její vývoj v čase od začátku roku (v této metrice se každý navštívený odběratel počítá v průběhu roku pouze 1)
- Agregovaný obrat obchodního reprezentanta za posledních 12 měsíců proti přechodním 12 měsícům.
- Agregovaný obrat obchodního reprezentanta za současný kalendářní rok proti minulému kalendářnímu roku.

### 7.3.3 Cílová skupina #3 – Pracovník marketingu/asistentka – PC

Poslední uživatelským případem využití aplikace, které se podstatně odlišuje od předchozích, je pozice pracovnice marketingu, respektive asistentky společnosti, na které jsou přeusměřované hlavní telefonní linky.

Marketingová pracovnice má na sebe nasměrovanou linku pro komunikaci s širokou veřejností. Vedle běžných dotazů týkajících se obsahu a používání produktů se často jedná o dotazy, ve kterých lékárnách v některé z českých obcí jsou k dispozici konkrétní produkty. Jelikož ne každá lékárna bere veškerý sortiment společnosti, není tuto otázku možné odpovědět výběrem například lékárny s největším obrátem v dané obci.

Asistentka společnosti naopak většinou komunikuje s koncovými prodejci – lékárnami nebo ZV -, kteří se chtějí dozvědět o nabídce produktů. Jejím primárním úkolem je identifikovat, do kterého regionu prodejna patří a nasměrovat je na příslušného obchodního reprezentanta.

Oba úkoly spojuje potřeba znát rychle informace o odběratelích a regionech ze systému.

Pro oba případy (navíc, zákazníci někdy volají na klasickou pevnou linku nasměrovanou na asistentku, namísto volání na zelenou linku) by bylo ideální vytvoření mapy odběratelů s možností vyhledat konkrétní město (a podle něj určit, do kterého regionu spadá) a případné opakované odběratele dotazovaného produktu za poslední tři měsíce (z čehož lze určit, která lékárna drží dané produkty skladem).

#### **7.4 Úprava implementačního řešení velkodistribučních dat**

Stěžejním bodem, kromě úprav uživatelských rozhraní, je přepracování implementačního mechanismu tak, aby byly eliminovány chyby způsobující vytváření duplicitních odběratelů. Jak bylo doloženo v praktické části – chyby vyplývající z pře-prodejů produktů nebo přiřazování prodeje mateřským lékárnám jsou sice neelimitovné, jejich celkový výskyt mezi daty je ale zanedbatelný.

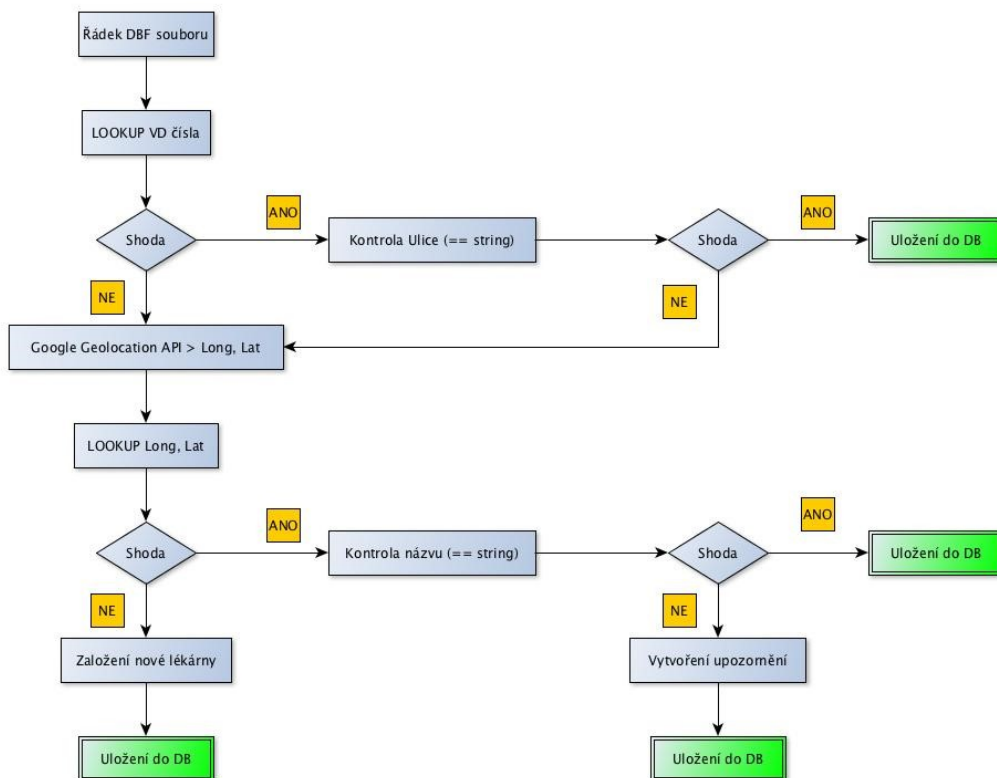
Pro tyto potřeby je nutné celý proces importování vytvořit od základů znovu. S ohledem na analýzu dat velkodistribucí bude inovovaný proces spoléhat primárně na velkodistribuční čísla lékáren. Ta se oproti současnému stavu, kdy samotný import data neviduje, a tak jsou doplňována pouze průběžně obchodními zástupci, budou ukládat přímo z VD dat spolu s adresou a souřadnicemi (viz dále).

Importovací mechanismus tedy nejprve porovná VD číslo lékárny uvedené v importované DBF databázi s aktuální databází již naimportovaných lékáren. Pokud najde shodu, zkontroluje, zda se shoduje název uložené ulice s ulicí uvedenou v DBF databázi. Pokud ano, prodeje automaticky uloží do karty stávající lékárny.

Pokud shodu ve VD čísle a případně ulici nenajde (cca 30-40 případů měsíčně), využije zavolání na Google Maps Geolocation API, kterému odešle adresu lékárny a vyžádá si od něj souřadnice. Ty se pokusí porovnat se současnou databází a zjistit shodu. Pokud na jedněch souřadnicích najde již existující lékárnu (tj. na jedné adrese bude sídlit více prodejců), pokusí se tuto lékárnu ověřit dle jména. V případě, že se lékárna jmenuje stejně, ale má nové číslo, půjde patrně o lékárnu s novým majitelem na stejné adrese. V takovém případě dojde k doplnění údajů a prodejce budou zaneseny do databáze. Jestliže na jedné adrese objeví systém již existující lékárnu, která ale podle názvu neodpovídá datům od velkodistributorů, dojde v systému k vytvoření nové lékárny spolu s vytvoření upozornění (příznaku) u dané lékárny, aby obchodní manažer věděl, že je potřeba Zkontrolovat, zda se jedná o například nákupní centrum, ve kterém byla otevřena zcela nová lékárna, anebo zda jde o například odkup lékárny sítě, která změnila její název.

Pokud systém neobjeví shodu ve VD čísle ani na dané lokaci nebude sídlit jiná provozovna, vytvoří novou lékárnu dané prodejce k ní přiřadí.

Výše uvedený princip je aplikovatelný napříč jednotlivými velkodistribucemi a po otestování může být dále zpřesňován a jednoduše za pomoci dalších pravidel vylepšován.



Obr. 16, Návrh nového procesního modelu importu dat z VD

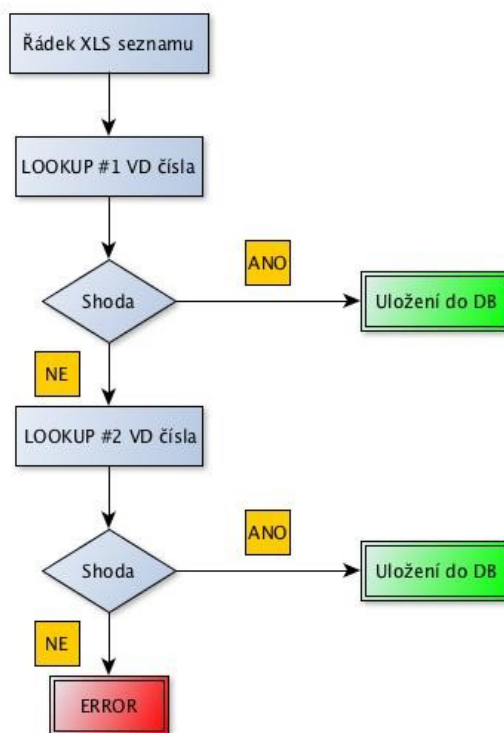
Jakmile bude systém postavený na identifikaci lékáren podle velkodistribučních čísel, dalším krokem pro zkvalitnění výstupů obchodních dat tak může být přiřazení konkrétních lékáren lékárenským sítím. Ty spolupracující jsou dnes schopny pravidelně aktualizovat a zasílat společnosti seznamy lékáren, jenž do jejich sítě patří a na základě těchto seznamů – obsahujících názvy, adresy a hlavně VD čísla jednotlivých lékáren je společnost schopná automaticky rozřazovat lékárny dle dostupné sítě.

Metodika importu je v podstatě zjednodušená metodika importu prodejních dat. Uživatel aplikace do systému nahraje XLS soubor s informacemi o zapojených lékárnách. Formát vstupních dat je buď předvolen automaticky (tj. jsou předpřipraveny vzory importů pro každou síť lékáren podle vzorových dat), anebo bude v ideálním případě uživatel vyzván, aby identifikoval jednotlivé sloupce, ve kterých jsou informace o VD číslech.

Po označení sloupců k identifikaci se systém pokusí vyhledat VD číslo lékárny v interní databázi odběratelů a pokud najde shodu, označí danou lékárnu jako součást sítě.

Jelikož neznáme preference odběratelů při volbě velkodistributora (většina lékáren spolupracuje s více distributory, ale např. 90 % odběrů uskutečňuje přes primárního VD a zbylých 10 % rozděluje mezi zbylé dva) a existuje tak vysoká pravděpodobnost, že má odběratel velkodistribuční číslo, které i přes importy VD dat v systému není, pokračuje importovací mechanismus k číslům lékárny u dalších distributorů a hledá shodu dál. Pokud by shodu nenašel ani u čtvrtého velkodistributora, zobrazí po dokončení importu upozornění na lékárny, které nemohly být identifikovány.





Obr. 17, Procesní model importu dat sítí

## 7.5 Implementace původních databází

Aby byla zachována kontinuita dat, je potřeba pro novou verzi systému upgradovat, či spravit, současná data v databázi. Jelikož budou nově všechna data pro svou identifikaci využívat odběratelská čísla lékáren, nabízí se pro potřeby zajištění zpětné kompatibility využití právě jich.

Společnost disponuje všemi od velkodistributorů obdrženými daty o prodeji od začátku fungování první verze aplikace Arodata, proto je možné pokusit se o importování všech dat zpětně pomocí nového systému importu. Tím by byla zajištěna naprostá konzistence s importy následujícími (všechna data by byla zpracovávána totožným způsobem). Pokud ovšem budeme vycházet z premisy, že každým importem získáme cca 40 nezařaditelných lékáren, čistě aritmetickou metodou dojdeme k číslu necelých 4000 lékáren, které v průběhu importovaných let nebude aplikace postupně schopna přiřadit automaticky a které budou vyžadovat manuální kontrolu.

Nabízí se proto druhá varianta s využitím výše zmíněného Google Maps Geolocation API a pokročilého databázového software schopného provádět dotazy přes aplikační vrstvy internetových služeb – v této práci již zmíněného Google Refine.

Nad všemi aktuálními provozovny evidovanými v Arodatech může být spuštěn geolokační engine, který jim přiřadí zeměpisnou šířku a délku. Z těchto dat v kombinaci s obraty za zvolené období (navrhuji 2 roky) je možné jednorázově vyfiltrovat lékárny:

- Zavřené bez náhrady – na dané adrese sídlí jedná lékárna bez obratu za zvolené období.
- Otevřené s nahrazením – na dané adrese sídlí více lékáren, přičemž pouze jedna nebo dvě měly za zvolené období evidovaný obrat (z nich je vybrána poslední nakupující lékárna).
- Otevřené v obchodních centrech – na dané adrese sídlí více lékáren evidujících obrat s rozdílným názvem a daná adresa je adresou obchodního centra (může být i v kombinaci s předchozím případem, což je potřeba zkontrolovat manuálně).
- Otevřené – lékárny, které během osmi let nezaznamenaly změnu majitele a na dané adrese sídlí samostatně.

Výše zmíněné lékárny je dle potřeby možné podle automaticky přiřazených příznaků (Google Refine podporuje pokročilé podmínky a automatický výběr dat) sloučit a vytvořit tak základní adresář pro následný import dat s přiřazenými čísly velkodistributorů.

Tímto postupem bude zachována kompatibilita původních dat o prodejních případech.

Druhou podmínkou implementace původních dat do nové databáze je vyčištění struktury o nestandardní vyjádření hodnot, resp. změna formátu dat do podoby, která je standardizovaná.

V rámci kontroly datových podkladů byl odhalen jediný, ale podstatný problém využívání atypického formátu pro uchovávání času a data v databázi. Na rozdíl od webového standardu, který formát data stanovuje na podobu YYYY-MM-DD HH:MM:SS (tedy rok-měsíc-den hodina:minuta:vteřina), jsou data v databázi uložena ve formátu YYYYMMDD HH:MM:SS. Tento drobný rozdíl pak může způsobovat nekompatibilitu s aplikacemi třetích stran, které data načítají v souladu s webovými standardy a které by tak s využíváním dat databáze mohly mít problém.

Řešením je jednorázový přepis dat klasickou funkcí CONCATENATE, známou i z tabulkových procesorů typu EXCEL, pomocí SQL příkazu:

```
UPDATE <zvolená tabulka> SET <nový sloupec s datem> = CONCAT(LEFT(datum, 4), "-", MID(datum, 5, 2), "-", RIGHT(datum, 2));
```

Tímto příkazem je pro každý záznam v tabulce upraveno datum do standardní podoby v souladu s webovými standardy MySQL a surová databázová data je možné napojit do dalších aplikací.

## 7.6 Prototyp uživatelského rozhraní

Přestože je projekt zaměřen primárně na technickou stránku aplikace, s ohledem na výsledky projektové části a důrazu na uživatelskou jednoduchost a přívětivost byly vypracovány náhledové studie možného vzhledu aplikace na mobilních zařízeních.

Tento postup práce (nejprve návrh grafiky mobilní verze a až poté desktopové) byl zvolen s ohledem na dvě premisy celé přípravy nové verze aplikace:

- Cílem nové verze aplikace je přiblížení a zjednodušení uživatelského rozhraní uživatelům aplikace na mobilních zařízeních.
- Cílem je udržení konzistence vzhledu mezi desktopovou a mobilní aplikací.

Proto nejprve navrhuji zaměřit se na uživatelský zážitek (UX) mobilní verze a poté tuto předělat pro potřeby klasického desktopu.

V následujících kapitolách proto bude představena mobilní verze aplikace s primárním užitím na zařízeních Apple iPad. Prototypy byly vytvořeny za pomoci aplikace Adobe XD CC.

Cílem této práce není navržení konečného prototypu uživatelského rozhraní, jako spíš nadnesení možností, jak uživatelské rozhraní pojmout, aby splnilo svůj účel. Všechny návrhy proto respektují výše uvedené skutečnosti, ale neobsahují všechny navržené varianty metrik a hodnotících indikátorů z důvodu.

### 7.6.1 Základní uživatelské prvky

Jako většina moderních aplikací, i nová Arodata jsou navržena tak, aby jejich vizuální pojetí co nejvíce zjednodušovalo jejich používání. Celý systém proto provázejí jednoduché pikto-gramy usnadňující orientaci v aplikaci.



Menu aplikace, umístěné v levé části obrazovky, tak obsahuje rychlé odkazy na nejpoužívanější části aplikace:

- Domů
- Přehled osobních obrátů
- Přehled celkových obrátů
- Mapa odběratelů s navigací
- Adresář odběratelů
- Osobní nastavení
- Odhlášení z aplikace

### 7.6.2 Domácí obrazovka

Domácí obrazovkou rozumíme stránku, která bude dostupná hned po přihlášení do systému a bude tak vstupní branou obchodních zástupců i dalších zaměstnanců do systému. Zejména obchodní reprezentanti, kteří na ní uvidí své výsledky v porovnání s ostatními, ji před sebou budou mít několikrát denně.

Je proto vhodné využít jí jako jednoduchá dashboard pro jejich přehled o prodejích a úspěšnosti.



Obr. 18, Náhled úvodní stránky

Již na první pohled by z ní mělo být obchodnímu zástupci jasné, jak si v aktuálním měsíci stojí. V této části tak uvidí nejdůležitější informační grafy své činnosti. Dashboard by měl být z nastavení obchodním manažerem konfigurovatelný a výše uvedené metriky zapnutelné nebo skryitelné podle potřeby obchodního manažera pro daný region.

V této variantě obchodní reprezentanti vidí základní přehled (horní zelená část) svého regionu v číslech – osobní obrat, počet návštěv a počet objednávek, v % vyjádřený oproti stejnému období minulého roku. Je zde také uvažován prvek jednoduché gamifikace, kdy obchodní reprezentanti sice kvůli demotivačním tendencím nevidí ostatní obraty jiných regionů, ale v případě, že je aktuálně nejlepší, zobrazí se mu odznáček s „průběžným 1. místem“.

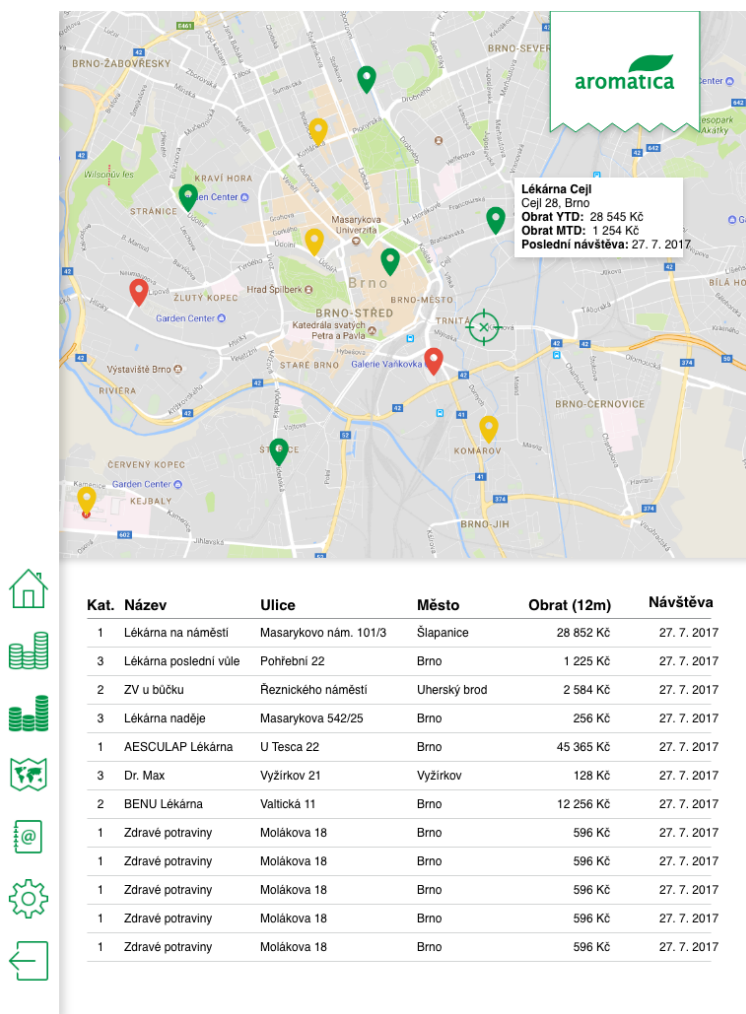
V grafové části ve spodní polovině displeje pak jsou aktuálně zapnuté grafy meziročních prodejů dle kategorií, vývoj obratu za poslední měsíce a graf cílů návštěv lékáren.

### 7.6.3 Mapa odběratelů

Další část aplikace pak představuje vylepšený seznam lékáren s mapou tak, aby měl obchodní reprezentant informace o všech okolních lékárnách podle potřeby. Mapa využívá zjištěné geolokační údaje získané při importu lékáren do systému a na základě prodejních dat umí lékárny „vybarvit“ dle přiřazené obratové kategorie.

Součástí mapy je aktuální poloha obchodního zástupce a možnost zapnout si navigaci na vybranou lékárnu.

Obchodní reprezentanti aktuálně v terénu používají 9,7“ iPady Air, proto je možnost využít tablet jako nepřichází v úvahu, respektive je spíše nebezpečná. Ve spojení s Google Maps SDK for iOS a dalšími API společnosti by ale mělo být možné poslat příkaz na navigaci na připojený telefon, respektive přímo do navigace služebních aut. Těmi jsou ve většině případů vozy Toyota Auris disponující navigací kompatibilní s Google Mapami.



Obr. 19, Náhled seznamu lékáren a mapy

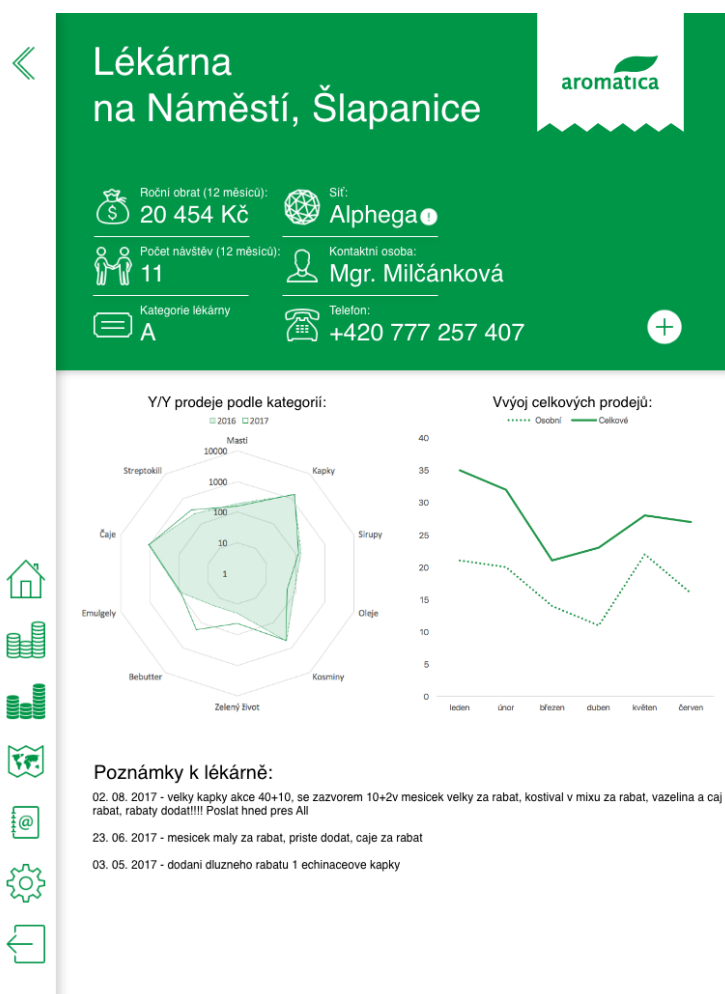
Zbytek této části jinak vychází ze současné verze aplikace – ve spodní části obchodní reprezentanti vidí textový výpis lékáren včetně obratu a poslední evidované návštěvy.

Zejména tato obrazovka by měla obchodním reprezentantům zjednodušit práci a orientaci v terénu a zvýšit % navštěvovaných odběratelů za 12 měsíců.

#### 7.6.4 Detail lékárny

Jedním z cílů vytvoření nové verze aplikace je zlepšení informovanosti obchodních zástupců o poměrech a situaci na lékárnách, které hodlá navštívit. V současné době má obchodní reprezentant k dispozici možnost vyhledat si lékárnu v seznamu odběratelů, aby viděl kontaktní osoby, poznámky a celkový obrat uskutečněný za zvolené období (standardně poslední rok).

Nová verze by to měla změnit a poskytnou obchodním reprezentantům kompletní informační servis.



Obr. 20, Náhled detailních informací o lékárně

V prototypu rozhraní obchodní reprezentanti vidí nejen poznámky a výši obratu za posledních 12 měsíců, ale také síť, do které lékárna patří (včetně informací o centrálně domluvené spolupráci), vývoj obratu lékárny za posledních 12 měsíců (s možným srovnáním za přechozích 12 měsíců) a rozdíl odběru produktů podle kategorií (opět s meziročním srovnáním).

I tyto informace by měly být modulárně volitelné dle požadavků obchodního manažera.

### 7.6.5 Objednávkový formulář

Společnost Aromatica na trh uvádí přes 100 produktů a proto, přestože jinak celý proces objednávky je i v současném systému bezproblémový, chtěla objednávkový formulář zjednodušit a zpřehlednit.



Druhým důvodem lehkého redesignu objednávkového formuláře byla snaha začít tablety k objednávání produktů využívat přímo na lékárnách ve spolupráci s magistrami a majiteli. Z toho důvodu bylo navrženo, aby objednací postup vypadal více jako nákup v klasickém e-shopu, kdy je proces objednávky rozdělen do více kroků. V našem případě dvou – vlastního objednání produktů a následného potvrzení.

Objednávka: Datum návštěvy: 27. 7. 2017

Kategorie	Název produktu	Cena	Objednávka / Rabat
Masti	Měsíčková mast 50 ml	52 Kč	
Emulgely	Měsíčková mast 100 ml	52 Kč	
Balzámy	Kostivalová mast 50 ml	52 Kč	
Kosmin	Kostivalová mast 100 ml	52 Kč	
Bebutter	Měsíčková mast s peruánským balzámem	52 Kč	
Sirupy	Kostivalová mast s kafrem	52 Kč	
Oleje	Rakytňiková mast	52 Kč	
Čaje	Heřmánková mast	52 Kč	
Streptokill			
Zelený život			

**Přehled objednaných položek:**

Měsíčková mast 50 ml	5 ks	154 Kč	
Kosmin po bodnutí hmyzem	1 ks	59 Kč	
Bebutter - Šlehané - rakytňik s pomerančem	2 ks	298 Kč	

**Přibližná cena objednávky: 548 Kč bez DPH**

**Přehled objednaných rabatů:**

Měsíčková mast 50 ml	1 ks	52 Kč	
Echinaceové kapky 50 ml	1 ks	115 Kč	

**Celková hodnota rabatů: 172 Kč bez DPH**  
(22 % z hodnoty objednávky)


Pokračovat k objednávce

Obr. 21, Náhled objednávkového formuláře

Na první stránce objednávkového formuláře byl původní dlouhý seznam rozříděn do kategorií a přibyl i vizuální přehled objednaného zboží a vyskladňovaných rabatů (resp. dárek zdarma). V dalších verzích aplikace je možné zvážit balíčky produktů, respektive předvyplněných rabatových akcí, aby obchodní reprezentant nemusel předpřipravené akce zadávat ručně na dvakrát.

«

## Lékárna na Náměstí, Šlapanice



---

### Přehled objednávky:

**Přehled objednaných položek:**

Měsíčková mast 50 ml	5 ks	154 Kč	<input type="checkbox"/>
Kosmin po bodnutí hmyzem	1 ks	59 Kč	<input type="checkbox"/>
Bebutter - Šlehané - rakytník s pomerančem	2 ks	298 Kč	<input type="checkbox"/>

**Přibližná cena objednávky: 548 Kč bez DPH**

**Přehled objednaných rabatů:**

Měsíčková mast 50 ml	1 ks	52 Kč	<input type="checkbox"/>
Echinaceové kapky 50 ml	1 ks	115 Kč	<input type="checkbox"/>

**Celková hodnota rabatů: 172 Kč bez DPH**  
(22 % z hodnoty objednávky)

- Přidat distributora
- Přidat poznámku distributorovi

Fakturační adresa:	Dodací adresa:	Kontaktní údaje lékárny:
Lékárna na Náměstí Masarykovo nám. 101/3 Šlapanice 66451 IČO: 26963523 DIČ: CZ26963523	Lékárna na Náměstí Nádražní 2211 Šlapanice 66451 IČO: 26963523 DIČ: CZ26963523	<b>Mail:</b> lekarna@slapanice.cz <b>Telefon:</b> +420 254 545 545 <b>Mobil:</b> +420 777 257 407 <b>Souhlas se zasláním OZ:</b> <input checked="" type="checkbox"/>

- Přidat interní poznámku k lékárně

Obr. 22, Náhled objednávkového formuláře, 2. část

Po dokončení objednávání produktů se obchodním reprezentantům a magistrům ukáže shrnutí objednávky včetně možnosti kontroly vyplněných údajů a dodatečných změn.

Na této stránce bude mít obchodní reprezentant možnost zvolit velkodistributora, od kterého bude zboží vykrývat, ale podle kterého se mu zobrazí formulář k přímému objednání, viz níže. Dále bude moci přidat poznámku distributorovi, což využije v případě odesílání zboží z centrálního skladu společnosti, ve kterém oproti ostatním VD může obchodní reprezentant s podmínkami více „čarovat“. Dále je vyzván k doplnění interní poznámky o své návštěvě na lékárně, včetně vyplnění informací o tom, co na lékárně tuto návštěvu představil z portfolia společnosti, jaké akce nabídnul atd.

V souladu s aktuální legislativou GDPR je možné využít tablet jako zařízení k vyjádření souhlasu se zasíláním obchodních sdělení formou podpisu, který se k dané lékárně uloží jako potvrzení jejího souhlasu.

### 7.6.6 Objednávkový formulář – velkodistribuce

Velkodistributoři ani v roce 2018 nenabízejí API, přes které by bylo možné odesílat objednávky do jejich systému automaticky. Nezáleží tedy, zda obchodní reprezentant udělá objednávku na papír nebo v tabletu či jiném elektronickém zařízení – vždy bude nakonec muset přejít na web velkodistributora a objednávku zadat ručně tam.

V rámci aktualizace aplikace se nabízí alespoň částečné usnadnění práce obchodních reprezentantů pomocí využití dual-windows displeje v tabletech Apple iPad. Ten nabízí možnost zobrazit si vedle sebe dvě okna aplikace vedle sebe. Se znalostí pořadí produktů v objednávkách jednotlivých VD tak může aplikace po volbě distributora seřadit objednané položky podle jejich pořadí v objednávkovém formuláři a ve druhém okně otevřít stránky distributora.

Obchodní reprezentant sice bude i nadále muset objednané množství přepsat, ale znalost pořadí mu alespoň ušetří čas.

**Info k objednávce:**  
 Distributor: Phoenix  
 Číslo lékárny: 17054566  
 Magistra: Milčánková

**Přehled objednaných položek:**

Měsíčková mast 50 ml	5 ks
Kosmín po bodnutí hmyzem	1 ks
Bebutter - Šlehané - rakytník s pomerančem	2 ks
Echinaceové kapky 50 ml	40 ks
Jitrocelový sirup Avenisa	2 ks

**Přehled objednaných rabatů:**

Měsíčková mast 50 ml	1 ks
Echinaceové bylinné kapky	10 ks

**Disponibilita na OC**

Zobrazit obsah košíku Vyprázdnit košík nápověda

OZ: Šimůnek Jakub Lékárna: Lékárník: Datum: 02.08.2017 Sortiment

Firma: Aromatica

Název výrobku	Cena s DPH	Br	VM	Množství
AROMATICA Aquamin Vápník 350mg tbl.100.	0	0	0	Objednat
AROMATICA Aquamin Vápník 350mg tbl.30	0	0	0	Objednat
AROMATICA Arobalzám masážní přípr.s jalovcem 100ml	0	0	0	Objednat
AROMATICA Bambucké máslo BIO 75ml	117.25	7	2	Objednat
AROMATICA Bambucké máslo Levandule BIO 75ml	0	0	0	Objednat
AROMATICA Bambucké máslo Rakytník-pomer.Bio 75ml	0	0	0	Objednat
AROMATICA Bílá toaletní vazelína s vit.E 100ml	46.37	149	151	Objednat
AROMATICA Bílá toaletní vazelína s vit.E 500 ml	156.61	17	28	Objednat
AROMATICA Bylinný čaj Cholesterol n.s.20x2g	40.16	17	16	Objednat
AROMATICA Bylinný čaj Čistící n.s.20x2g	40.16	34	27	Objednat
AROMATICA Bylinný čaj Detoxikan n.s.20x2g	40.16	23	42	Objednat

Obr. 23, Náhled transferové objednávky

## 7.7 Implementace databáze do systému třetích stran

Všechny výše zmíněné metriky a jejich vyhodnocování vycházejí z možností a schopností databázového systému MySQL. Jejich implementace do aplikace se dá vyložit jako „dotaz“, který aplikace posílá databázovému systému, a na který dostává odpověď. Pokud chceme například znát celkovou hodnotu prodejů na lékárny za celou dobu existence databáze, použijeme nejjednodušší příkaz:

```
SELECT SUM(obrat) FROM prodeje
```

Všechny další metriky a zjištěné hodnoty jsou v kódu pouhé zpřesnění příkazu a jeho podmínek.

Jelikož pro tento účel musí být všechny metriky před-chystány programátory a každá nová metrika bude vyžadovat administrátorský zásah do systému (aplikace nepočítá s vlastní editorem metrik), nabízí se otázka, jak data pro tvorbu vlastních pokročilých reportů zpřístupnit v databázové aplikaci některé třetí strany, která by umožňovala provádět dotazy na databázi z uživatelského prostředí bez nebezpečí, že ji nějakým špatným zásahem poškodí.

To obchodnímu manažerovi usnadní práci v tom směru, že nebude kvůli každé nestandardní operaci vycházet z hrubých dat stažených do Excelu, ale bude moci s databází pracovat ad-hoc.

Z toho důvodu navrhuji zvážení zavedení do systému Metabase (nebo podobného).

Metabase je v podstatě převodníkem lidské řeči do komplikovaných dotazů jazyka SQL – umožňuje uživateli zvolit jaká data chce z jaké tabulky získat, jaké mají být jejich omezení nebo agregace a jakým způsobem je chce zobrazit. To je například v případě dodatečného plánování metrik nedocenitelné, neboť je obchodní manažer schopen zjistit, jakým způsobem budou data a hodnoty vypadat ještě předtím, než je programátor importuje do systému. Ve výsledku také tento způsob práce podstatně zjednoduší programátorskou práci, jelikož programátor se zadáním obdrží také hotový SQL příkaz, který pouze importuje do systému Arodat.

## 7.8 Odhad časové a finanční náročnosti, komunikace projektu

Časová a finanční náročnost byla zjišťována konzultací se společností Viktorin Computers s.r.o., jmenovitě Ing. Tomášem Petránkem, který měl na starost přípravu původní aplikace Arodata a staral se o její průběžnou aktualizaci. Konzultace byla věnována především časové


a finanční náročnosti úpravy front-endu aplikace a optimalizaci pro mobilní zařízení. Jako druhý konzultující byl pozván Ing. Tibor Peňáz z Masarykovy univerzity, který se v rámci Dixons Carphone věnuje data miningu v rámci Business Intelligence a který poskytl informace k předpokládané časové náročnosti úpravy databáze a tvorbě kódu pro jednotlivé metriky.

### 7.8.1 Časová náročnost projektu

Činnost	Vykonavatel	Optim. varianta	Pesim. varianta
Úprava a čištění databáze	Ing. Tibor Peňáz	20 hodin	40 hodin
Příprava kódů metriky	Ing. Tibor Peňáz	20 hodin	60 hodin
Úprava uživatelského rozhraní	Viktorin Computers s.r.o.	40 hodin	60 hodin
Úprava dílčích exportů	Viktorin Computers s.r.o.	10 hodin	15 hodin
Optimalizace pro mobilní zařízení	Viktorin Computers s.r.o.	5 hodin	10 hodin
Napojení na systém 3 strany	Interně	1 hodina	3 hodiny
	<b>CELKEM</b>	<b>96 hodin</b>	<b>188 hodin</b>

Tab. 3, Časová náročnost projektu

Časy jsou počítány jako čisté, tedy bez doby čekání na odpovědi v případě dotazování na detaily projektu. Zaneseno do Ganttova diagramu je uvažovaná doba deploymentu aplikace následující. Gantt v tomto případě popisuje pouze spuštění hlavní funkcionality aplikace a neuvažuje dodatečné vícepráce ve formě napojování na systémy třetích stran a pokročilých exportů.



Obr. 24, Ganttův diagram projektu

### 7.8.2 Finanční náročnost projektu

S ohledem na povahu této diplomové práce a její zaměření na funkčnost aplikace jde u finanční analýzy aplikace o pouhý kvalifikovaný odhad. Zpřesnění odhadů je možné očekávat až po uspořádání dvou- a třístranných jednání s dodavateli dílčích řešení. Cenová kalkulace pro potřeby tohoto projektu proto vychází z přepočtu obou variant smluvní sazbou obou partnerů. V obou případech shodnou ve výši 500 Kč bez DPH / hod.

V případě optimistické varianty tak vychází předpokládaný náklad na 47 500 Kč bez DPH plus interní náklady společnosti, v případě pesimistické varianty odhad činí 92 500 Kč bez DPH plus interní náklady společnosti.

Interní náklady zahrnující projektový management a implementaci DB do Metabase byly odhadnuty na 10 hodin za každý započatý týden projektu, celkem tedy 50 hodin. Při průměrné super hrubé mzdě managementu firmy cca 270 Kč / hod. jsou odhadované interní náklady cca 13 500 Kč za celý průběh projektu.

### 7.8.3 Komunikace projektu

Jelikož se jedná o vnitrofiremní projekt, komunikace je plánována hlavně pro detailní představení záměru zainteresovaným osobám – jednatelům, obchodnímu manažerovi, obchodním reprezentantům a dalšímu managementu firmy.

Vzhledem k povaze projektu je vhodné celý projekt komunikovat se zaměstnanci již od počátku a mít tak přístup k průběžnému feedbacku.

První meeting pro seznámení se záměrem projektu a představením zde popisovaných plánů navrhuji na polovinu května. V rámci tohoto meetingu očekávám dodatečné nápady všech zainteresovaných stran. Díky dvoutýdenní časové prodlevě je možné tyto připomínky nižších zaměstnanců zpracovat, validovat a případně přidat k projektové dokumentaci projektu.

Následně doporučuji např. mailovou formou nebo krátkými meetingy na týdenní bázi průběžně informovat všechny zainteresované o postupu na projektu. To pozitivně ovlivní přístup zaměstnanců k projektu samotnému a eliminuje pocit tzv. „o nás bez nás“.

Po dokončení projektu na začátku července, s ohledem na velkou prázdninovou poradu obchodních zástupců, potom doporučuji udělat velké společné školení práce v novém systému. Obchodní reprezentanti by zde měli mít kromě klasické prezentace s vysvětlením rozhraní nové aplikace i možnost tzv. imitaci návštěvy na lékárně s kompletním průchodem novým objednávkovým formulářem.

S ohledem na slabší sezónu v průběhu letních prázdnin, která platí nejen v médiích, ale i obecně v maloobchodě, budou mít obchodní reprezentanti ideální prostor na reálné zažití prvních zkušeností, pozitivních i negativních. V rámci příprav projektu a diskusí počítáme s časovými prodlevami a zprvu pomalejší práci obchodních reprezentantů v terénu po zavedení nové verze. Ovšem, byť výběr data realizace závisel na jiných faktorech než na práci

obchodních reprezentantů, červenec a srpen budou ideálními měsíci, kdy si obchodní reprezentanti vše v klidu vyzkouší, aby pak do nejexponovanějších měsíců nastoupili řádně připraveni.

Kromě prvního vstupního školení plánovaného na červenec tak budou obchodní reprezentanti znovu proškoleni v září, kde jim kromě vysvětlení dotazů budou znovu zopakovány důvody k nastavenému workflow.

Časový harmonogram představení projektu včetně předpokládaných aktivit a finanční náročnosti je následující.

Měsíc	Týden	Aktivita	Odpovědná osoba	Počet účastníků	Počet hodin
6	23	Úvodní meeting s představením záměru	JŠ	13	3
6	24	Update meeting s managementem	JŠ	6	1
6	25	Update meeting s managementem	JŠ	6	1
6	26	Update meeting s managementem	JŠ	6	1
6	26	Představení dílčích novinek OR	TB	6	1
7	27	Školení OR a managementu	JŠ	13	3
7	27	Testování aplikace na use-cases	TB	6	4
7	28	Meeting k dokončení projektu / kontrola	JŠ	6	2
8	31	Druhé proškolení OR	TB	6	3
8	32	Druhé proškolení managementu	JŠ	6	3

Tab. 4, Komunikace projektu

(TB – Tomáš Bartusek, JŠ – Jakub Šimůnek)



## ZÁVĚR

Tato práce se zabývala přípravou projektu nové verze obchodně-analytického software pro společnost AROMATICA CZ s.r.o.

Za své cíle si stanovila zjistit dostupné informace pro data mining na poli farmaceutického průmyslu, aktuálně používané metriky a důvody využití data miningu v obchodní praxi společnosti. Dále jak tyto informace použít pro zlepšení postavení obchodních zástupců společnosti v terénu a jak připravit projekt pro vývojářskou společnost, která jí software zpracuje.

Z toho důvodu v ní byla provedena rešerše veřejných i neveřejných zdrojů, které popisují český trh, zejména pak primárních sell-out dat českých farmaceutických velkodistributorů, kteří poskytují data o obchodních případech produktů společnosti na konkrétní české lékárny. Dále byly s pomocí aktuálních, zejména internetových, zdrojů zjištěny metriky, které jsou v oblasti prodeje při data miningu využívány včetně ověření proveditelnosti. Nakonec potom bylo nastíněno, jak je možné zjištěné informace použít v praxi.

V teoretické části byly stanoveny základní výzkumné otázky:

- Jaké informace jsou nejdůležitější pro jednotlivé úrovně managementu?
- Zisk jakých informací tvoří největší překážku ke zvýšení relevance reportů?
- Jak zlepšit UX a UI software a zpřístupnit tak relevantní data v co nejširší formě i méně technicky zdatným uživatelům?

V případě nejdůležitějších informací z rozhovorů s manažery firmy bylo zjištěno, že se jedná zejména o vývoj prodeje jednotlivých obchodních zástupců v časových kontextech – meziroční, meziměsíční -, a mezi sebou. Dále to jsou vývoje obrátů jednotlivých lékáren a jejich skupin (sítí). Pro nižší management, obchodní reprezentant, jsou to mimo výše zmíněných celkových prodejů informace o prodejích, které obchodní reprezentant zajistil sám svou návštěvou na lékárně a také meziroční srovnání prodejů produktů v jednotlivých kategoriích.

Aktuálně největší problém má společnost se správným nastavením postupu importu dat od velkodistributorů do svého systému, jak ukázala kvalitativní analýza současných dat s pomocí obchodních reprezentantů. Navržená metodika importu, která je určená pro novou generaci aplikace by tento problém měla eliminovat, byť z podstaty věci jej nikdy 100% nevyřeší a zachování maximální míry relevance dat bude vždy vyžadovat jednorázové zásahy a kontroly systému.

Zlepšení UX by dle rozhovorů s vedením firmy mělo být dosaženo zrychlením aplikace za použití modernějších vývojářských nástrojů a technologií. UI by mělo zůstat rámcově zachováno i přes předělání celého front-endu aplikace. Navíc je na základě analýz možné eliminovat některé již nevyužívané prvky aplikace, které nyní překáží a zbytečně rozhraní aplikace znepřehledňují.

## SEZNAM POUŽITÉ LITERATURY

A. EDELSTEIN, Herbert. Introduction to Data Mining and Knowledge Discovery. 2nd edition. Potomac (Maryland): Two Crows, 1998. ISBN 978-1892095008.

BROOKS, Chad. What is Data Mining?. Business News Daily [online]. USA: Business News Daily, 2014 [cit. 2018-04-14]. Dostupné z: <https://www.businessnewsdaily.com/5947-data-mining.html>

ČERNÝ, Michal. Big data a jejich zpracování. Root.cz [online]. CZ: Root.cz, 2013 [cit. 2018-04-17]. Dostupné z: <https://www.root.cz/clanky/big-data-a-jejich-zpracovani/>

Český statistický úřad [online]. CZ: Český statistický úřad, 2018 [cit. 2018-04-17]. Dostupné z: [www.czso.cz](http://www.czso.cz)

COLUMBUS, Louis. Ten Ways Big Data Is Revolutionizing Marketing And Sales. Forbes.com [online]. USA: Forbes, 2016 [cit. 2018-04-17]. Dostupné z: <https://www.forbes.com/sites/louiscolombus/2016/05/09/ten-ways-big-data-is-revolutionizing-marketing-and-sales/#12ef3c0d21cf>

DE MAURO, Andrea, Marco GRECO a Michele GRIMALDI. A formal definition of Big Data based on its essential features. Library Review. 2016, 65(3), 122-135. DOI: 10.1108/LR-06-2015-0061. ISSN 0024-2535. Dostupné také z: <http://www.emeraldinsight.com/doi/10.1108/LR-06-2015-0061>

HAN, Jiawei, Micheline KAMBER a Jian PEI. Data mining: concepts and techniques. 3rd ed. Haryana, India ; Burlington, MA: Elsevier, 2012. ISBN 978-938-0931-913.

HETHERINGTON, Victoria. The Dashboard Demystified: What is a Dashboard?. Dashboard insight [online]. USA: Dashboard insight, 2009 [cit. 2018-04-17]. Dostupné z:

<http://www.dashboardinsight.com/articles/digital-dashboards/fundamentals/the-dashboard-demystified.aspx>

INGERSOLL, Grant S., Thomas S. MORTON a Andrew L. FARRIS. Taming text: how to find, organize, and manipulate it. Shelter Island: Manning, 2013. ISBN 978-1-933988-38-2.

LYMER, Andrew. Business reporting on the Internet: a report prepared for the International Accounting Standards Committee. London: Internat. Accounting Standards Comm, 1999. ISBN 09-056-2577-3.

MADERER, Jason. Using Data Mining to Make Sense of Climate Change. Georgia Technical University [online]. USA: Georgia Technical University, 2018 [cit. 2018-04-17]. Dostupné z: <http://www.news.gatech.edu/2018/01/17/using-data-mining-make-sense-climate-change>

MAIMON, Oded. a Lior. ROKACH. Data mining and knowledge discovery handbook. 2nd ed. New York: Springer, c2010. ISBN 978-0-387-09822-7.

MAKSYMIUK, Mateusz. Customer Loyalty Schemes Case Study: Tesco Clubcard. In: Prezi.com [online]. USA: Prezi.com, 2015 [cit. 2018-04-14]. Dostupné z: <https://prezi.com/b0kscw3ll54l/customer-loyalty-schemes-case-study-tesco-clubcard/>

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.

PALM.COM, U.S. Robotics Announces Two New Models of the Best Selling Pilot Connected Organizer. Palm.com [online]. USA: Palm, 1997 [cit. 2018-04-17]. Dostupné z: [https://web.archive.org/web/20030815030604/http://www.palm.com/us/company/pr/1997/pressrel\\_palm20.html](https://web.archive.org/web/20030815030604/http://www.palm.com/us/company/pr/1997/pressrel_palm20.html)

PAPEŽOVÁ, Edita. Řízení vztahu se zákazníky. Brno, 2004. Diplomová práce. Masarykova univerzita.

PATEL, Neil. 10 Ways Data Mining Can Help You Get a Competitive Edge. Kissmetrics [online]. USA, 2017 [cit. 2018-04-14]. Dostupné z: <https://blog.kissmetrics.com/data-mining/>

PETR, Pavel. Data Mining. Vyd. 2. Pardubice: Univerzita Pardubice, 2008-. ISBN 978-80-7395-098-9.

ROUSE, Margaret. What is data mining?. TechTarget.com [online]. USA: TechTarget, 2017 [cit. 2018-04-17]. Dostupné z: <http://searchsqlserver.techtarget.com/definition/data-mining>

SINHA, Swati. AI and machine learning in sales: Everything you need to know for the future. The Future of Commerce [online]. USA: The Future of Commerce, 2017 [cit. 2018-04-14]. Dostupné z: <http://www.the-future-of-commerce.com/2017/11/29/ai-and-machine-learning-in-sales/>

Státní ústav pro kontrolu léčiv [online]. CZ: Státní ústav pro kontrolu léčiv, 2018 [cit. 2018-04-17]. Dostupné z: [www.sukl.cz](http://www.sukl.cz)

TREMBLAY, Sylvain. The History of CRM: A Consultant's Perspective. CRM Software-Blog [online]. USA: CRM SoftwareBlog, 2014 [cit. 2018-04-14]. Dostupné z: <https://www.crmsoftwareblog.com/2014/02/the-history-of-crm-a-consultants-perspective-part-one/>

WILLIAMS, Mike. Best CRMs for SMBs in 2017. TechRadar.com [online]. USA: TechRadar.com, 2017 [cit. 2018-04-17]. Dostupné z: <https://www.techradar.com/news/software/business-software/10-crm-systems-small-businesses-should-know-1250344>

ZEISIG, Katyia. 12 sales metrics to kick-start your sales analytics. Klipfolio [online]. USA: Klipfolio, 2018 [cit. 2018-04-14]. Dostupné z: <https://www.klipfolio.com/blog/sales-analytics-12-metrics>

**SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK**

CRM	Customer relationship management
CSV	Comma-separated value, textový databázový soubor
Front-end	Vizuální stránka aplikace (to, co vidíme na obrazovce)
GUI	Grafické uživatelské rozhraní
OC	Obchodní centrum velkodistributora
XLS	Dokument programu Microsoft Excel
DBF	Databázový dokument formátu dBase
SW	Software
VD	Velkodistributor
ZV	Zdravá výživa

**SEZNAM OBRÁZKŮ**

Obr. 1, Vývoj CRM systémů .....	16
Obr. 2, Graf růstu obratu.....	21
Obr. 3, Graf plnění cílů .....	21
Obr. 4, Graf růstu dosavadních prodejů.....	22
Obr. 5, Graf prodejů po kategoriích.....	22
Obr. 6, Graf konverzního poměru.....	23
Obr. 7, Graf kanibalizace starých produktů .....	23
Obr. 8, Graf prodejů dle obchodníků .....	24
Obr. 9, Graf hodnoty objednávky .....	24
Obr. 10, Graf prodeje dle regionu .....	25
Obr. 11, Obrazovka zadání nové objednávky .....	37
Obr. 12, Náhled úvodní stránky .....	38
Obr. 13, Návrh úpravy grafu osobních objednávek .....	46
Obr. 14, Náhled pavučinového grafu.....	47
Obr. 15, Současná databázová struktura, zjednodušený model .....	58
Obr. 16, Návrh nového procesního modelu importu dat z VD.....	63
Obr. 17, Procesní model importu dat sítí .....	65
Obr. 18, Náhled úvodní stránky .....	69
Obr. 19, Náhled seznamu lékáren a mapy .....	71
Obr. 20, Náhled detailních informací o lékárně.....	72
Obr. 21, Náhled objednávkového formuláře .....	73
Obr. 22, Náhled objednávkového formuláře, 2. část .....	74
Obr. 23, Náhled transferové objednávky .....	75
Obr. 24, Ganttův diagram projektu .....	78



**SEZNAM TABULEK**

Tab. 1, Ukázka dat ze systému .....	35
Tab. 2, Přehled datových polí v souborech velkodistributorů .....	43
Tab. 3, Časová náročnost projektu.....	77
Tab. 4, Komunikace projektu .....	80

## SEZNAM PŘÍLOH