



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

Fakulta elektrotechnická

Katedra ekonomie, manažerství a humanitních věd

**Aktuální trendy v manažerských informačních systémech
a systémech pro podporu rozhodování**

**Present State of Management Information System and Decision
Support System**

Bakalářská práce

Studijní program: Softwarové technologie a management
Studijní obor: Manažerská informatika

Vedoucí práce: Ing. Pavel Náplava

Barbora Tomková

Praha 2014

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Student: **Tomková** Barbora

Studijní program: Softwarové technologie a management
Obor: Manažerská informatika

Název tématu:

Aktuální trendy v manažerských informačních systémech a systémech pro podporu rozhodování

Pokyny pro vypracování:

1. Specifikace pojmu manažerský informační systém a systém pro podporu rozhodování
2. Analýza existujících řešení
3. Možné způsoby využití systémů
4. Případová studie vhodného využití a nasazení MIS

Seznam odborné literatury:

1. Novotný O., Pour J., Slánský D.: Business intelligence, GRADA, 2005.
2. Pour J., Maryška M., Novotný O.: Business intelligence v podnikové praxi, GRADA, 2012.

Vedoucí bakalářské práce: Ing. Pavel Náplava

Platnost zadání: do konce letního semestru 2014/2015

Doc. Ing. Jaroslav Knápek, CSc.

vedoucí katedry



Prof. Ing. Pavel Ripka, CSc.

děkan

Prohlášení

Prohlašuji, že jsem bakalářskou práci vypracovala samostatně a v souladu s Metodickým pokynem o dodržování etických principů pro vypracování závěrečných prací, a že jsem uvedla všechny použité informační zdroje.

V Praze dne.....

.....

Podpis

Poděkování

Tímto chci poděkovat především vedoucímu práce Ing. Pavlu Náplavovi za odborné vedení, trpělivost, vstřícný přístup, užitečné rady, připomínky a podněty, které vedly k dokončení této práce.

Dále chci poděkovat přátelům za psychickou podporu nejen při psaní této práce, ale během celého studia.

Abstrakt

Cílem této práce je představit manažerské informační systémy a systémy pro podporu rozhodování, které slouží k podpoře řízení firmy. Dalším cílem je pak ukázat možné využití těchto systémů a předvést, že najdou uplatnění i v malých a středních podnicích.

První část je věnována definici těchto systémů, kde jsou mimo jiné popsány i jejich jednotlivé komponenty. V druhé části jsou představeny hlavní poskytovatelé, a to nejen ti největší hráči na poli manažerských systémů, ale i představitelé open source a cloudových řešení. Třetí část je přechodem mezi teoretickou a praktickou částí. Na vzorových příkladech jsou v ní ukázány možná využití systému. A nakonec čtvrtá část blíže popisuje návrh a nasazení systému. Pro lepší názornost je vypracována ve formě případové studie, která se nejprve zabývá rozbořením zákazníka, pro kterého je pak navrženo optimální řešení. Pro účely této studie jsem si vyzkoušela některé BI nástroje, a to především nástroje společnosti Pentaho. Celá případová studie je završena vyhodnocením přínosů systému.

Klíčová slova: MIS, DSS, EIS, manažerský informační systém, systém pro podporu rozhodování, Business Intelligence, BI, Datový sklad, DWH

Abstract

The goals of this thesis are to introduce management information systems and decision support systems and to show the possible uses of these systems and to demonstrate that these systems can find application in small and medium-sized enterprises.

In the first part of this thesis there are defined these systems and described the components of these systems. In the second part there are presented the main providers - the biggest players as well as providers of open source and cloud computing solutions. The third part is the transition between the theoretical and practical parts. Several examples show the potential uses of the system. In the final - practical part there is described the design and deployment of the system in detail. This part is in the form of case studies, which initially focuses on the analysis of the customer and after that it is designed for optimal solutions. To demonstrate the possible uses of system I tried BI tools of Pentaho company. The study is concluded with the results of the deployed solution .

Keywords: MIS, DSS, EIS, Management Information System, Decision Support System, Business Intelligence, BI, Data Warehouse, DWH

Obsah

1 Úvod	1
2 Specifikace pojmu manažerský informační systém.....	2
2.1 Definice základních pojmů	2
2.2 Postavení systémů v informační strategii firmy	2
2.3 Business Intelligence	4
2.3.1 Metadata	5
2.3.2 Datový sklad a datové tržiště	5
2.3.3 Transformace dat	7
2.3.4 Dočasná a operativní uložení dat	8
2.3.5 Multidimenzionalita dat	8
2.3.6 OLAP databáze.....	10
2.3.7 Analýza dat	10
2.3.8 Prezentace	10
2.4 Corporate Performance Management.....	11
2.4.1 Metodiky	12
2.4.2 Metriky	12
2.4.3 Technologie	13
2.4.4 Zavedení CPM.....	13
2.5 Business Analytics.....	14
2.5.1 Big data.....	14
2.5.2 In-memory Analytics.....	15
2.5.3 Prediktivní analýza.....	15
2.5.4 Vizualizace dat.....	15
2.5.5 Zavedení BA.....	15
2.6 Shrnutí	16
3 Analýza existujících řešení.....	16
3.1 Historie a vývoj MIS.....	16
3.2 Aktuální situace na trhu	16
3.3 Proprietární řešení.....	17
3.3.1 Microsoft	18
3.3.2 IBM	18
3.3.3. Oracle	19
3.3.4 SAP.....	19
3.4 Open source řešení.....	19
3.4.1 Pentaho	19

3.5 Cloudové řešení.....	20
3.6 Průzkum trhu.....	20
4 Možné způsoby využití systému.....	23
4.1 Příklad: Doprava.....	24
4.2 Příklad: Soukromý pivovar.....	26
4.3 Příklad: Cestovní kancelář.....	29
5 Případová studie.....	30
5.1 Zákazník.....	30
5.1.1 Představení zákazníka.....	30
5.1.2 SWOT Analýza.....	30
5.1.3 Firemní procesy.....	32
5.1.4 Uživatelé systému.....	32
5.1.5 Funkční a nefunkční požadavky zákazníka.....	32
5.2 Řešení.....	32
5.2.1 Datový sklad.....	33
5.2.2 ETL.....	35
5.2.3 OLAP kostky.....	36
5.2.4 What-if analýza.....	36
5.2.5 Reporting.....	38
5.2.6 Presentace dat.....	39
5.2.7 Kalkulace.....	40
5.3 Přínosy řešení.....	40
5.4 Zhodnocení případové studie.....	41
6 Závěr.....	41
7 Seznam použité literatury.....	42
8 Seznam použitých zkratk.....	44

1 Úvod

Manažerský informační systém hraje důležitou roli v řízení podniku. Aby každá firma fungovala a byla úspěšná, je třeba činit správná rozhodnutí. Ta ovšem nemůžeme dělat, aniž bychom pro to měli odpovídající podklady. Už v dřívějších dobách, kdy nebyla k dispozici počítačová technologie, si firma musela vést nějaké záznamy alespoň v papírové podobě. Na jejich základě se pak mohlo rozhodnout, například kolik kupovat jakého zboží, na co se více zaměřit a podobně. Dnes k tomuto účelu slouží manažerské informační systémy a systémy pro podporu rozhodování. V praxi se spíše než s těmito názvy setkáváme s termínem Business Intelligence. Tento nepřekládaný výraz zahrnuje nástroje a technologie pro analýzu firmy.

Cílem mé práce je čtenáře seznámit s manažerskými informačními systémy a systémy pro podporu rozhodování. Nejen tyto termíny definovat, ale také představit a popsat jednotlivé komponenty těchto systémů a jednoduše vysvětlit jak fungují. Poté, co se s těmito systémy seznámíme, se blíže podíváme na vybraná řešení a jejich poskytovatele a uvedeme příklady, kdy se hodí využití těchto systémů. Cílem praktické části je pak navrhnout a ukázat možné řešení na vybraném příkladu.

2 Specifikace pojmu manažerský informační systém

V této kapitole vysvětlím, co znamenají pojmy manažerský informační systém (dále jen MIS) a systém pro podporu rozhodování (dále DSS) a definuji související výrazy. Poté popíši a objasním, jak tyto systémy fungují a jaké nástroje a technologie zahrnují.

Když se řekne *manažerský informační systém*, málokdo si pod tímto pojmem představí něco konkrétního. O slovech manažer, informace, informatika či systém máme ponětí, i když ne všechny termíny bychom dokázali spatra definovat. S termínem *systém pro podporu rozhodování*, na tom nebudeme o moc lépe, ale rozhodně můžeme odvodit, že souvisí s rozhodováním při řízení firmy.

2.1 Definice základních pojmů

Začnu tedy od základu. Termín *informace* je známý všem, přestože pro některé může být problém ho popsat. Informace má mnoho významů a existuje mnoho definic. Obecně se dá popsat jako obsah nějaké zprávy. V teorii informačních systémů rozlišujeme tyto pojmy [4]:

- *data* získáváme měřeními či pozorováními (nějaká sekvence znaků např.: „1S2 0400“ nebo „zelená“),
- *informace* jsou data, kterým přisuzujeme nějaký význam (před domem stojí zelené auto státní poznávací značky 1S2 0400),
- *znalosti*, které vycházejí z nabytých informací.

Tak i tak se jedná o určitý údaj, na který můžeme pohlížet z více aspektů. Pro zjednodušení budeme všechny tyto termíny souhrnně nazývat informace.

Systém je neprázdna množina prvků a vazeb mezi nimi, které jsou uspořádány do smysluplného celku [3]. Předmětem *informačního systému* (dále jen IS) je informace. IS sbírá, ukládá a zpracovává informace, které jsou pak předány dál ať pro další IS nebo k jejich prezentaci. Příkladem IS může být například knihovní katalog, on-line rezervace letenek, ale také obyčejný telefonní seznam. MIS a DSS jsou informační systémy sloužící řídicím pracovníkům a managementu. MIS se zabývá řízením podniku na taktické úrovni, uchovává a zpracovává firemní data, které pak slouží k analýze. DSS navíc zahrnuje úlohy pro podporu rozhodování.

2.2 Postavení systémů v informační strategii firmy

Informační systémy se dají rozdělit z mnoha hledisek: funkčnosti, zaměření, režimu činnosti a tak dále. Pro naše účely, a to vysvětlení role MIS a DSS v podnikové informatice, si IS rozdělíme podle postavení ve struktuře firmy, k přehlednosti nám poslouží informační pyramida (Obr. 1).



Obr. 1 Informační pyramida

Na nejnižší úrovni se nachází informační systémy zaměřené na operativu. Sem patří např. systémy CRM (řízení péče o zákazníka), RIS (rezervační IS), TPS (transakční IS), databáze ERP (IS pro řízení podnikových zdrojů) a mnoho dalších. Operativní systémy zajišťují fungování firmy a ve svých databázích udržují stále aktuální data, čímž se liší od manažerských systémů, které jsou stabilnější a uchovávají i několik dní stará data. Jak je vidět na obrázku, z operativních systémů čerpají data systémy pro podporu managementu. Právě sem patří MIS a DSS. Zatímco v ostatních systémech se data vytvářejí a pak se mohou dále zpracovávat, tyto systémy data pouze analyzují. Výstupy těchto analýz slouží pak jak managementu k rozhodování a řízení firmy, tak vrcholovému managementu.

Tím se dostáváme na pomyslný vrchol pyramidy. Sem patří EIS (Executive Information System), který podporuje vrcholové řízení společnosti. Výstupem těchto systémů jsou vysoce agregovaná strukturovaná data. Tato data dávají přehled o situaci firmy a navíc umožňují modelovat hypotetické situace a jejich dopady, což opět pomáhá rozhodování.

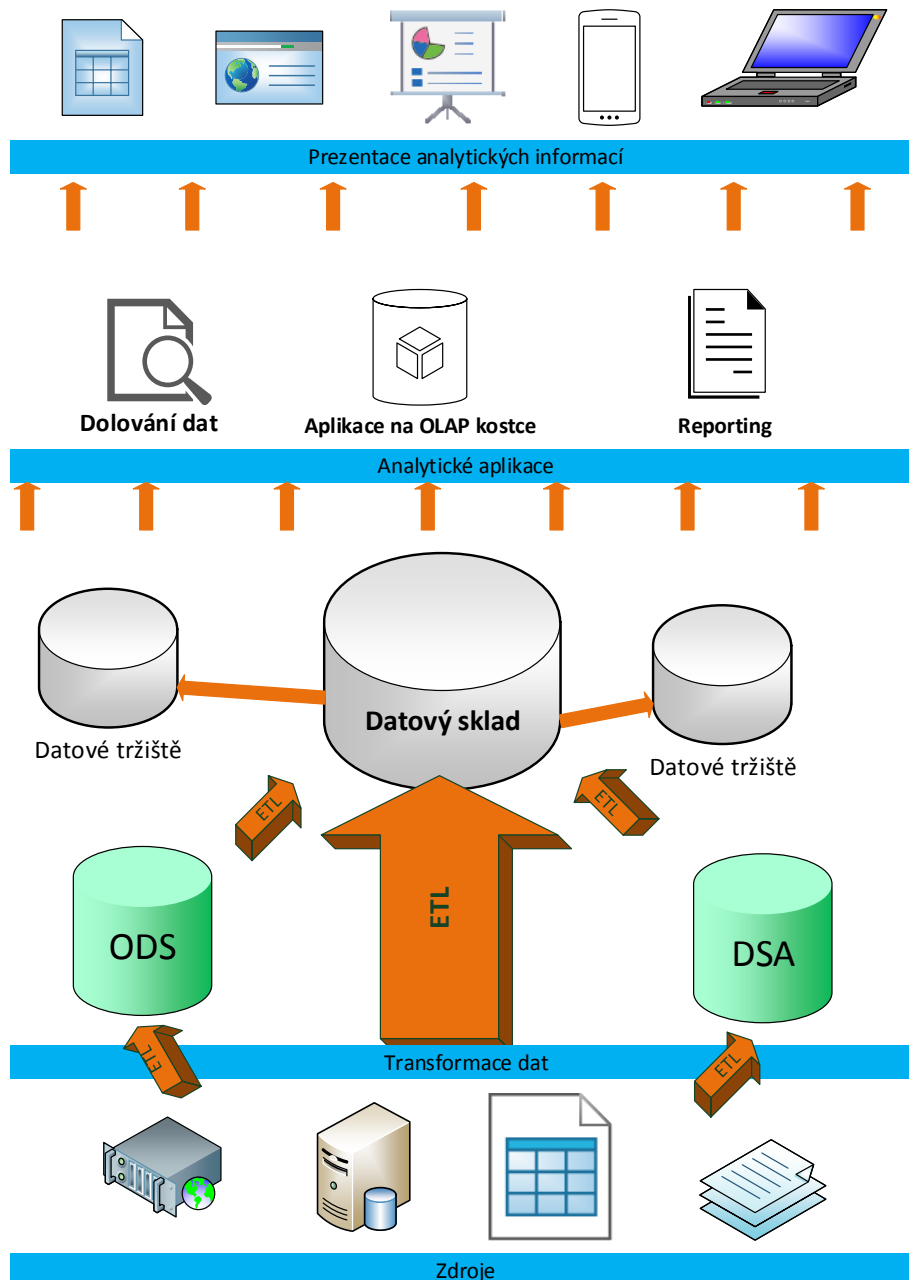
Asi může být matoucí jaký je rozdíl mezi všemi těmito systémy. Jak už bylo řečeno, tak MIS a DSS slouží managementu k rozhodování a řízení firmy a to na taktické nebo operativní úrovni, což zahrnuje krátkodobější plánování a zaměření na konkrétnější cíle. EIS se zabývá strategickým plánováním, tedy dlouhodobým plánováním ovlivňujícím směřování celé firmy.

Pro představu poslouží následující příklad. Zaměstnanec zadá do systému údaje například, že na své pobočce prodal zboží se specifickým kódem, cenou atd. Z těchto dat můžeme sice rovnou získat jednoduchý přehled jako počet prodaného zboží, tržbu konkrétního zaměstnance a podobně. Na rozdíl od toho, MIS sesbírá data z více systémů a dá nám o dané situaci širší přehled, například objem tržby v čase, podle zákazníků, prodejen atp. V těchto analýzách můžeme najít a spatřit fakta, která bychom jinak nezjistili, a která můžeme využít při řízení firmy. A nakonec, vrcholovému vedení firmy se

dostanou informace o celkovém stavu firmy v co možná nejpřehlednější formě (například balanced scorecard, o kterém píšu později – kapitola 2.3.8).

2.3 Business Intelligence

Existuje více pojetí Business Intelligence (dále BI) a jeho vztahu k manažerským informačním systémům. V této práci pojmem BI jako synonymum ke všem těmto systémům. Zatímco MIS a DSS je spíše náležitostí managementu, BI je pojato více technicky. BI je souhrn nástrojů, aplikací, technologií, ty jednoduše řečeno slouží ke konverzi velkých objemů dat na poznatky, které poslouží koncovému uživateli. Tento nástroj slouží nejen jako podpora řízení firmy, ale k celkovému pochopení aktuální situace trhu a predikci budoucího vývoje. Jak funguje BI je vidět na následujícím obrázku (Obr. 2).



Obr. 2 Obecná architektura BI

V BI se klade především důraz na kvalitu informací. Ta se posuzuje ze čtyř hledisek: dostupnost, přesnost, úplnost a konzistence. To vše by mělo být zajištěno už v databázích operativních IS, ačkoliv tomu tak někdy nebývá. Proto je často na ETL procesech aby mimo jiné zajistily kvalitu dat. ETL (Extract, Transform, Load) nebo také datová pumpa má na starost extrahování dat ze zdrojových databází (taková, která jsou určena pro analytické, plánovací a rozhodovací aktivity podniku), jejich úpravu a nahrání do datového skladu (DWH). Data z datového skladu se dále analyzují, takže buď můžeme získat informace o aktuálním stavu, ale i předpovědět jak se daný stav bude dále vyvíjet. Právě tyto informace se pak zobrazují např. pomocí dashboardů (kapitola 2.3.8) koncovému uživateli.

2.3.1 Metadata

Před tím než se rozepíšu o jednotlivých komponentách BI, je třeba vysvětlit pojem *metadata*, která hrají v BI důležitou roli. Metadata jsou strukturovaná data o datech. Nedávají ale jen informace o samotných datech, ale také o vztazích mezi nimi, a jak se mohou vzájemně ovlivňovat. Kvalitní metadata jsou jednoznačná a mají prokazatelný původ.

Metadata mají různé funkce: identifikační (při shodném jméně dvou uživatelů), výběrová, popisná a dokumentační, archivační a mnoho dalších. V BI se využívají například pro popis zdrojových systémů, pro popisy transformačních pravidel u datového skladu nebo k vysvětlení každého pole reportu při reportingu.

Rozlišují se tři typy metadat:

- **Business metadata** slouží především koncovému uživateli, aby pochopil obsah dat. Popisují, odkud data pochází, co znamenají a jaký mají vztah k ostatním datům datového skladu. Dají se užít i jako dokumentace k datovému skladu, který popíšu později (kapitola 2.3.2). Jako příklad uvedu údaj „tomkobar“. Metadata říkají, že je to login uživatele se jménem *Barbora* a příjmením *Tomková*, že je v roli studenta a další vztahy.
- **Technická metadata** dávají kontextové informace o datových zdrojích, nástrojích, datovém typu atp. Slouží především IT pracovníkům pro údržbu datových zdrojů a vývoj ETL procesů nebo reportů. Vrátil-li se zpět k případu „tomkobar“, technická metadata říkají, že se jedná o datový typ String a že pochází z tabulky „students“ (například).
- **Operační metadata** popisují jednotlivé výsledky během různých operací v datovém skladu. Například uživatel *Tomková* si změnil heslo, což se projeví po proběhnutí ETL procesů. Kromě toho že metadata zaznamenají čas spuštění a ukončení ETL procesů, zaznamenají, že nastala změna hesla uživatele „tomkobar“. Operační metadata také zachycují, kdy a jak je datový sklad využíván.

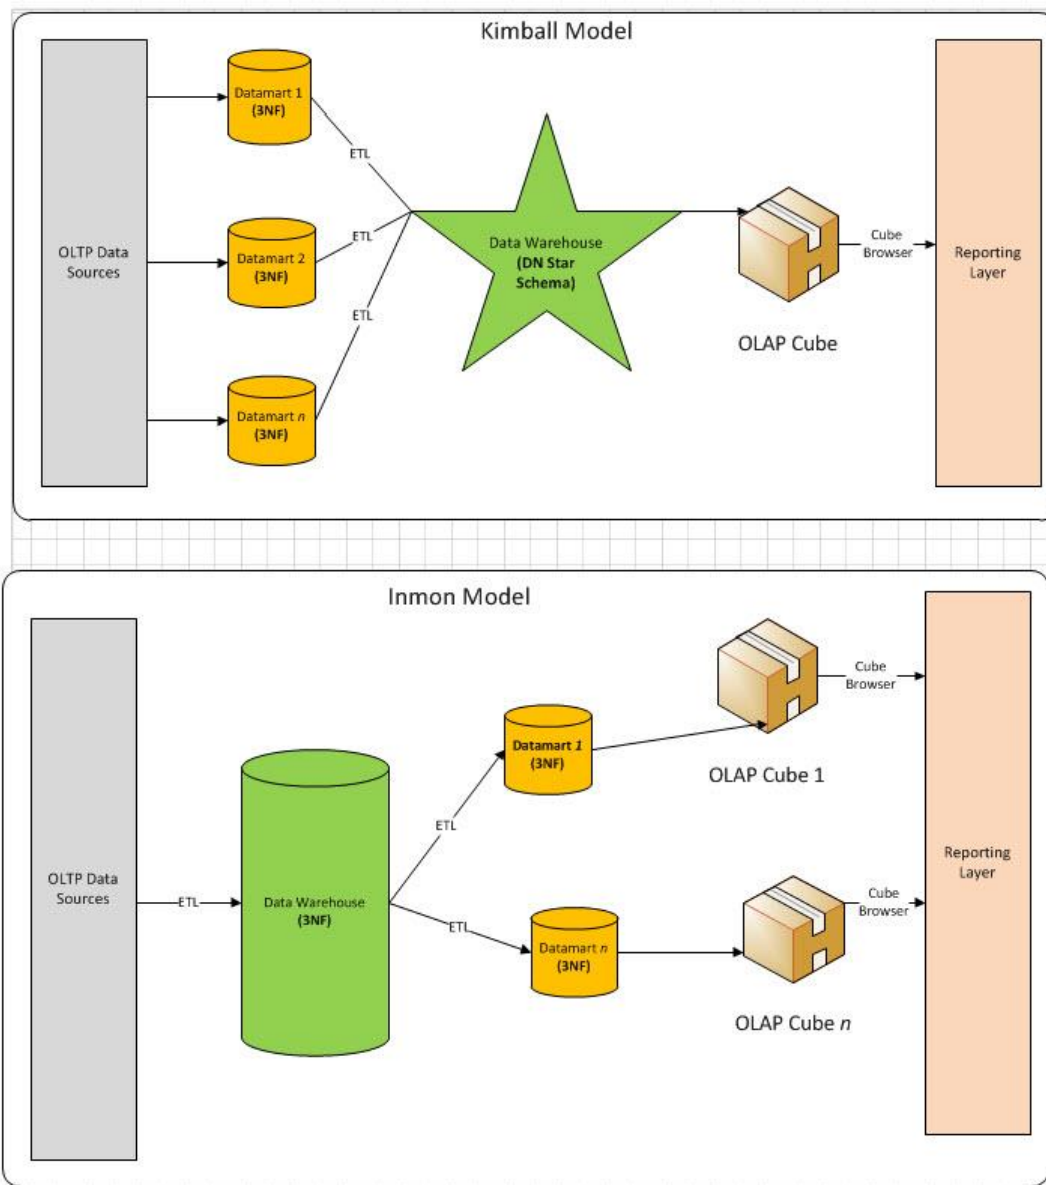
2.3.2 Datový sklad a datové tržiště

Základem BI je datový sklad (DWH). Pro vymezení pojmu DWH použijeme definici Williama Inmona [1]: „*Datový sklad je integrovaný, subjektivě orientovaný, stálý a časově rozlišitelný souhrn dat, uspořádaný pro podporu potřeb managementu.*“ Dle této definice, můžeme říct, že datový sklad obsahuje podstatná data, která jsou rozdělována podle typu, tedy ne podle aplikace, ve které vznikla. Všechna data jsou zde použita pouze jednou a jsou časově rozlišitelná. Datový sklad ale není pouze uložště dat, zahrnuje také nástroje pro extrakci a transformaci dat a nástroje pro reporting, analýzu dat, data mining apod.

Existují dva základní přístupy k budování datového skladu – podle Kimballa nebo podle Inmona. Ty se liší podle vztahu mezi datovým skladem a datovým tržištěm. Datové tržiště je v podstatě omezený datový sklad, určený pro omezený okruh uživatelů (oddělení, pobočka, závod...) nebo orientovaný na konkrétní problematiku [1].

Podle Kimballa je datový sklad sjednocením datových tržišť - sklad se buduje jejich postupným vytvářením a logickým sjednocováním. Tržiště se budují podle aktuálních potřeb společnosti, spolu s ním se určí tzv. sdílené dimenze, které se využijí při tvorbě dalších tržišť. V rámci každého tržiště se většinou samostatně vytvářejí i jednotlivé komponenty BI. Toto řešení je zpočátku levné, rychlé a jednoduché. Problémy nastávají s nárůstem datových tržišť – vznikají duplicitní data, celková integrace BI se stává problematickejší, vytváření jednotného reportu se stává časově i finančně náročné a mohou růst i celkové náklady na provoz. Toto řešení je podle mě vhodné pro menší a střední podniky, které se neplánují v blízké době rozrůstat.

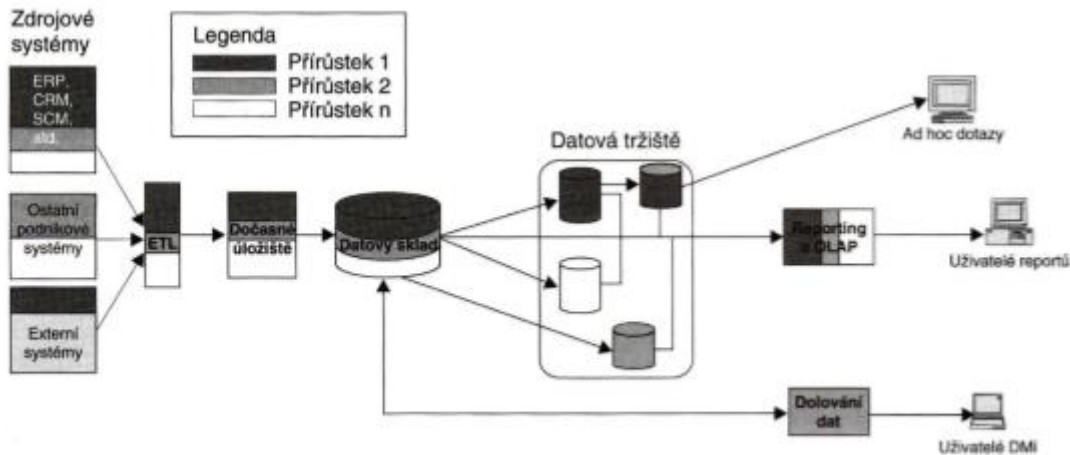
Podle Inmona se nejprve vytvoří celopodnikový DWH a z něj se pak vytváří jednotlivá tržiště podle potřeb uživatelů. Řešení tohoto skladu bývá robustní a dražší na implementaci, navíc se zde hůře sleduje návratnost investic. Výhodou ale je, že v něm můžeme snadno vytvářet další datová tržiště pro potřeby různých uživatelů, eliminují se duplicity a je vhodný pro složitější analytické úlohy [2].



Obr. 3 Porovnání datového skladu v pojetí Kimballa a v pojetí Inmona (zdroj: <http://bennyaustin.wordpress.com>)

Vedle těchto řešení stojí za zmínku ještě tzv. přírůstkové budování skladu. To je odvozeno od řešení podle Inmona. Sklad se buduje postupně podle potřeb zákazníka. Před samotnou implementací se

navrhnu a definují jednotlivé přírůstky a určí se jim priority. Podle priorit se pak přírůstky postupně implementují. Investice do budování skladu se tedy mohou rozložit do většího časového úseku a dá se zde sledovat návratnost investic (na rozdíl od celkového robustního řešení). Při tomto řešení se zde také lépe reaguje na změny, pokud nejsou v právě budované části skladu. Nevýhodou může být častější součinnost s dodavatelem.



Obr. 4 Přírůstkový přístup k datovému skladu [1]

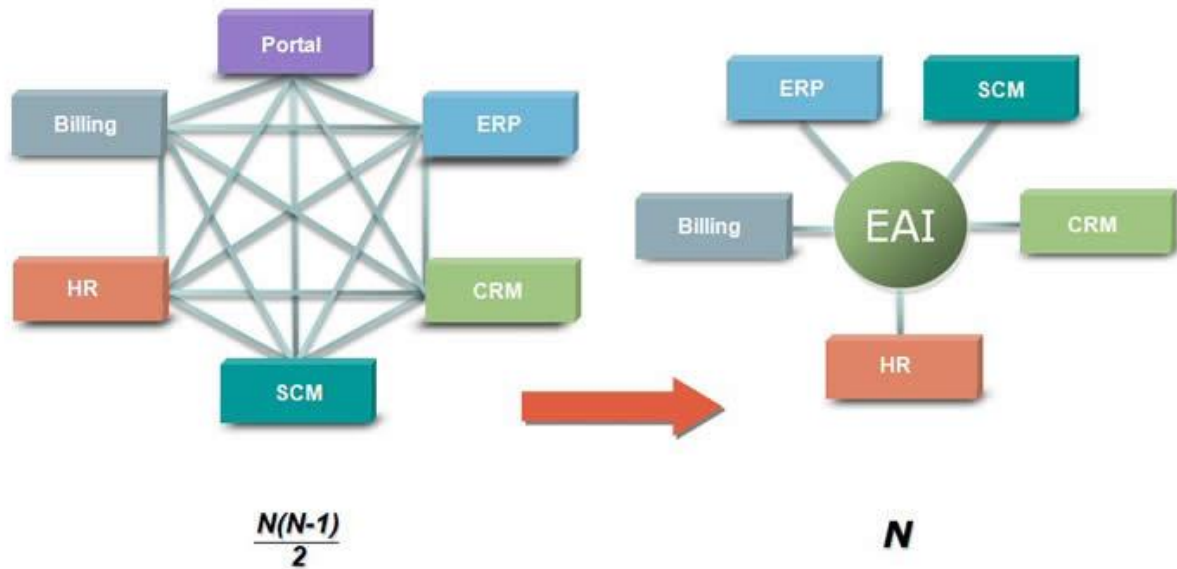
2.3.3 Transformace dat

Jak už bylo řečeno, datový sklad obsahuje dostupná jednoznačná data. Ta jsou seřazena tematicky tak, jak je třeba je analyzovat a ne podle toho, ze kterého zdroje pochází. Data jsou jedinečná a neopakují se, takže i když máme například konkrétního pana Františka Vomáčku ve více různých databázích, v datovém skladu se bude vyskytovat pouze jednou.

Z toho všeho vyplývá, že rozhodně nestačí data pouze zkopírovat a uložit, ale musí si projít určitými procesy. Ty nazýváme ETL, což je zkratka anglického extract (získat), transform (transformovat), load (nahrát). Probíhá to tak, že se nejprve ze zdrojových systémů vyberou data, která jsou vhodná k analýze. Ta se transformují do požadované podoby, což není jednoduchý proces. Pomocí algoritmů a různých procesů se musí eliminovat chyby způsobené jak lidským faktorem, tak jinými okolnostmi, vyloučit duplicity či multiplicity a tak dále. Nakonec se data nahrají do specifických struktur datového skladu tak, aby se na ně dalo nahlížet z více dimenzí. Tyto procesy pracují v dávkovém režimu, což znamená, že se spouští v určitých časových intervalech. ETL je klíčová komponenta BI řešení, proto je tato část nejvíce časově náročná.

Někdy se můžeme také setkat s ELT procesy. Ty fungují obdobně, s tím rozdílem, že nejprve se data nahrají do datového skladu a teprve poté se transformují.

Pro některé typy úloh je nutné, aby byly řešeny v reálném čase (např. v oblasti bankovníctví). ETL je sice schopno se tomu přiblížit, ale zde je spíše namístě použití EAI nástrojů (Enterprise Application Integration). Jejich cílem je integrovat primární podnikové systémy, aby se redukoval počet jejich vzájemných rozhraní. Jak to vypadá, ukazuje následující obrázek (Obr 5.)



Obr. 5 Účel a užití EAI (zdroj: paw-systems.com)

2.3.4 Dočasná a operativní uložení dat

Tyto komponenty zajišťují spolu s ETL řízení kvality dat, nemusí se však vyskytovat ve všech BI řešeních.

Dočasná uložení dat (dále jen DSA – Data Staging Area) podporují rychlý a efektivní výběr dat. Ukládají se zde aktuální data ze zdrojových systémů ve stejné struktuře, jak jsou v nich uložena. Ta se zpracují pomocí ETL a jsou smazána.[1]

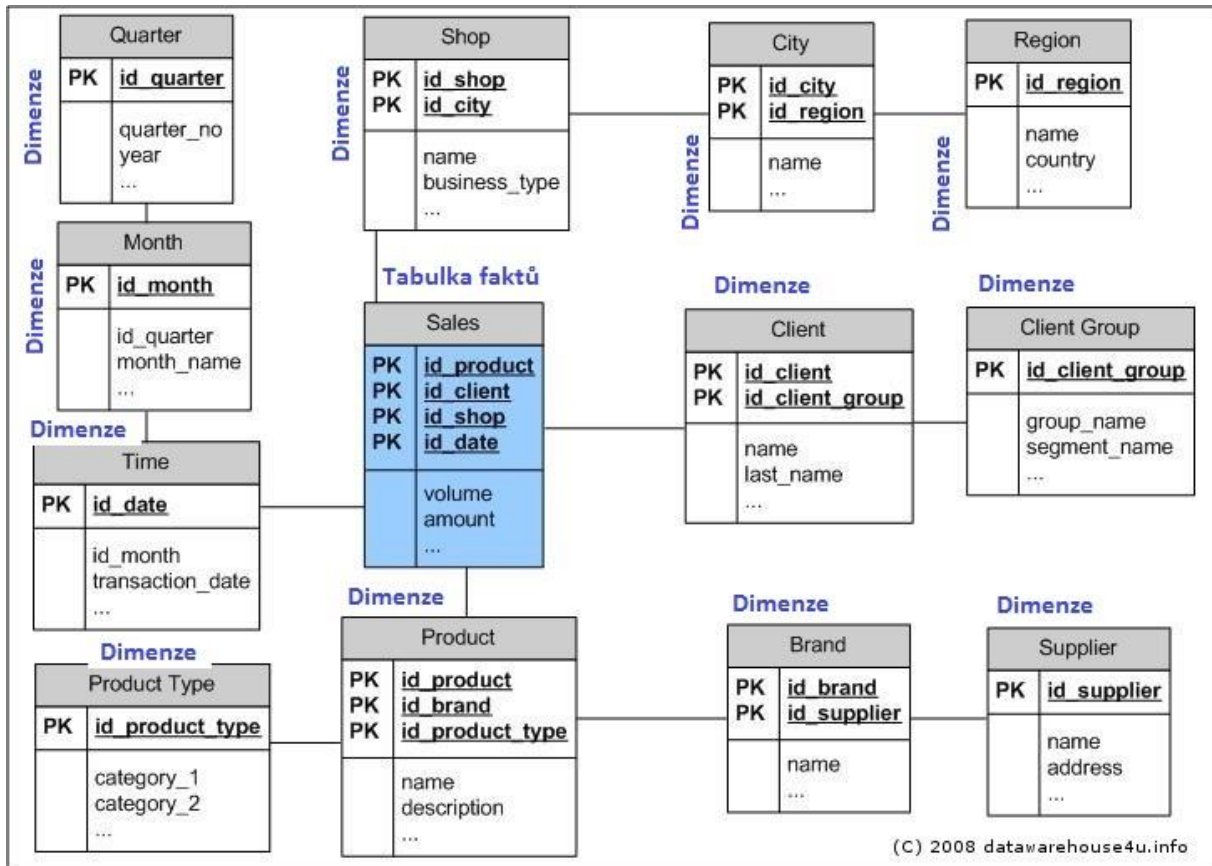
Operativní uložení dat (ODS – Operational Data Store) má obdobnou funkci jako DSA, s tím rozdílem, že obsahuje už konzistentní data, která jsou uložena podle typu a ne podle zdrojových aplikací. Oproti DSA, které slouží opravdu jen jako uložení před zpracováním, je ODS určené pro operativní analýzu a dotazování.[1]

2.3.5 Multidimenzionalita dat

Před tím než přejdu k analýze dat, je třeba zmínit multidimenzionální uložení a práci s daty. Jelikož jsou základem BI. To umožňuje sledovat zvolené ukazatele z více hledisek (dimenzí) a výrazně to usnadní jejich analýzu. Multidimenzionalita se dá realizovat dvěma způsoby – vyjádřením v relačních databázích nebo pomocí OLAP (On-line analytical processing) technologie.

Multidimenzionalita v relačních databázích

Data jsou uložena v tabulkách propojených ve specifických strukturách (relační dimenzionální model), které umožňují snadnější procházení. Tato schémata jsou navržena tak, že v centru se nachází tzv. tabulka faktů, kde jsou uloženy cizí klíče tabulek (tzv. dimenzionálních tabulek) obsahujících ukazatele, které sledujeme. Právě tyto tabulky obsahují prvky jednotlivých dimenzí. Tomuto schématu se říká **hvězdicové schéma**. Spíše častěji se používá tzv. **schéma sněhové vločky** (Obr. 6), zde se tabulky napojené na tabulku faktů rozdělí podle hierarchických úrovní dimenze do více tabulek a to proto, aby se některá data neopakovala.



Obr. 6 Schéma sněhové vločky (zdroj uveden na obrázku)

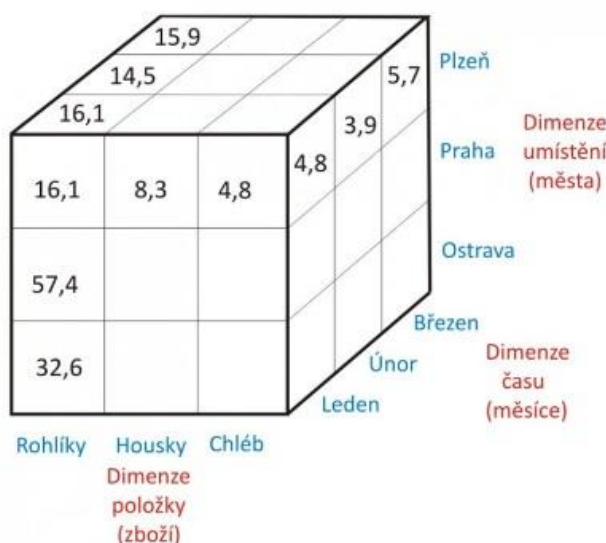
OLAP technologie

OLAP technologie je celkem zásadní nástroj v BI. Tato technologie umožňuje vícedimenzionální uložení velkého objemu dat, což dovoluje jejich rychlou a pružnou analýzu. OLAP se nejčastěji realizuje v těchto variantách [2][26]:

- ROLAP (relační OLAP), který využívá technologii relačních databází. Pro analýzu je ale třeba používat SQL dotazy.
- MOLAP (multidimenzionální OLAP), data zde jsou uložena v multidimenzionální struktuře, ve tvaru vhodném k analytickému zpracování – v binárních OLAP kostkách.
- HOLAP (hybridní OLAP) kombinuje oba předchozí způsoby. Detailní data jsou uložena v relačních databázích, ale agregace jsou uloženy do binárních OLAP kostek.

2.3.6 OLAP databáze

OLAP databáze jsou tvořeny několika OLAP kostkami. Zásadní výhodou OLAP kostek je, že umožňují pružně měnit jednotlivé dimenze - na počet prodaného pečiva se můžeme dívat podle pobočky nebo



podle druhu pečiva. Pro představu jak vypadá taková OLAP kostka slouží Obr. 7. Jednotlivé dílky představují prvky databáze, každá hrana pak určitou dimenzi. Ta reprezentuje kategorii pro analýzu dat (v našem případě to je dimenze času, místa a produktu). Jednotlivé dimenze pak mohou mít určitou hierarchii. Například pro dimenzi času to je: rok -> měsíc -> týden -> den. Průchod těmito hierarchiemi nám umožňují operace **drill-down** a **drill-up**. Drill-down umožňuje průchod od nejvyšší úrovně (prodejnost v roce 2002) po nejnižší (prodejnost 21. března 2002). U drill-up je to naopak (up jako směrem vzhůru).

Obr. 7 OLAP kostka (zdroj: pvasystems.cz)

vyříznout určitou část kostky, abychom se podívali na údaje z určitého pohledu, když chceme třeba vědět, kolik se v březnu prodalo rohlíků nebo kolik rohlíků prodala pobočka v Ostravě. To je podle mě mnohem jednodušší, než vytváření SQL dotazu v databázi, který by musel jít napříč velkým množstvím tabulek atd.

2.3.7 Analýza dat

Dalšími nástroji pro analýzu dat je reporting a dolování dat.

Reporting je činnost spojená s dotazováním (např. pomocí SQL dotazů). Rozlišujeme standartní reporting (předpřipravené dotazy jsou spouštěny v určitých periodách) a ad hoc reporting (dotazy jsou spouštěny jednorázově podle potřeby uživatele) [1].

Dolování dat získáváme strategická data pomocí algoritmu (rozhodovací stromy, časové řady, asociační pravidla atd.). Jedná se o data, která nejsou předem známá a slouží nám k odhalení nových skutečností, která nejsou jednoduše odhalitelná [2].

2.3.8 Prezentace

Získané analýzy se pak prezentují koncovým účastníkům. Výsledek analýzy by měl být schopen odpovědět na otázku: „Co se děje?“. Koncovému uživateli může být prezentován v různých formátech a podobách – od textového dokumentu, přes tabulky po webovou stránku. Každopádně platí, že by výstup měl dávat sjednocený, jasný a stručný pohled na danou situaci. Na to jak zobrazit data se klade čím dál tím větší důraz, tomu se věnuji v kapitole věnované Business Analytics (kapitola 2.5). Nejčastěji bývá výstup prezentován těmito formami:

- **Reporty** dávají rychlý, přehledný pohled na potřebné informace. Většinou obsahuje grafy, tabulky s popisky a vysvětlivkami.
- **Dashboards** se mohou zdát velmi podobné reportům. Často jsou přirovnávány k pilotním kabinám – tzv. „manažerský kokpit“. Jedná se o interaktivní prezentaci, kde se data zobrazují

ve 2D nebo 3D datech, animovaných reportech nebo barevných drillovacích mapách (tedy mapách, kde si můžeme přiblížit určitou oblast).


- **Scorecard** je vizualizace podnikových metrik (blíže si přiblížíme v kapitole 2.4.2). Často bývají ve formě semaforů či jiných ukazatelů (šipky směřující nahoru dolů, „smajlíci“ a podobně). Jasně a zřetelně zobrazují, jak si konkrétní oblast vede (červená – špatně, zelená – dobře) v porovnání s firemní strategií. Právě proto bývá tato forma vhodná právě pro vrcholový management.

2.4 Corporate Performance Management

Corporate Performance Management (dále jen CPM) je považován za následníka BI. Na rozdíl od BI není účelem CPM pouze zjistit, jak je společnost výkonná, ale především výkon řídit za účelem zvýšení. Takže CPM neodpovídá pouze na to PROČ se to děje, ale také řeší CO a JAK udělat do budoucna, aby se situace změnila. A to pomocí modelování, plánování, what-if analýz a podobně. Dá se říct, že CPM je nadstavbou BI. Zatímco BI poskytuje technickou strukturu, CPM ho rozšiřuje nejen o další nástroje a technologie, ale o metodiky, metriky apod. Základní myšlenka se často v zobrazuje ve 4 krocích:

1. Formulace strategie („Kam míříme“)
2. Plánování („Jak se tam dostaneme“)
3. Monitorování („Jak si vedeme oproti plánu a proč“)
4. Korekce („Co s tím budeme dělat“)

Než se ale dostaneme k těmto krokům, přiblížíme si nejprve základní komponenty CPM (Obr. 8). Všechny komponenty se vzájemně ovlivňují, například metriky jsou užity v manažerských metodách (metodikách) a ty jsou pak svázány s určitými procesy. To vše je postaveno na určitých technologiích. Nebudu mluvit o všech komponentách, ale vysvětlím ty nejdůležitější.



Obr. 8 CPM komponenty

2.4.1 Metodiky

V oboru podnikové informatiky pojem metodika znamená souhrn doporučených postupů a praktik jak pracovat. V CPM jsou tu metodiky proto, aby urychlily a zefektivnily analytické procesy. Do těchto metodik patří například:

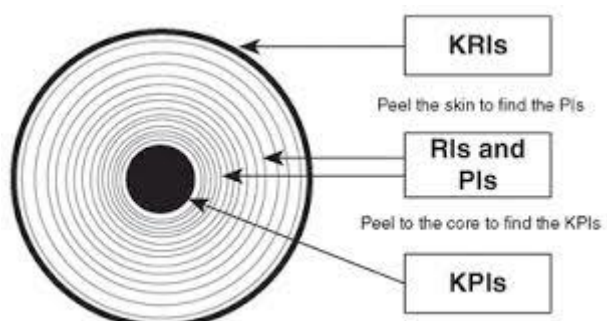
- Activity Based Costing (ABC) je manažerská metoda zabývající se oceňováním procesů a produktů. Objevila se už v 80. letech záhy se ale zjistilo, že finanční analýzy je nutné doplnit o nefinanční ukazatele, což vedlo ke vzniku BSC.
- Balanced scorecard (BSC), jeho cílem je zefektivnit implementaci, monitoring a korekce obchodní strategie. Česky se tato manažerská metoda dá nazvat jako „systém vyvážených ukazatelů výkonnosti podniku“ a to také proto, že je postavena na systému indikátorů, které sledují firmu z 6 hledisek: finance, zaměření na zákazníka, interní podnikové procesy, prostředí/společenství, spokojenost zaměstnanců a učení se a růst. Tyto indikátory nesledují jen minulé události, ale ukazují i aktuální dění, a je možno jimi modelovat budoucí vývoj.
- Economic Value Added (EVA) je účetní metoda, která vyjadřuje přibližný ekonomický zisk.
- Six Sigma (6σ) je sada principů, které byly vyvinuty v 80. letech společností Motorola. Jejich hlavním cílem je zefektivnit firemní procesy, a to omezením jejich nedostatků.
- Value Based Management (VBM) jejím cílem je vytvořit hodnotu podniku. A to právě na základě rozhodování, jelikož špatné rozhodnutí snižuje hodnotu společnosti.
- A mnoho dalších, např. přístupy zdůrazňující důsledné procesní řízení, řízení kvality všemi zaměstnanci, decentralizaci pravomocí apod.

2.4.2 Metriky

Jak název napovídá, metriky slouží k měření výkonnosti podniku. K tomu je využito klíčových ukazatelů:

- KRI (Key Result Indicator) – klíčový ukazatel výsledku
- RI (Result Indicator) – ukazatel výsledku
- PI (Performance Indicator) – ukazatel výkonu
- KPI (Key Performance Indicator) – klíčový ukazatel výkonu

David Parmenter připodobňuje, ve své knize Key Performance Indicators [5], tyto indikátory ke slupkám cibule (Obr. 9). Povrch cibule představuje KRI, už při pohledu na cibuli vidíme, jestli je zdravá, kolik slunce vody a živin přijala a jak se s ní zacházelo. Jak se postupně dostáváme dovnitř slupkami představujícími PI a RI vidíme další souvislosti, až se dostaneme k samému jádru – KPI. V tomto pořadí, jak jsme loupali cibuli, popíšu detailněji jednotlivé ukazatele.



Obr. 9 čtyři typy metrik výkonu (zdroj: [5])

Klíčové ukazatele výsledku

KRI jsou často zaměňovány s KPI, což je velká chyba. Jedná se o úplně něco jiného a je třeba tyto ukazatele odlišit. KRI nám ukazuje pouze výsledky toho, jak si vedeme, a jestli se ubíráme správným

směrem. Nedává nám ale možnost nebo návod jak tyto výsledky změnit. KRI jsou měřeny v delších časových periodách (měsíc, čtvrtletí). Měření zahrnují tyto oblasti: spokojenost zákazníků, čistý zisk před zdaněním, ziskovost zákazníků, spokojenost zaměstnanců a návratnost vloženého kapitálu.

Ukazatele výkonu a výsledku

KRI a KPI jsou doplněny ukazateli výkonu a výsledku. Ty nemají klíčový dopad na fungování firmy, přesto pomáhají dodržení firemní strategie. RI říká, co jsme udělali. Může například ukazovat: kolik prodejů se za určitý den uskutečnilo, kolik postelí v nemocnici se tento týden používalo nebo čistý zisk určité prodejny apod.

Na druhou stranu PI nám radí co dělat. PI je doplňkem KPI. Je to nefinanční ukazatel zaměřen na určitý proces či oddělení. PI může ukazovat: stížnosti klíčových zákazníků, o kolik procent se zvýšily obchody s klíčovými zákazníky nebo kolik návrhů od zaměstnanců se zrealizovalo v minulém měsíci.

Klíčový ukazatel výkonnosti

KPI je hlavní metrikou, která má výrazný dopad na úspěšnost firmy. Přesto s ní mnoho firem stále nedokáže pracovat. KPI nám říká co dělat, abychom výrazně zvýšili výkon firmy. David Parmenter definoval 7 základních charakteristik KPI [5]:

1. jsou nefinanční metriky (nepojí se k nim žádná měna, to by se pak jednalo o KRI)
2. jsou měřeny často (denně, týdně nebo sledovány v reálném čase)
3. jsou určeny pro vrcholové řízení firmy (to se pak obrátí na náležité oddělení)
4. jasně naznačují jaký krok je vyžadován od zaměstnanců
5. jsou metriky, které vážou zodpovědnost níže k nějakému týmu (např. vedení zavolá vedoucímu týmu a ten pak provede nezbytné kroky)
6. mají významný dopad
7. vedou k náležitým krokům.

KPI se prezentuje většinou pomocí scorecard vedení firmy (na rozdíl od PI, které je prezentováno náležitému úseku společnosti). Vedení pak deleguje kroky na určité oddělení. Mezi KRI a KPI je tenká hranice, je však důležité tyto ukazatele odlišovat. KRI nám jen ukazuje co se děje, ale KPI už nám říká jaká opatření přijmout, aby se situace zlepšila.

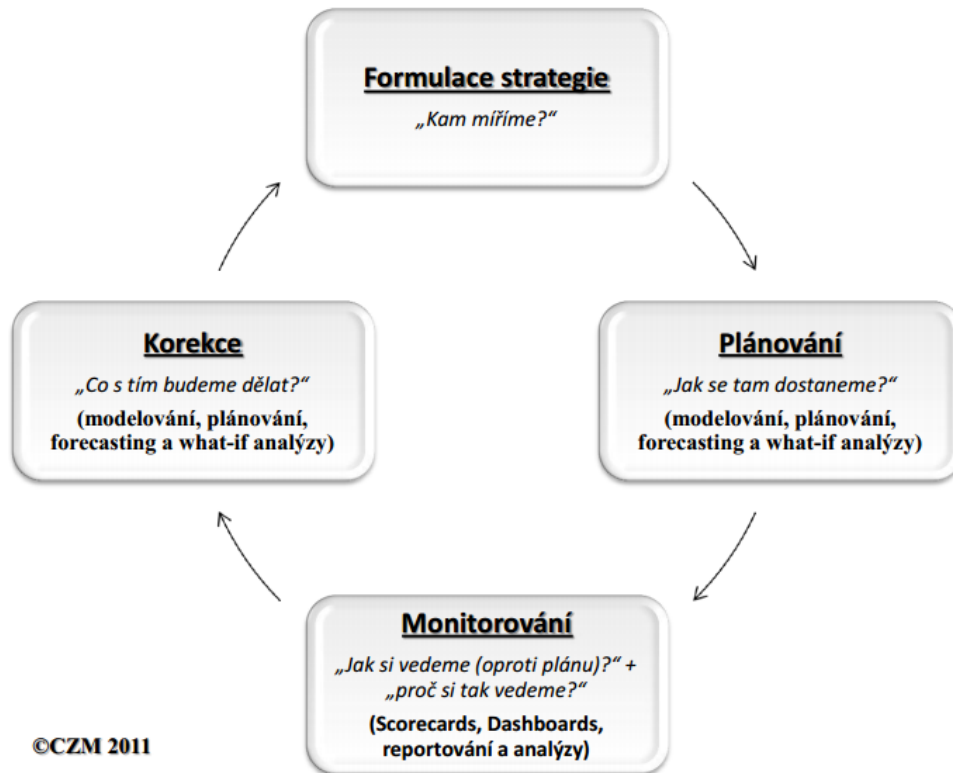
2.4.3 Technologie

Technologická řešení staví na metodikách, metrikách a procesech CPM. Patří sem různé aplikace pro prognózu a plánování nebo aplikace pro vizualizaci výstupů dashboardy a scorecardy. Ty zajišťují provázání KPI na strategické mapy. Pak jsou tu aplikace pro analýzy, modelování a reportingy.

2.4.4 Zavedení CPM

Hlavní komponenty CPM jsme si už popsali, teď si ukážeme, jak to vše probíhá. Průběh si můžeme představit jako uzavřenou smyčku (Obr. 10). Nejprve je třeba **formulovat strategii**. Jakmile tak máme učiněno, stanovíme si cíle pomocí metrik. Ty by měly být takové, aby byly skutečnými generátory. Tím máme odpověď na otázku „kam míříme“. Teď je třeba si zodpovědět to, jak se tam dostaneme. Dostali jsme se tak do fáze **plánování**, v této fázi přichází na řadu modelování, what-if analýzy, plánování a forecasting (předpověď budoucnosti). Je důležité angažovat všechny údaje, elementy, které mohou ovlivnit celkový výsledek společnosti a to především ty, které mají vliv na nefinanční metriky. V rámci této fáze dochází k detailnímu rozpisu strategického plánu. Při fázi **monitorování** kontrolujeme, jak si vedeme. Prostředkem pro to jsou dashboardy a scorecardy, které jsme si zmiňovali už před tím. Je třeba denně monitorovat situaci a včas zachytit odchylky od původního plánu. Strategie by se měla stále rozvíjet a řídit, k tomu slouží **korekce**. Spíše nežli samotná strategie se provádí korektury taktických a operačních plánů. Soustředíme se na to, jak bychom měli dosáhnout co nejmenších

odchylek od původního plánu, a řešíme to opět modelováním, what-if analýzami, forecastingem a plánováním.



Obr. 10 Základní kroky CPM (zdroj: [19])

2.5 Business Analytics

Poslední dobou se namísto BI a CPM setkáváme s výrazem Business Analytics (dále BA). Přestože BA není na trhu žádnou novinkou, začíná se prosazovat až v posledních letech. Jednoznačná odpověď na otázku jaký je vztah mezi BI a BA neexistuje. Někteří považují BA za následníka BI a veškeré nástroje a technologie nazývají souhrnně Business Analytics. Jiní se drží názvu Business Intelligence. Pak je tady druhý tábor, který tyto pojmy striktně odděluje. Já v této práci zůstanu u pojmu Business Intelligence, pod kterým jsou zahrnuty jak technologie a komponenty BI, tak i CPM a BA.

Když jsem hledala rozdíl mezi BI a BA, dostalo se mi následujících odpovědí. Zatímco BI náleží spíše reporting a podobné související činnosti, BA se zabývá analýzou, plánováním forecastingem, vizualizací dat apod. Pod BA spadá vše, co se dá hodnotit a měřit. Jako například prodejnost produktů, spokojenost a reakce zákazníků nebo efektivita podnikových procesů a další. Hlavním cílem BA je právě zlepšení podnikových procesů a výkonu. Jak je vidět BA se moc neliší od CPM. Dle mého názoru je BA rozšířením BI a CPM o nové nástroje a technologie, jehož nutnost přichází s vývojem IT technologií. O těchto nástrojích a technologiích budu psát v kapitolách 2.5.2 až 2.5.4.

2.5.1 Big data

Před tím než budu psát o samotných BA komponentách, je podle mě třeba říci něco o big data. Jelikož právě s příchodem big data přestali běžné softwary, které zachycují a zpracovávají data, stačit. Vznikla potřeba zefektivnit a především zrychlit analýzu dat a to je náležitostí BA.

Big data v překladu znamená „velká data“, nemluvíme však jen o objemu, který dosahuje nejen gigabyty, ale až tera- či dokonce pentabyty. Velikost big dat se týká i různorodostí a rychlostí nárůstu.

Dříve byla analýza dat spíše statickou úlohou – nahrála se do DWH, odkud si je brali analytici pro zpracování a následné reporty. V dnešní době je ale třeba některá data zpracovávat v téměř reálném čase (např. sociální marketing). I to umožňuje BA, se kterým přichází nové typy analýz a metrik.

2.5.2 In-memory Analytics

Jak už bylo řečeno, v dnešní době je potřeba některá data zpracovávat v nejrychlejším možném čase. Toho se dá dosáhnout pomocí nové technologie in-memory. Ta funguje tak, že se data (většinou právě big data) ukládají do paměti, kde se s nimi hned pracuje. Takže se ušetří čas a výkon za diskové operace a analytické procesy se mohou provést až ve zlomku sekund.

2.5.3 Prediktivní analýza

Prediktivní analytika je významný nástroj BA. Předvídá trendy a potřeby zákazníků, změny v nabídce a poptávce, změny na trhu, které mohou ovlivnit chod firmy a mnohé další. Krom toho dokáže vyřešit zdánlivě neřešitelné problémy, protože vidí a předvídá souvislosti tam, kam lidská mysl nedohlédne.

Prediktivní analytika využívá vlastní složité algoritmy a techniky strojového učení, díky kterým sama pochopí veškeré souvislosti a řetězy událostí. Zpracovává a analyzuje velké množství dat ze systémů a infrastruktur. Dále používá algoritmy k předpovídání pravděpodobností různých událostí. Ty vykonávají analýzu z historických dat nebo v reálném čase, takže mohou včas předvídat problémy a pomoci je řešit.

2.5.4 Vizualizace dat

Vizualizace dat, je aktuálně jednou z nejdůležitějších úloh v BA. Heslem vizualizace dat je: „jeden obrázek vydá za milion dat“. Zobrazení dat by mělo být jasné, jednoduché a hlavně přehledné, což není tak snadné, jak se na první pohled zdá. Každý údaj, informaci je vhodné zobrazit jiným způsobem. Pro něco je vhodné graf pro jiné věci tabulka a podobně. Další problematikou je, že vizualizaci dat má na starost IT oddělení. To ale úplně nevidí do problematiky dané věci a neví, na které části a údaje je třeba se soustředit. Výstupy jsou pak určeny hlavně pro management a vedení, kde lidé nebývají tak technicky zdatní. Proto se ve firmách vytvářejí nové pozice pro „vizualizéry“ dat nebo se pro zaměstnance poskytují různá školení zaměřená na vizualizaci.

Shrňme si, jak by měla vypadat vizualizace dat. Především je třeba vědět, pro koho jsou výstupy určené a podle toho vybrat, co chceme předat. Měli bychom se omezit opravdu jen na údaje, které je třeba sdělit. Proto je třeba vynechat vše co je mimo tyto údaje, avšak je třeba mít na paměti, že bez kontextu čísla neznamenaají téměř nic. Potřebné a nejdůležitější informace by měly být nejvíce viditelné. A nakonec, je vhodné se vyvarovat zbytečných barevných variací.

2.5.5 Zavedení BA

Nakonec si řekneme, jak by se při analýze mělo postupovat. Nejprve je třeba zvolit vhodnou otázku. Ta by měla být taková, že odpověď na ni pro nás má nějaký význam. Můžeme ji využít a dá se zodpovědět bez výrazných překážek. Nejlepší je začít u firemních KPI. Dalším krokem by měla být realizace a řízení dat. Pro to by měla mít firma stanovený jasný model, kdy se shromáždí vhodná kvalitní data, zpracují a včas dodají vedení. Je vhodné sbírat data i mimo tradiční podnikové zdroje, například sledovat reakce zákazníků pomocí webové analytiky.

Dále by se měla data vyhodnotit, otestovat své postřehy a vyladit úlohy. Když už máme fungující řešení, můžeme ho aplikovat a rozšířit na další oblasti. Fungující BA může firmu posunout a vytvořit velký náskok před konkurenty.

2.6 Shrnutí

V této kapitole byly definovány pojmy manažerský informační systém a systém pro podporu rozhodování. Více vžitý je ale spíše název Business Intelligence. BI zahrnuje nástroje a technologie pro sběr, analýzu a prezentaci dat. Základní komponentou BI je především datový sklad, kam se ukládají zpracovaná a vyčištěná data. Z datového skladu se pak data berou k analýze například pomocí OLAP technologie, reportů nebo dolování dat. Výstupem analýz je odpověď na to co se děje. Dneska se už nevymezujeme pouze na analýzu dat minulých a současného stavu, ale pomocí BI nástrojů můžeme i předpovědět kam vývoj firmy směřuje a ovlivnit ho. To už je náležitostí dalších řešení, která jsou brána jako rozšíření BI. Těmi jsou Corporate Performance Management a Business Analytics.

3 Analýza existujících řešení

Tato kapitola je věnována především rozboru poskytovatelů manažerských informačních systémů, respektive BI. Nejprve si řekneme něco o vývoji a historii manažerských systémů. Poté si rozdělíme řešení systémů z různých hledisek a na některé možnosti se podíváme blíže. Dále si vyjmenujeme konkrétní poskytovatele a jejich produkty a nakonec analyzujeme aktuální situaci na trhu s BI.

3.1 Historie a vývoj MIS

První zmínka o BI se objevila již v roce 1958 v článku „A Business Intelligence System“, který vyšel v IBM Journal [32]. Samotná řešení se objevují na konci 70. let, ty jsou spjata především s firmou Lockheed, která přišla s aplikací MIDS (Management Information and Decision Support) určenou pro manažery. V 80. letech se na trhu USA objevují první komerční systémy založené na multidimenzionálním uložení a zpracování dat, označovány jako EIS (Executive Information System), volně přeloženo jako informační systém pro vrcholové řízení. Přelom 80. a 90. let je spjat s čím dál větším prosazováním datových skladů. Jak už bylo řečeno v kapitole 2.3.2, za jejich rozvojem stojí především pánové R. Kimball a W. Inmon. S rostoucím objemem dat v datových skladech a datových tržištích se začaly vyvíjet různé technologie a nástroje pro analýzu dat například tzv. dolování dat, které bylo zmíněné v kapitole 2.3.7.

S tím, jak se vyvíjejí počítačové technologie, vyvíjí se i nástroje MIS. K datům může najednou přistupovat i několik tisícovek uživatelů najednou. Zrychluje se nejen připojení k systému, ale i jednotlivé procesy. S nástupem éry cloud computingu přicházejí nové možnosti například nabídka MIS jako služba (SaaS – Software as a Service).

Nakonec se podívejme na vývoj v České republice. První komerční řešení MIS se k nám dostávají až po revoluci a celkový vývoj je zde pomalejší. Datové sklady se začínají prosazovat spíše v polovině 90. let a další různá komerční a nekomerční řešení sem přicházejí až na konci dekády. Momentálně můžeme říct, že srovnáváme krok se světovým děním, což je samozřejmě způsobeno přítomností velkých mezinárodních firem. Co se týče českých společností, ne všechny jsou otevřené nasazení MIS, to ale na druhou stranu otvírá trh jak zahraničním, tak domácím poskytovatelům.

V dnešní době se na trhu objevuje mnoho různých řešení a poskytovatelů řešení, o těch se dozvíme v dalších podkapitolách.

3.2 Aktuální situace na trhu

Spíše než o MIS a DSS budeme mluvit opět o BI, jelikož s tímto pojmem se setkáváme častěji, když mluvíme o technickém řešení. Tím je myšleno nejen samotné BI, ale i CPM a Business Analytics. BI řešení není jen náležitostí velkých firem. Již delší dobu je tu určitý trend, kdy se poskytovatelé zaměřují na malé a střední podniky (SME). Nejen proto, že se tím poskytovatelům otevírají nové možnosti, ale samotné podniky si uvědomují výhody, které investice do BI přinesou. To mluvíme ale spíše o situaci na světovém trhu. V roce 2013 byl společností Oxford Economics proveden průzkum, který mimo jiné zkoumá postoj SME k investování do IT technologií (zdroj: „Jak malé a střední firmy

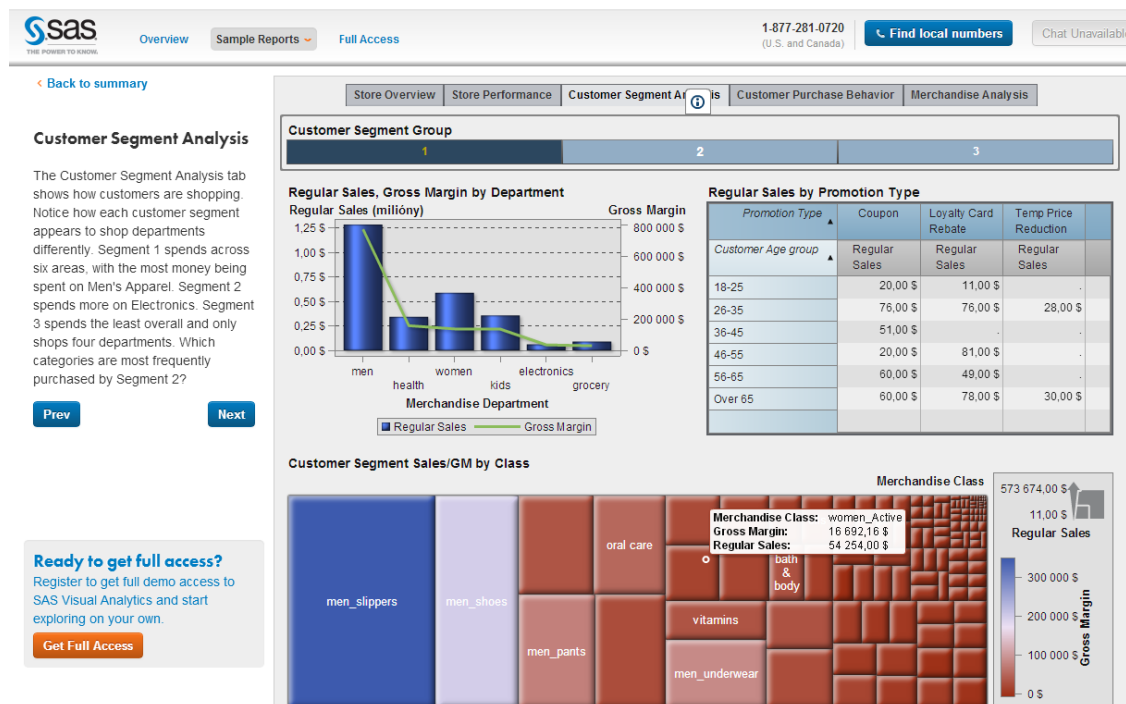
vidí samy sebe“ [6]. Dle průzkumu si české SME uvědomují důležitost investování do technologií, jak už kvůli tlaku konkurence (která zahrnuje právě mezinárodní firmy), tak i kvůli zefektivnění činnosti. Jenže přesto, že jsou české SME otevřené novým technologiím, především co se týče BI a BA, a uvědomují si jejich potřebu, realita je jiná – pouhý zlomek z nich plánuje v blízké budoucnosti tyto nástroje nasadit.

Právě díky rozšíření trhu o SME, se mění i požadavky na BI. Už proto, že robustní řešení poskytovaná velkými společnostmi nejsou pro SME nejvhodnější. Tak se začaly objevovat i odlehčenější verze s omezenými funkcionalitami zaměřené na určitý útvar společnosti. Dále jsou čím dál oblíbenější i open source řešení, kde nejen odpadají náklady na licence, ale zákazník použije jen ty funkcionality, které potřebuje. V dnešní době se také prosazuje Business Intelligence v cloudu. Všem těmto oblastem se budeme věnovat v následujících kapitolách.

3.3 Proprietární řešení

Proprietární řešení znamená řešení s uzavřeným kódem. Tato oblast trhu zahrnuje velkou škálu poskytovatelů. My se blíže budeme věnovat hlavně těm největším dodavatelům (tzv. *megvendors*), kam patří známé společnosti jako Microsoft, IBM, Oracle a SAP [2]. Není žádné překvapení, že na trhu dominují právě tyto firmy, jenž vládnu trhu IT technologií. Mimo jiné se zabývají vývojem databázových systémů, což je důležité, jelikož základem BI je datový sklad.

Bohužel nemůžeme mluvit o všech poskytovatelích, které stojí za zmínku, jelikož jich je nepřehledné množství. Namátkou můžu zmínit například společnost **SAS Institute**, která se zaměřuje spíše na BA. Kromě *SAS Visual Analytics*, které umožňují vizuální analýzu dat, poskytuje nástroje pro data mining a pokročilou analytiku jako text mining (dolování textu). Mimo jiné samozřejmě nabízí vybudování a správu datového skladu. Na webových stránkách společnosti je možné nalézt detailní popis produktů a mimo jiné je tu možnost vyzkoušet si vizualizaci dat právě pomocí nástroje *Visual Analytics*. V rámci této práce jsem si vyzkoušela několik ukázek, na Obr. 11 je screenshot analýzy nákupního chování zákazníků.



Obr. 11 Ukázka nástroje SAS Visual Analytics [16]

Za český a slovenský trh bychom mohli dále zmínit produkty Helios, společnosti Asseco Solutions. Ty nabízejí specializovaná řešení pro velké, střední i malé podniky. Tato společnost typicky nabízí ERP systémy. Hlavním důvodem, proč o tomto produktu mluvím, je to, že nabízí nástroje BI integrované právě v ERP, což je další způsob nasazení BI.

3.3.1 Microsoft

Stále nejvyužívanějším nástrojem bývá BI v Excelu, aktuálně Excel 2013. Většina těchto funkcí je podporována ve službách Excel Services, které umožňují nahrávání, zpracování a zobrazování sešitů v rámci SharePoint Server 2013. To tedy mluvíme o místním uložení dat. BI v cloudu je podporováno v SharePoint Online Enterprise, které umožňuje práci se sešity (do určité velikosti) v okně prohlížeče.

Jaké tedy BI funkce jsou podporovány v nástroji Excel:

- Power Query (dříve známý jako „Data Explorer“) – umožňuje snadné vyhledávání a přístup k veřejným a firemním datům.
- Power Pivot se používá k vytváření a úpravě flexibilních datových modelů v rámci Excel.
- Power View slouží k vizualizaci dat, kdy vytváří interaktivní tabulky, grafy, reporty, dashboardy a scorecardy.
- Power Map je nástroj pro vizualizaci 3D dat. Umožňuje například sledovat aktuální vývoj trendů.
- Power BI Sites slouží například ke sdílení dat, reportů v rámci firmy/oddělení. Dále udržuje data o zákaznících stále aktuální.
- A další.

Dalšími BI nástroji jsou například SQL Server Reporting Services, SQL Server Analysis Services nebo ProClarity – nástroj pro analýzu dat společnosti ProClarity Corporation, která byla Microsoftem zakoupena v roce 2006.

3.3.2 IBM

Asi nejznámějším softwarem společnosti IBM v oblasti BI je IBM Cognos. Společnost Cognos byla největším poskytovatelem řešení BI a Performance Management. V roce 2008 byla tato firma zakoupena společností IBM a tím si IBM posílila svou pozici mezi nejsilnějšími v oboru podnikové informatiky.

- Cognos Business Intelligence poskytuje komplexní řešení BI. Nabízí nástroje pro analýzu a reporting dat a následnou vizualizaci (reporting, analysis, dashboard, scordarding...).
- Cognos Insight je osobní analytické řešení. Umožňují během chvíle vytvářet vlastní analýzy a vizualizace bez účasti podnikového IT.
- Cognos Office umožňuje manipulaci s obsahem vytvořeným v Cognos BI v aplikacích Microsoft Office
- Cognos TM1 je softwarová platforma pro plánování podniku. Může být implementován v cloudu. Umožňuje reporting analýzy a prognózy.
- Cognos Express nabízí nástroje pro středně velké firmy, slouží k analýzám (Cognos Express Advisor), reportingu (Cognos Express Reporter) a plánování v reálném čase (Cognos Express Xcelator)
- A mnoho dalších jako produkty pro zobrazování dashboardů mobilní zařízení a různé analytické nástroje.

Mimo nástroje Cognos nabízí IBM software SPSS pro prediktivní analýzu. Ten je v podstatě konkurencí SAP Predictive Analytics, které zmíním v kapitole 3.3.4. IBM SPSS pomáhá při rozhodování, řešení problémů a zlepšování hospodářských výsledků. Mezi IBM SPSS patří software pro sběr dat (IBM SPSS Data Collection), pro pokročilé analýzy a statistiky (IBM SPSS Statistics), pro vizualizaci (IBM SPSS Modeler) nebo pro podporu rozhodování (IBM SPSS Analytical Decision Management). V rámci těchto software se nabízí řešení např. pro analýzu zákazníků, provozní analýzy nebo analýzu hrozeb a podvodů.

Dalším produktem, který je vhodný zmínit je Business Intelligence Pattern, který je řešen na soukromém cloudu a urychluje tak implementaci IBM Cognos BI.

3.3.3. Oracle

Společnost Oracle nabízí jak BI nástroje, tak převážně nástroje pro analýzu dat. V rámci produktu BI Foundation Suite, který nabízí velkým podnikům i SME, poskytuje nástroje pro reporting, ad-hoc dotazování, OLAP analýzy, dashboardy a scorecardy. Mimo to také řešení pro přenosná zařízení – Mobile BI.

Dále poskytuje analytické nástroje jako například Exalytics, které umožňují in-memory analýzu, Oracle Advanced Analytics, umožňující prediktivní analýzu a samozřejmě řešení v cloudu.

3.3.4 SAP

Jako BI řešení poskytuje společnost SAP produkt BusinessObject. V rámci něj nabízí edici pro Microsoft Office, edici pro OLAP, dashboardy, řešení pro mobilní zařízení a tak dále. Dalšími produkty jsou SAP Lumira – nástroj pro vizualizaci, SAP Crystal Reports nebo řešení pro malé a střední podniky. Co je dále třeba zmínit je produkt SAP Predictive Analytics, který je nejlepší na trhu v oblasti prediktivní analytiky (dle [21]). A to díky nasazení in-memory technologie (SAP HANA).

3.4 Open source řešení

Open source řešení pro BI přišla na svět díky komunitě developerů vyvíjejících databázové systémy. Ačkoliv dříve panovaly z této možnosti obavy, poslední dobou se toto řešení začíná čím dál více prosazovat. O tom se přesvědčíme v kapitole 3.6 věnované průzkumu trhu, kde se podíváme na analýzy společnosti Gartner, ze kterých mimo jiné plyne, že postavení poskytovatelů open source na trhu sílí.

Open source software je software s otevřeným zdrojovým kódem, takže ho mohou uživatelé legálně použít a pozměnit aniž by museli vydávat finance za licence. To však neznamená, že toto řešení je úplně zdarma, poskytovatelé si často účtují za konzultace a technickou podporu nebo také dodatečně přidané funkcionality. Proto je třeba si pořádně rozvrhnout a rozmyslet, zda se toto řešení opravdu vyplatí a nakonec se neprodrazí. Další výhodou svobodných licencí je to, že software může používat neomezený počet uživatelů a může běžet na neomezeném počtu procesorů. Navíc si uživatel může stáhnout jen ty funkcionality, které potřebuje, což opět hraje ve prospěch open source. Přesto v některých firmách stále panuje velká nedůvěra vůči tomuto řešení. Jako důvody se často uvádí: nízká kvalita oproti proprietárním softwarům, nedostatečné zabezpečení a absence dokumentace a technické podpory. Tyto obavy jsou mylné, ačkoliv jisté úskalí tu je a to již zmíněné případné náklady za školení, technickou podporu a dodatečné funkcionality, které mohou řešení výrazně prodrazit.

Poskytovatelů open source řešení není málo, můžeme jmenovat například Pentaho, Jaspersoft či Talend a další. V této kapitole budeme věnovat více prostoru právě společnosti Pentaho.

3.4.1 Pentaho

Pentaho poskytuje samostatné nástroje, které řeší určitou funkcionalitu BI, těmi například jsou:

- **Data Integration (Kettle)**, který zajišťuje integraci dat a stará se o ETL procesy.

- **Mondrian**, který je nabízen jako OLAP server. Ten umožňuje analýzu dat v reálném čase, pomocí prohlížeče JPivot.
- **Reporting** umožňuje vytvářet reporty v PDF, Excelu, HTML, XML apod.
- Nástroj **Weka** pro data mining.

To byl jen výčet základních funkcí, všechny jsou psány v jazyce Java a volně dostupné ke stažení. Mimo jiné datový sklad je řešen relační databází a lze použít jakoukoliv databázi komunikující přes JDBC (Java Database Connectivity).

Stejně jako ostatní poskytovatelé, tak i Pentaho, jde s dobou a poskytuje moderní technologie a nástroje, například pro Business Analytics, analýzu big data a BI pro mobilní přístroje.

3.5 Cloudové řešení

Před samotným představením cloudových řešení je třeba říci něco o cloudu. Cloud v překladu znamená mrak, což nám sice moc nepřiblíží, o co se jedná, ale můžeme si představit, že veškerá technologie a infrastruktura leží v pomyslném mraku. Jde o to, že veškeré služby, platformy, datová centra, aplikace nemají uložení u uživatele, ale někde jinde (u poskytovatele) a jsou uživateli dodávány přes internet. Navíc podle NIST (Národní institut standardů a technologie USA) má následující vlastnosti [24]:

- Samoobslužný systém (On-demand self-service) - uživatel si sám volí velikost uložení, výkonost serveru apod. pomocí ovládacího panelu, aniž by musel nějak komunikovat s poskytovatelem služby.
- Všeobecný síťový přístup (Broad Network access) – vše je dostupné přes síťové připojení.
- Sdílení zdrojů (Resource pooling) – výpočetní zdroje jsou sdíleny, aby obsloužily více uživatelů najednou a to i na různorodých zařízeních.
- Rychlá flexibilita (Rapid elasticity) – odběr služeb je uživateli poskytován rychle a pružně a uživatel si sám mění službu, podle potřeby.
- Měřitelné služby (Measured Service) – využití služeb je měřeno, kontrolováno a reportováno jak uživateli, tak poskytovateli.

Jak je vidět, nehraje tu roli jen to, že software a infrastruktura jsou uloženy někde jinde, což může být vhodné pro společnosti, které nemají prostor ani prostředky, aby je měli u sebe. Ale užití cloudu má i jiné výhody (viz výše). Samozřejmě to sebou nese i možné nevýhody, jako například právě to, že je uživatel závislý na připojení k internetu, ale i na samotném poskytovateli anebo také to, že uživatel vlastně neví, kde jeho data ve skutečnosti leží, a jak jsou zabezpečeny.

Cloudové řešení dnes nabízí většina velkých poskytovatelů, ale jsou společnosti, které se na cloudové řešení přímo specializují. Konkrétně Birst a GoodData, kteří aktuálně patří k nejvýznamnějším poskytovatelům.

Pro nás je zajímavá společnost GoodData už proto, že za jejím zrodem stojí úspěšný český podnikatel Roman Staněk. Cloudová platforma GoodData poskytuje všechny podstatné nástroje BI: ETL nástroje, datový sklad, multidimenzionální uložení dat (ROLAP) a nástroje pro analýzu (ad hoc reporty) a vizualizaci dat (interaktivní dashboardy). Mimo jiné pak nabízí následné služby jako podpora, školení, konzultace, nahrávání dat a monitoring.

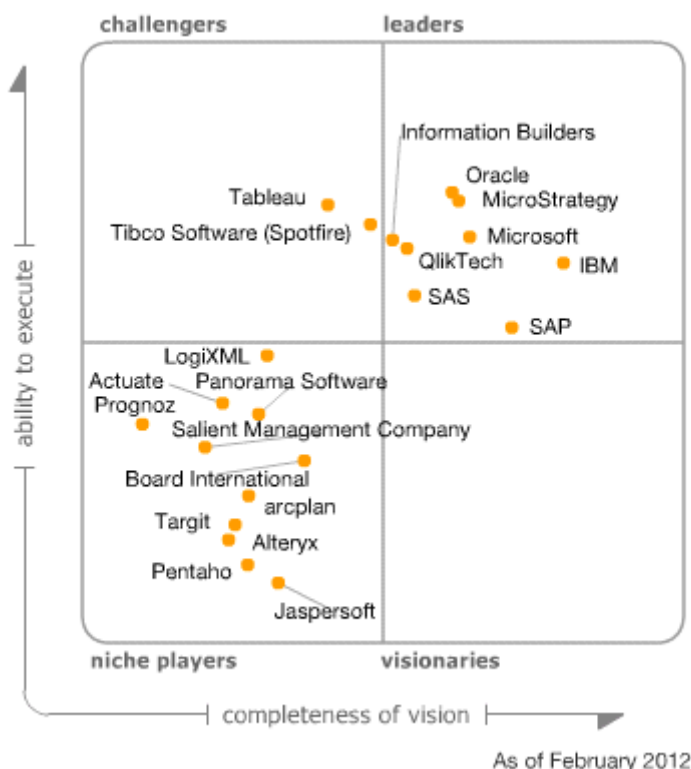
3.6 Průzkum trhu

V této části se podíváme na to, jak si určité společnosti vedou na světovém trhu, a jak se jejich pozice vyvíjí v posledních třech letech. Průzkumem trhu na poli informačních technologií se zabývá například společnost Gartner. Analýzy a statistiky této společnosti jsou sice placené, ale dají se sehnat i z jiných zdrojů, já použila grafy ze stránek společnosti Tableau Software [33].

Společnost Gartner vyvinula metodu tzv. magických kvadrantů. Ta hodnotí poskytovatele ze dvou hledisek – úplnost vize (vodorovná osa), stoupající zleva doprava a schopnost realizace (svislá osa), jejíž hodnota stoupá směrem nahoru. Tento graf je rozdělen právě do čtyř kvadrantů [22]:

- **Leaders** (lídři), sem patří samozřejmě „ti nejlepší“. Nabízejí nejnávštěvnější služby a přitom si drží takovou vizi, která jim umožňuje stabilní postavení na trhu. Zaměřují se na aktuálně nabízené produkty, ale zároveň investují do budoucího vývoje.
- **Challengers** (vyzyvatelé) disponují dostatečnými prostředky, ale může jim chybět dostatečná vize a neodhadnou včas, kam směřuje trh, čímž mohou ztratit svou dobrou pozici. Naopak rozšířením své vize se mohou dostat na pozici lídrů.
- **Niche Players** (specializovaní hráči) jsou společnosti, které si sice vedou dobře, ale jsou omezeni zaměřením na jeden segment trhu nebo geografickou oblast. Pozice v tomto kvadrantu je celkem nestálá a je na samotné firmě, jestli dále poroste anebo naopak neudrží krok s požadavky trhu a další rok se v magickém kvadrantu neobjeví.
- **Visionaries** (vizionáři), ti mají stejný pohled na budoucí vývoj trhu jako Gartner, bohužel však často nemají prostředky na vyplnění své vize. Mají novátorské myšlenky, avšak přijít s něčím novým může být velké riziko. Na druhou stranu, podstoupení tohoto rizika může vynést velké přínosy, to už je ale spíše náležitostí marketingové strategie firmy.

Pozice společností v těchto kvadrantech se celkem rychle obměňují. Jen vydání nové verze SW může výrazně zamíchat pořadím. Abychom měli větší přehled, podívejme se na poslední 3 roky vývoje Business Intelligence.

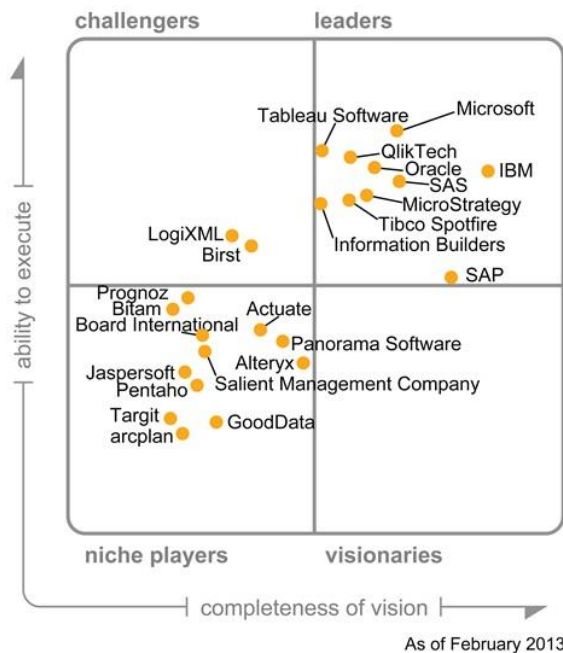


Obr. 12 Magický kvadrant 2/2012 [33]

Na Obr. 12 je vidět stav trhu k únoru 2012. Není překvapením, že právě v pravém horním rohu se nachází již zmiňovaní velikáni Oracle, Microsoft, IBM a SAP. Velmi dobrou pozici si drží také SAS

Institute. Naopak podle předpokladu, poskytovatelé specializovaných řešení a OpenSource produktů najdeme v levém spodním kvadrantu.

Figure 1. Magic Quadrant for Business Intelligence and Analytics Platforms



Source: Gartner (February 2013)

Obr. 13 Magický kvadrant 2013 [33]

Stav na grafu z roku 2013 (Obr. 13) můžeme srovnat s předchozím rokem. Jak je vidět, mezi lídry se toho moc nezměnilo, kromě toho, že se do tohoto kvadrantu dostaly společnosti Tableau Software a Tibco Spotfire. Co je pro nás více zajímavé, že na grafu figuruje česká společnost GoodData. Další zajímavostí je poměrně velký vzestup poskytovatelů open source, hlavně co se týče společnosti Jaspersoft, na druhou stranu, vize této firmy spíše pokulhává.

Na následující stránce vidíme výstupy z února letošního roku, a dá se říci, že vývoj je čím dál tím zajímavější. Můžeme sledovat celkem výrazný pokles všech velikanů a to především v kompletnosti vize. Naopak významný postup je vidět u poskytovatelů cloudových řešení Birst a GoodData, dalo by se předpokládat, že je to právě díky perspektivní technologii cloudů, ale spíše opak je pravdou. Podle webového portálu Solution Review [34] průzkumy ukazují, že pouze 33% dotázaných by mělo zájem nasadit BI řešení v cloudu.

Co se týče open-source řešení, nastal zde obrovský postup, a to jak ve schopnost realizace, tak i v úplnosti vize. Především Pentaho se významně přiblížilo kvadrantu leaderů.

Figure 1. Magic Quadrant for Business Intelligence and Analytics Platforms



Obr. 14 Magický kvadrant 2/2014 [33]

4 Možné způsoby využití systému

Tato kapitola je spíše úvahou nad tím, kdy má nasazení MIS a DSS smysl. Jejím cílem je ukázat jak by mohlo vypadat řešení pro malé společnosti. Jako příklad jsem uvedla tři fiktivní malé společnosti. Přestože se jedná o tři různé oblasti, chci ukázat, že u všech bude postup řešení podobný.

Aby nasazení MIS mělo smysl, je třeba mít dostatečné množství dat, nevyplatí se zavádět systém v případě, kdy data hned analyzujeme pomocí jednoduchých výpočtů. Dále je systém určen k dlouhodobému využívání a ne jen k jednorázové úloze. Důležitá je také úvaha po kolika letech fungování firmy má smysl systém zavádět. Chceme-li analyzovat a předvídat i budoucí vývoj, musíme mít k dispozici i historická data. Je jasné, že při zahájení provozu společnosti bude její vývoj jiný než při delším fungování. Začínající společnost, teprve bojuje o své místo na trhu a získává nové zákazníky. Zavedená společnost už bude mít stabilnější data, ze kterých se dá předvídat další vývoj. Dobu fungování firmy, po které je vhodné nasadit MIS, bych zvolila, alespoň tři roky.

Pro následující společnosti nehledám jedno obecné řešení, ale řešení šitá na míru. Přesto u každého řešení, probíhá obdobný postup - společnost má data, která neumí efektivně využít. Naším cílem je z těchto dat vytěžit maximum, aby co nejefektivněji pomohly při řízení firmy. Nejprve je třeba specifikovat, jaká data máme k dispozici a odkud pocházejí. Poté určíme jednotlivé metriky, které chceme sledovat, definujeme užívané metodiky a zároveň s tím zahrnuté procesy. Poté můžeme určit, na jakých technologiích řešení postavíme (viz Obr. 8 v kapitole 2.4).

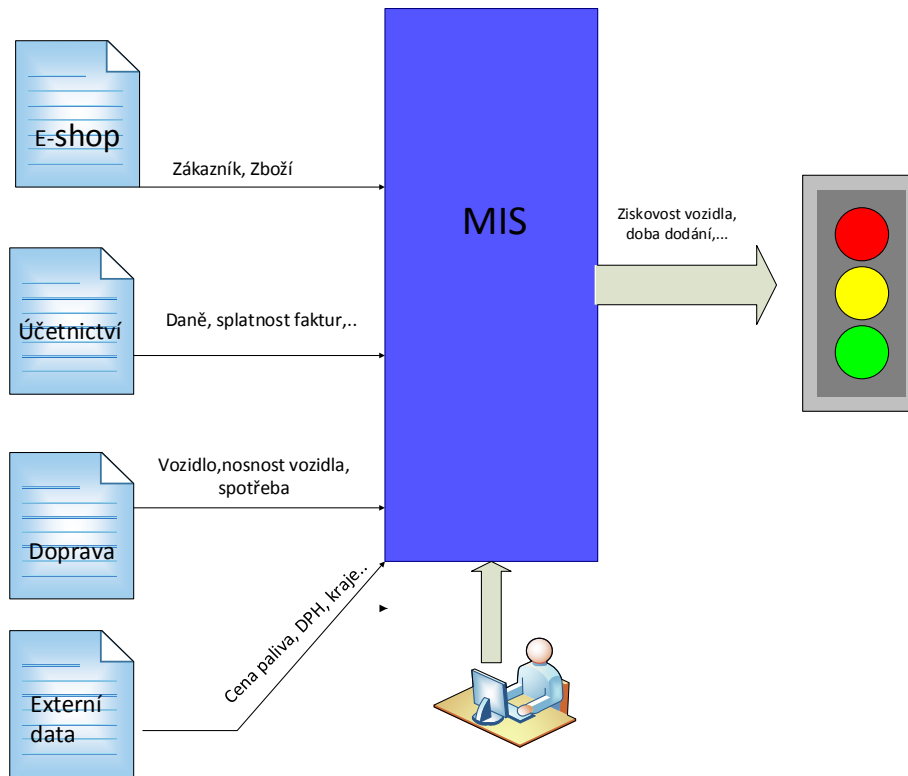
4.1 Příklad: Doprava

Společnost funguje už 4 roky, a zabývá se prodejem náhradních dílů do aut a motocyklů. Ty si zákazník může vyzvednout na pobočce v Olomouci, jinak ale firma rozváží své produkty převážně po moravských krajích. Nedávno rozšířila své působení do Čech, kde plánuje zřídit mezisklad. V budoucnu se také chce rozšiřovat dále, třeba na Slovensko. Aktuálně ale společnost řeší problém s dopravou. Někdy auta jezdí téměř prázdná, čímž dochází ke ztrátám, jindy jsou všechna auta tak vytížená, že musí některé dovážky posílat přes cizího dopravce. Proto společnost uvažuje o zakoupení nových vozidel, ale je otázkou, zda se to vyplatí.

Společnost má k dispozici data o objednávkách a zákaznících z e-shopu, informace o vozidlech - jestli je vozidlo v pořádku, kolik za den najelo kilometrů nebo kolik spotřebovalo paliva. Dále má informace o zákaznících, zaměstnancích, dodavatelích a účetnictví, přesto tyto data nedokáže efektivně využít.

Víme tedy, jaká data máme. Nyní je třeba si ujasnit, jaké zdroje k našemu účelu potřebujeme a zauvažovat, co vše nám tato data mohou prozradit. Nejvhodnější je shromáždit všechna firemní data a koukat se na ně jako na celek. Neomezit se jen na to jaké máme tržby, ale dívat se na tržby vzhledem k regionu apod.

Nás konkrétně zajímá problematika dopravy. Na Obr. 13 vidíme návrh, jak by takové řešení mohlo probíhat. Nejprve určíme zdroje, odkud čerpáme data, ty jsou vstupem do našeho systému. Dalším vstupem je ruční zadávání, kdy uživatel zadává různá modelová data pro what-if („co se stane když“) analýzu. V tomto případě to může být, například když se vedení rozhoduje, zda zakoupit nový vůz. Zvolí si metriku, kterou chce sledovat – třeba průměrná doba dodávky. Do systému pak zadává parametry – např. jedno auto s nosností 3,5 tun či dvě auta s nosností 1,5 tun a sleduje, jak se daná metrika mění. Uvnitř systému si můžeme představit obdobný průchod dat, jako na Obr. 2 v kapitole 2.3. Data ze zdrojových systémů projdou transformacemi a nahrají se do datového skladu. Z něj se pak berou data pro analytické operace a poté se prezentují koncovému uživateli. V tomto případě se prezentují formou scorecard, který se dá připodobnit semaforu. Ten se váže k dané metrice - dobře dodání. Je-li maximálně třídní, situace je v pořádku, svítí zelená. Tři až pět dní je stále v rámci mezí, svítí oranžová. Ale je-li dodací lhůta delší než pět dní, svítí červená.



Obr. 15 Návrh řešení

Než se ale začne se samotným návrhem a implementací řešení, je třeba si promyslet celkovou strategii. To je třeba určit i s ohledem na to, jaké informace máme k dispozici. Především nás zajímá, k čemu bude systém sloužit. V tomto případě jsem určila tři oblasti:

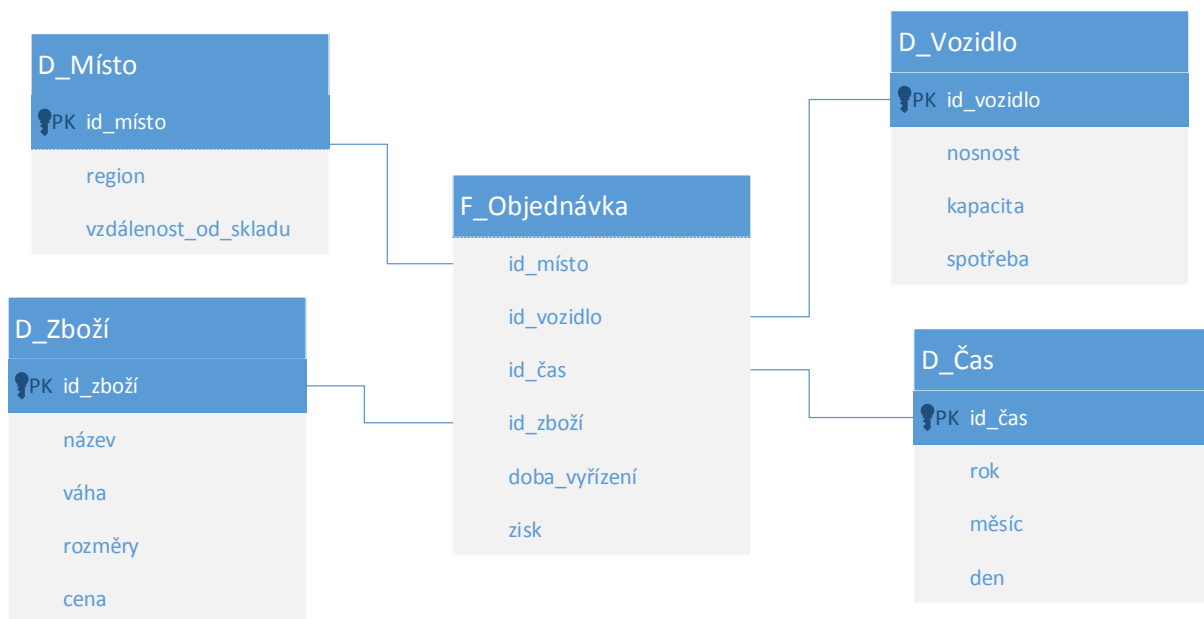
- Podpora rozhodování. Snadnější a efektivní rozhodování je umožněno různými úlohami, jako např. modelováním a analýzou různých scénářů, prediktivní analytikou apod. Příkladem je what-if analýza z předchozího odstavce, kdy se vedení rozhoduje, zda zakoupit nový vůz. Při rozhodování je třeba stručný a rychlý přehled zvolených metrik. Nejlepší proto je zobrazit výstup právě pomocí scorecard. Jak vůbec vypadá, příklad takového scorecardu je ukázán na Obr. 16 na následující straně.

Critical Success Factors	Target	Status
Business Benefit	- Customer Care costs reduced by 15% - Market share increase by 5%	●
Financials	- Program budget tracking at or under 100% of planned	●
Schedule	- Milestone 1 = week 3 - Milestone 2 = week 28 - Milestone 3 = week 48	●
Technology	- Target patents on track - Key technology partners in place	●
Customer	- Product scores 4/5 with target consumer segment - Customer care scores 4/5 with target consumer segment	●

Obr. 16 Scorecard (zdroj:<http://www.expertprogrammanagement.com/2009/07/using-a-balanced-scorecard/>)

- Plánování. V tomto případě se chceme soustředit právě na oblast dopravy zboží – nejen na to, jak plánovat jednotlivé dovážky, což zahrnuje například hledání nejefektivnější trasy, která obslouží co nejvíce cílových míst, ale zároveň je co možná nejkratší a nejrychlejší nebo plánování nákladu, aby vozidlo jezdilo alespoň z větší části naplněné.
- Reporting. Základní účel tohoto je sledovat a vyhodnocovat situaci ve společnosti. Nyní je třeba určit, co chceme sledovat. Můžeme sledovat metriky jako naplněnost vozu, počet porouchaných aut či průměrnou spotřebu paliva atd. Ty se dají nejlépe zobrazit pomocí scorecard. Zde se ale využijí i jiné formy prezentace. Například, chceme-li zjistit, jak moc se v kterém regionu nakupuje konkrétní zboží atp. K tomu se hodí dashboardy a nebo klasické reporty.

Máme tedy určeny zdrojové databáze, definovány cíle řešení a nyní se může přejít k samotnému návrhu a implementaci. Máme tedy zdrojová data, ale potřebujeme je shromáždit na určité místo – do datového skladu. Nejprve si navrhne celkovou strukturu skladu. Začneme tím, že si zvolíme, co vůbec chceme sledovat a poté jednotlivé dimenze (hlediska), ze kterých to chceme sledovat. Co se týče například jedné objednávky (která nese ukazatele jako např. doba vyřízení, zisk apod.) můžeme ji sledovat z hlediska zboží (co se kupuje), vozidla (kdo to dovezl), regionu (kde se nakupuje) a času (kdy bylo doručeno). Tak se může doplňovat o další fakta jako tržby nebo dimenze, jako zákazník (kdo nakupuje) nebo palivo (na kolik vyjde cesta).



Obr. 17 Jednoduchý návrh struktury skladu

Postupně pak vytvoříme celou strukturu datového tržiště - na obr. 17 je triviální návrh datového tržiště, v praxi bývá návrh složitější. Do tržiště můžeme nahrát samotná data. Před tím je ale třeba si určit transformační pravidla, aby byla data co nejvíce kvalitní a zabránilo se např. redundantním záznamům, či vkládání NULL hodnot. Nad tím vším pak můžeme vytvářet OLAP kostky či SQL dotazy nebo provádět různé analytické úlohy. Díky tomu můžeme sledovat, co potřebujeme, například vytíženost jednotlivých vozidel, a jak byla naplněna, v jaké oblasti se nejvíce nakupuje, a které zboží tam je nejžádanější.

4.2 Příklad: Soukromý pivovar

Soukromý pivovar E-pivo je poměrně mladý pivovar. Jeho pivo je jedinečné zprvu tím, že je vařeno tradičním způsobem bez konzervantů. K zákazníkům, ale zvolil poměrně netradiční cestu, a to e-shop,

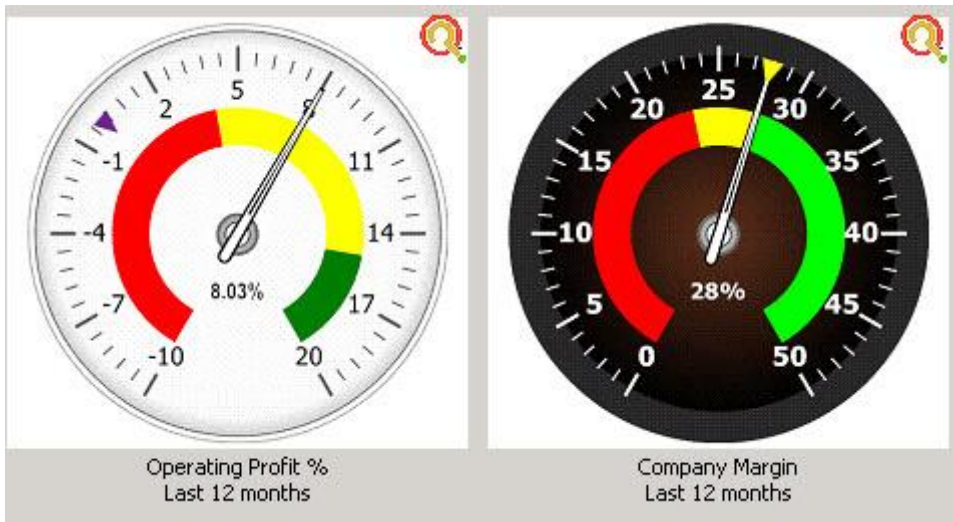
kde, mimo jiné, prodává pивní kosmetiku a suvenýry. Vedle toho má vlastní hospodu s prodejnou. Pro abstinující nebo malé návštěvníky hospody je nabízena domácí limonáda. Pivo má poměrně velký úspěch a to tak, že občas nastane situace, kdy se nestačí ani vařit. Na druhou stranu je zde problém, že toto pivo má menší trvanlivost, a když se neodhadne dávka, musí se přebytky vylévat. Dále management zamýšlí rozšířit pole působnosti. Otázkou je kam. Zda do okolních hospod či do supermarketů, s čímž jsou spojeny další náklady a je otázkou, zda by jejich pivo už v tak velké konkurenci obstálo. Anebo se soustředit na sezónní akce, kde by mohli přilákat nové zákazníky e-shopu. Hlavním cílem je oslovit a přilákat nové zákazníky a s tím rozjet marketingovou kampaň, která má být podpořena systémem.

Jako první krok se opět zamyslíme, jaká data máme k dispozici. Samozřejmě to jsou v první řadě data z e-shopu. Ten nám dává informace o zákaznících jako jméno, věk (z důvodu způsobilosti konzumenta), bydliště, jak často nakupuje, ale i o zboží – konkrétně prodejnosti zboží. Pak je tu účetnictví, informace o dopravci, zaměstnancích, dodavatelích a zboží (druh, forma balení, datum spotřeby, množství na skladě) a vše co se týká vaření. Jako kolik surovin je k dispozici, kolik je třeba na várku nebo kolik litrů se uvaří, a jak dlouho vydrží.

Informací je poměrně dost a nebude nejjednodušší je propojit. Dále musíme i počítat s nějakými externími daty, jako pronájem regálu v supermarketu nebo pronájem stánku na nějaké akci – tyto informace se budou hodit pak pro modelování situačních analýz apod.

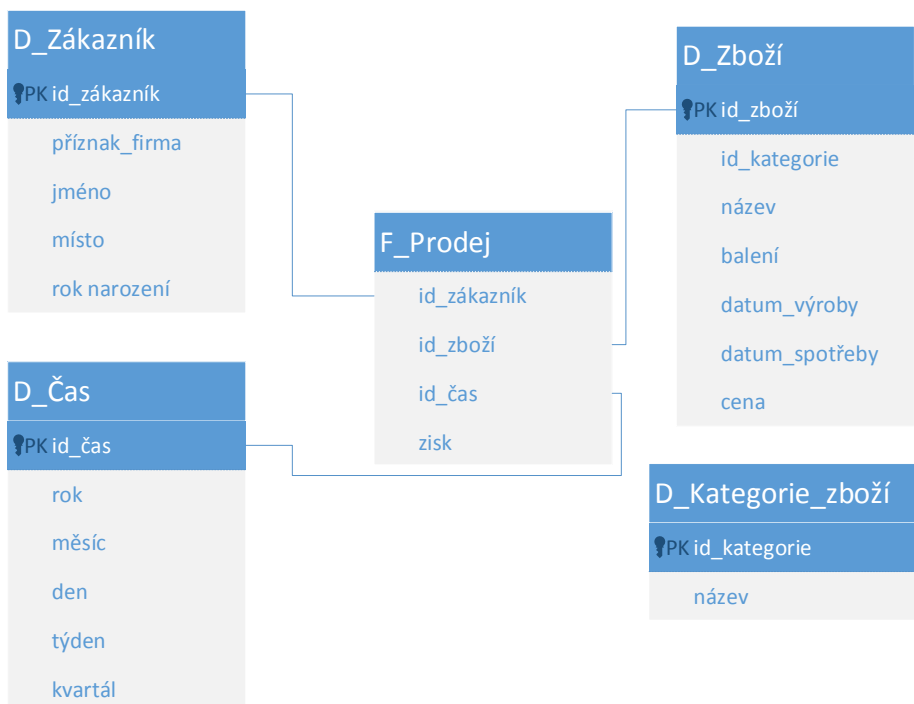
Co je tedy cílem našeho řešení:

- Zefektivnění výroby tak, aby se nemusely likvidovat přebytky a nedocházelo by tak ke ztrátám. Je jasné, že v létě bude větší spotřeba piva než v zimě, ale které množství je ideální pomůže určit systém, který jak z historických dat, tak z předpovědí vypočítá optimální množství.
- Podpora marketingu. Ta zahrnuje například vyhodnocování profitability jednotlivých produktů nebo i plánování a analýza marketingových kampaní. Analyzují se jak náklady na kampaň, tak celkový dopad kampaně. Pivovar se například rozhodne propagovat své produkty na hudebním festivalu. To zahrnuje náklady na pronájem stánku, brigádníky, reklamní letáky apod. Náklady na reklamu by měl pokrýt prodej piva během festivalu. S tím souvisí jedna z otázek, kterou může zodpovědět systém: Kolik piva je třeba prodat, aby se pokryly tyto náklady. Účelem marketingu je také dosáhnout nějakého cíle, tedy stanovit si určitá kritéria úspěšnosti, které potom systém hodnotí třeba pomocí „semaforu“. Jako například cílem kampaně je získat alespoň 150 nových zákazníků. Získá se jich více jak 150, svítí zelená, cíl je splněn. Přibude jich mezi 100-150 zákazníky, je to stále ok, svítí žlutá. Je-li zákazníků méně, kampaň je neúspěšná (červená).
- Reporting, ten je důležitou částí systému. Zobrazuje, jak si firma vede vzhledem k historickým datům nebo vzhledem k plánu. Zde se může sledovat například spotřeba piva, dle krajů či dle věkové skupiny. To je nejjednodušší vyobrazit pomocí dashboardů, kde je navíc možné zvolit určitou metriku, kterou chceme sledovat. Ta se dá vyobrazit například pomocí „tachometru“. Ukazuje-li ručička na červené pole, je to špatné, směřuje-li do žlutého, situace je v rámci mezí, a je-li na zeleném poli, vše je v pořádku. Příklad toho jak takový „tachometr“ může vypadat je na Obr. 18, který je vyňat z dashboardu vyobrazujícím příjmy společnosti. Toto vyobrazení je vhodné například nevystačíme-li si s prostým vyobrazením na „semaforu“, ale chceme i vědět jak daleko jsme od požadovaného výsledku.



Obr. 18 Tachometr z dashboardu (zdroj: <http://www.cleverq.com>)

Jsou vytyčeny požadavky, které má systém splňovat. Nyní je třeba navrhnout, jak toto řešení implementovat. Společnost se chce zaměřit na dvě oblasti. Výroba a marketing, které spolu souvisí. Například po marketingové kampani očekáváme narázově vyšší odbyt, tudíž musíme zvýšit výrobu. Otázkou je zda tyto oblasti řešit samostatně a vytvořit pro ně zvlášť datové sklady, kde by měly vlastní transformační pravidla, vlastní analytické úlohy apod. Nebo vše řešit v rámci jednoho datového tržiště. Jelikož se jedná o malý podnik a v obou případech často využijeme stejné dimenze, může se vše řešit v rámci jednoho tržiště. Výroba je ovlivněná prodejem, kde nás zajímá dimenze zákazníka, zboží a času. U marketingu se zas chceme soustředit na výdělečnost. U toho také využijeme oblast prodeje. Na Obr. 19 je jednoduchý návrh. Jelikož nás zajímá výdělečnost, kromě zisku potřebujeme znát i náklady na výrobu. Takže dále se využije dimenze dodavatele a surovin. Při marketingové kampani nás zajímají náklady s ní spojené a samozřejmě metriky, které si firma vytyčila jako kritérium úspěšnosti (např. počet nových zákazníků, zvýšení tržeb o určité procento apod.)



Obr. 19 Jednoduchý návrh struktury DWH pro pivovar

Než se vytvořené struktury naplní, je třeba opět zvolit transformační pravidla, ať jsou požadovaná data co nejkvalitnější. Poté můžeme nad tržištěm vytvářet dotazy a analýzy.

4.3 Příklad: Cestovní kancelář

V posledním příkladu už jen stručně nadnesu problematiku a popíšu řešení. Vše už bylo popsáno v předchozích příkladech. Tento příklad demonstruje, že ačkoliv se jedná o odlišnou oblast trhu, řešení bude obdobné jako v předchozích dvou příkladech.

Cestovní kancelář se specializuje na Bulharsko a další státy Balkánského poloostrova. Vede se jí velmi dobře, přesto by chtěla přilákat nové zákazníky a uspokojit stávající. Toho chce dosáhnout například pomocí slevových akcí, případně zvažuje i nové destinace. Je ale důležité neopominout hrozbu tzv. kanibalizace, tak se nazývá situace, kdy stávající zákazníci přejdou ze starého produktu na nový, což může vést ke ztrátám. Jako například v případě cestovní kanceláře, kancelář se rozhodne pro akci „ke dvěma dospělým, dvě děti zdarma“. Co když ale už tak velkou část zákazníků tvoří rodiny? To se pak taková akce nemusí kanceláři vůbec vyplatit. Už dříve kancelář vytvářela slevové akce, ale vše tvořila spíše intuitivně a podle toho, co nabízela konkurence, a ve výsledku to nemělo takový efekt, jaký byl očekáván. Právě i k tomu pomůže nasazení MIS.

Kancelář má k dispozici data o zákaznících, zaměstnancích, vozidlech, smluvních hotelech a samozřejmě účetnictví. Také sbírá pro své účely externí data jako kurz měny, cena paliva, nabídky slevových portálů, informace o konkurenci apod. Problém je, že tato data nedokáže efektivně využít. Víme, jaká data máme, je tedy načase zjistit, co vše nám můžou říct. Nejvíce nás zajímají zákazníci. Z daných informací můžeme zjistit, jaká skupina lidí cestuje nejčastěji s touto kanceláří – senioři, rodiny, mladí lidé nebo jiná skupina. Můžeme na to pohlédnout, ale i z jiné dimenze například jaký typ zájezdu daná skupina preferuje. Určitě nás také zajímá, jak velkou část tvoří stálý zákazníci, kteří s kanceláří cestují pravidelně, a jak velkou část tvoří jednorázoví zákazníci. Podle toho se může kancelář rozhodnout, jak různorodé zájezdy nabízet.

Informace o vozidlech, zaměstnancích, účetnictví a externí informace se využijí k plánování zájezdu a jeho kalkulaci. Ale to vše se dá i využít opět k reportingu, kde sledujeme, jak si kancelář vede vzhledem k historii či vzhledem k plánu. Sledovanými ukazateli může být: výdělečnost jednotlivých zájezdů, růst počtu klientů atd.

Tím jsem tedy i vytyčila, k čemu by měl systém sloužit. K plánování akcí, které by bylo podpořené what-if analýzou, uživatel si určí metriku, kterou chce sledovat (např. ziskovost jednotlivých zájezdů, počet nových klientů apod.) a zadává jednotlivé případy – k sedmidennímu zájezdu nabídnu dva dny zdarma nebo ke dvěma rodičům dvě děti zdarma apod. Scorecard („semafor“) pak zobrazí, co se stane s jednotlivými metrikami. Dále bude systém sloužit k plánování samotných zájezdů, podle chování zákazníků i podle kalkulace jednotlivých zájezdů.

Návrh a implementace by probíhala podobně jako v předchozích případech. Určí se data a dimenze a vztahy mezi nimi. Tak se navrhne struktura datového tržiště. Před tím než se do něj nahrají data, musí se určit transformační pravidla. Nad datovým tržištěm se pak vytváří dotazy a analýzy. Výstupem pak je scorecard nebo dashboard.

5 Případová studie

Předchozí příklady jsou spíše koncepty řešení. V této kapitole rozeberu řešení jednoho z příkladů více do detailu. Přejdu tedy od myšlenky k samotné realizaci. Já si k případové studii zvolila hned první příklad týkající se dopravy. Tento příklad jsem vybrala, protože byl pro mě nejlépe uchopitelný.

Studii jsem strukturovala do čtyřech částí. První část jsem věnovala představení zákazníka a jeho analýze. Ve druhé části jsem se zaměřila na samotné řešení systému. Třetí část je zhodnocením přínosů systému pro zákazníka. Nakonec jsem ve čtvrté části zhodnotila samotnou případovou studii.

5.1 Zákazník

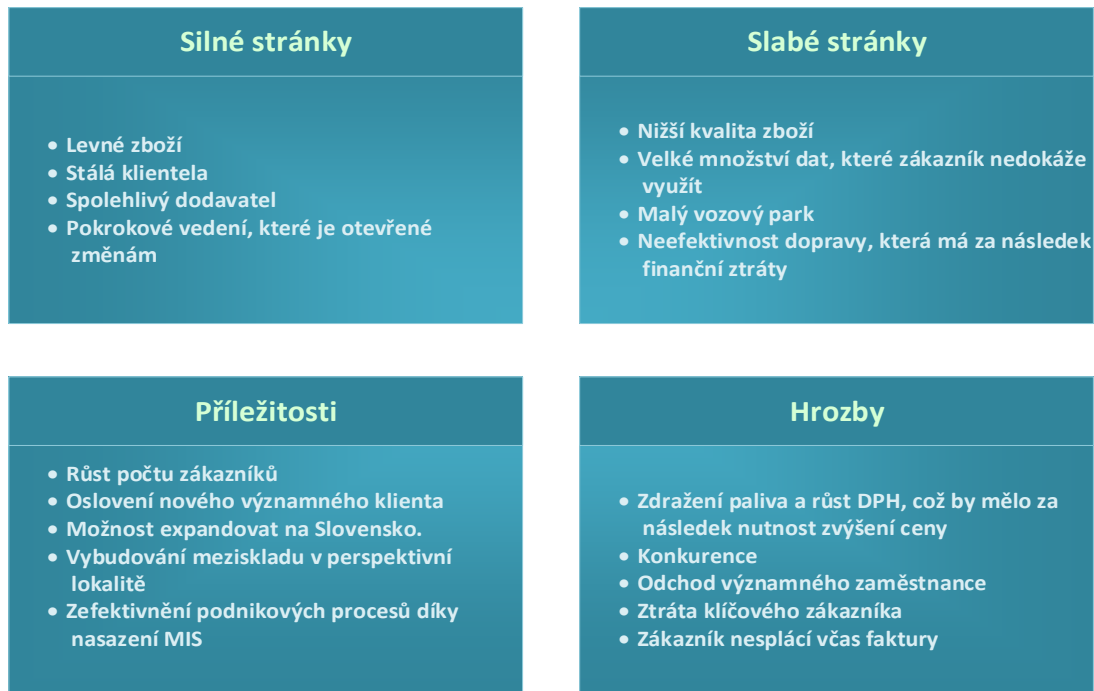
Ačkoli jsem zákazníka představila už v předchozí kapitole, v této kapitole ho chci popsat detailněji, pro pochopení zadané problematiky. Nejprve představím samotnou společnost, tedy to čím se zabývá a její zaměstnance. Dále předvedu SWOT analýzu a poté se detailněji podívám na firemní procesy. Na základě firemních procesů můžu identifikovat uživatele systému. Nakonec se budu soustředit na funkční a nefunkční požadavky zákazníka.

5.1.1 Představení zákazníka

Společnost ABCDíly s.r.o., funguje od roku 2010. Zabývá se prodejem náhradních dílů a autodoplňků, a to buď použitých, které získává z místních vrakovišť nebo nových, které si nechává dovážet z Polska. Přestože na trhu figuruje mnoho společností prodávajících náhradní díly, ABCDíly získává klienty díky nízkým cenám a vstřícnému přístupu vůči zákazníkům. Klientelu tvoří jak fyzické osoby, tak autoservisy. Co se týče velikosti, jedná se o malou firmu do 50 zaměstnanců. Kromě vedení to zahrnuje jednoho pracovníka IT, jednu účetní, zaměstnance na skladě, řidiče a prodejce, což čítá dalších 20 lidí.

5.1.2 SWOT Analýza

Před implementací a zavedením systému byla provedena SWOT analýza firmy, aby byly identifikovány oblasti, ve kterých systém může pomoci, jako například neefektivnost dopravy. Systém bohužel nemůže vyřešit všechny hrozby a slabé stránky. Například nedonutí neplatící zákazníky, aby zaplatili, přesto je může identifikovat jako neplatíče a na základě toho nepřijímat jejich objednávky. Stejně tak neovlivní výši DPH a cenu paliva, ale pomocí what-if analýz může sledovat jak zvýšení DPH nebo zdražení pohonných hmot ovlivní tržby. SWOT analýza na obrázku (Obr. 20) ukazuje stav, který byl před implementací řešení.



Obr. 20 SWOT analýza před nasazením systému

Nasazení systému má na SWOT analýzu (Obr. 21) významný dopad. Výrazně se zredukovaly slabé stránky – efektivnost dopravy se přesunula do silných stránek a problém s velkým množstvím nevyužitelných dat vymizel úplně. Co ale oslabilo zákazníka, je nutnost zaškolení vedoucího skladu, který si na systém hůře zvyká. MIS výrazně posílí silné stránky. Co se týče příležitostí, je jen na zákazníkovi jak je uchopí. Jak už sem psala, MIS nedokáže plně eliminovat hrozby, ale výrazně sníží pravděpodobnost toho, že nastanou.



Obr. 21 SWOT analýza po nasazení systému

5.1.3 Firemní procesy

Známe slabé a silné stránky společnosti. Nyní se můžeme podívat, na to jak to ve firmě běžně chodí. To potřebujeme znát nejen pro to, abychom mohli analyzovat firmu a navrhnout systém, ale i proto abychom určili, kdo vůbec bude uživatelem systému.

Zboží pochází od spolehlivého dodavatele z Polska, který do dvou dní přiveze objednané zboží. Dále společnost nakupuje díly v okolních vrakovištích, které jednou za 14 dní objíždí odborník s volným řidičem. Na skladě se zboží nafotí a přidá do e-shopu. Právě přes e-shop je prodej většinou zprostředkován, další možností je, že se klient se společností dohodne skrze telefon nebo sám přijede na pobočku. V případě objednání přes e-shop či telefon je zboží vyskladněno a připraveno k odvozu, to však může trvat i více dní, než si ho řidič převezme. Klienti si ale mohou připlatit, ať je jim zboží dovezeno přednostně. Samotná platba probíhá hotově při dobírce anebo později přes fakturu.

5.1.4 Uživatelé systému

Na základě údajích o zaměstnancích a firemních procesech byli identifikováni tyto uživatelé systému:

- **Vedení firmy**, které potřebuje mít přehled o dění ve firmě a podklady pro rozhodování.
- **IT pracovník** má na starost technickou stránku systému. Hlavně on spolupracuje s poskytovatelem systému.
- **Vedoucí skladu**, ten nejen potřebuje znát stav zásob ve skladu, ale organizuje vyskladňování a náklad zboží do vozidel.

5.1.5 Funkční a nefunkční požadavky zákazníka

Řešení bylo navrženo a implementováno na základě požadavků zákazníka. Ten kladl především důraz na určité funkcionality a nízkou cenu. Zákazník se chce soustředit především na oblast dopravy, která byla problematickou částí firmy, a ve které docházelo ke ztrátám. To vycházelo především z velkého množství informací, které zákazník nedokázal efektivně využít.

Hlavní funkcí systému je reportovací činnost, která dává přehled o situaci ve firmě. Zákazník chce sledovat především zisk (nebo ztrátu) každého z vozidel, dobu dodání objednaného zboží, naplněnost vozidel a všechny ukazatele související s dopravou. Mimo dopravu se také chce soustředit na tržby podle krajů a na neplatící zákazníky.

Co se týče nefunkčních požadavků, bylo předpokládáno, že řešení bude malé a neovlivní nijak chod e-shopu. Například spouštění ETL procesů bude probíhat přes noc, kdy je vytíženost e-shopu. Stejně tak reportovací dotazy se budou spouštět jednou týdně – v noci z neděle na pondělí. Dalším požadavkem je co nejnižší cena, proto je využito open source nástrojů, kde odpadají počáteční náklady na licence. Zákazník očekává, že nasazení systému zvýší zisk o 20%.

5.2 Řešení

Účelem této kapitoly není předvést, jak má takové řešení vypadat, ale spíše vyzkoušet si návrh datového skladu a zkusit některé BI nástroje. Pro práci jsem zvolila nástroje společnosti Pentaho. Tuto společnost jsem zvolila hlavně proto, že jde o open source řešení a registrace u této společnosti proběhla rychle a bez problémů. Navíc jsem se Pentaho věnovala i v kapitole 3.4.1, takže jsem měla přehled o nástrojích, které poskytuje.

Úlohy jsem řešila v obdobném pořadí, jako jsem popisovala jednotlivé komponenty BI v kapitole 2.3. Asi nejvíce času jsem věnovala návrhu datového skladu. Poté jsem si vyzkoušela jednoduché transformace v programu Data Integration společnosti Pentaho. Vedle Data Integration jsem vyzkoušela Business Analytics. To obsahuje především nástroje pro návrh: Schema Workbench, Aggregation Designer, Metadata Editor a Report Designer.

5.2.1 Datový sklad

Základem celého systému je datový sklad. Proto jsem významnou část věnovala právě návrhu a modelování datového skladu. V první tzv. přípravné části jsem identifikovala dimenze a ukazatele podle požadavků zákazníka a až poté jsem se soustředila na to, zda jsou k dispozici a odkud pocházejí. Ve druhé fázi jsem vytvořila tzv. hrubý dimenzionální model, kde jsem slovně popsala všechny dimenze včetně atributů a zdrojů a všechny ukazatele. V tabulce 1 jsou vyobrazeny dimenze, které mají vliv na ukazatele, které chceme sledovat.

Tabulka 1 Hrubý dimenzionální model - dimenze

Tabulka dimenzí						
Identifikace	Plný název	Obsah	Zdroj	Struktura	Atributy	Poznámky
D_Zak	Zákazník	Dimenze zákazníků a kategorie zákazníků podle toho zda je registrivaný či neregistrovaný	DB E-shopu	Kategorie zákazníka – zákazník	Zak_ID, Zak_kateg_ID, Zak_jmeno, Zak_firma_ID, Zak_kontakt, Zak_PSC	Jedná-li se o fyzickou osobu ID firmy bude "N"
D_cas	Čas	Dimenze času	Manuální	Rok-Měsíc-Den	Cas_ID, Cas_volno, Cas_rok, Cas_mesic, Cas_den,	
D_Zbo	Zboží	Dimenze zboží	DB E-shopu	Kategorie-Skupina podle značky vozu-Typ-Položka	Zbo_ID, Zbo_nazev, Zbo_pouzite, Zbo_kategorie, Zbo_znacka_vuz, Zbo_typ, Zbo_rozmary, Zbo_vaha, Zbo_cena, Zbo_DPH	
D_Voz	Vozidlo	Dimenze vozidla dovážejícího zboží. Zahrnuje mimo jiné i údaje o řidiči vozidla.	kupní smlouvy	–	Voz_ID, Voz_SPZ, Voz_Znacka, Voz_sпотреba, Voz_Pal_ID, Voz_kapacita, voz_nosnost Voz_Rid_ID, Voz_stav	Stav vozidla udává zda je auto k dispozici nebo ne (buď z důvodu poruchy nebo, že je na cestě)
D_Obl	Oblast	Dimenze oblasti kam je zboží dováženo.	Externí, PSC.xls	Obec-Okres-Kraj	Obl_ID, Obl_Zak_PSC, Obl_Obec, Obl_okres, Obl_Kraj	
D_Spl	Splatnost faktury	Dimenze splatnosti faktury. Udává čas splatnosti a stav zda byla uhrazena.	Účetnictví	–	Spl_ID, Spl_cas_id, Spl_stav	Umožňuje kontrolovat zda byla faktura splacena či jak moc, který zákazník přesahuje datum splatnosti
D_Serv	Servis a oprava	Dimenze servis a oprava vozidla	účetnictví, manuální	–	Serv_id, Serv_Voz_ID, Serv_cas_ID, Serv_cena	Umožňuje kontrolovat náklady za vozidlo co se týče oprav a servisu, ale také četnost poruch jednotlivých vozidel atp.
D-Pal	Palivo		Externí	–	Pal_id, Pal_nazev, Pal_cena	
D_PS	Plán nebo skutečnost	Dimenze sloužící k identifikaci, zda se jedná o plán nebo skutečnost	Manuálně	Bez struktury. P –plán, S - skutečnost	PS_ID, PS_nazev	Pomocná dimenze slouží k plánování

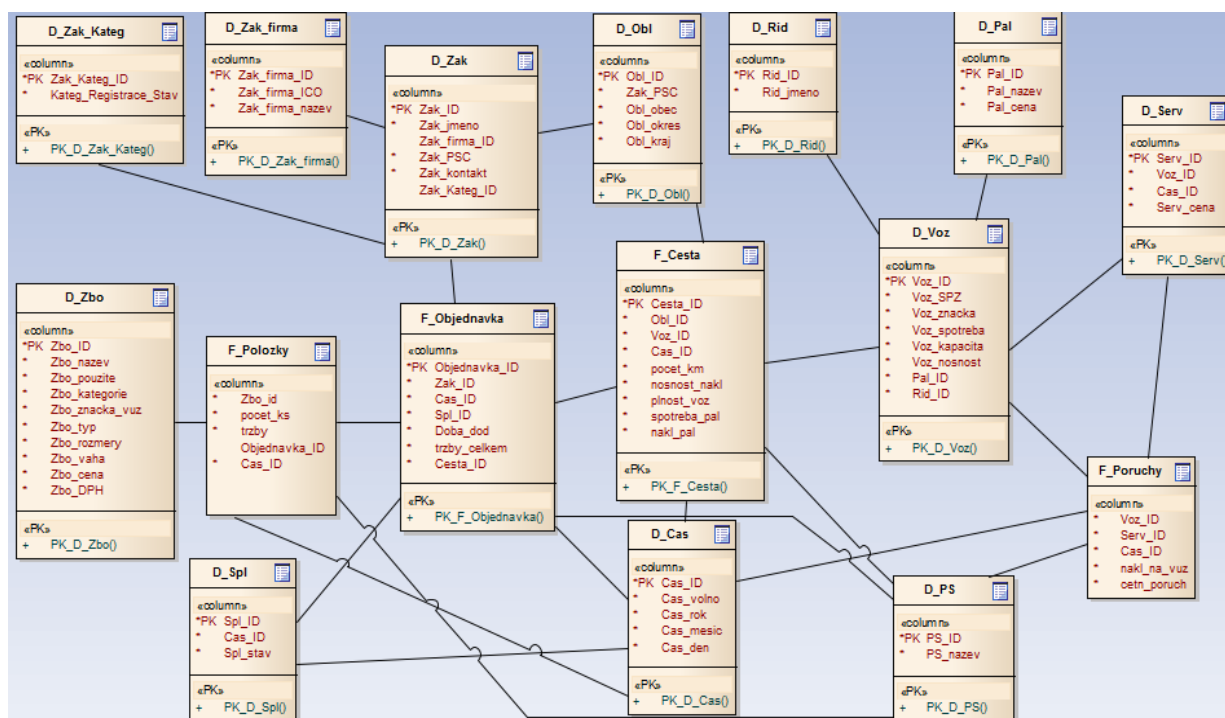
V tabulce 2 jsou vybrané ukazatele, které chceme sledovat. V této tabulce jsou mimo základního popisu i jednotky, ve kterých daný ukazatel měříme a hlavně vztah ukazatele k jednotlivým dimenzím.

Tabulka 2 Hrubý dimenzionální model - ukazatele

Tabulka ukazatelů												
Identifikace	Plný název	Obsah	Jednotka	Poznámka	Dimenze							
					Zak	Cas	Zbo	Voz	Obl	Spl	Serv	Pal
Doba_dod	Doba dodání	Doba dodání od objednání zboží	dny		X	X	X	X				
Trzby	Tržby	Tržby za prodané zboží.	Kč		X	X	X	X				
Pocet_km	Počet ujetých kilometrů	Počet ujetých kilometrů podle řidiče nebo vozidla.	Km			X		X	X			
Spotreba_pal	Spotřeba paliva	Průměrná spotřeba paliva.	l/100 km			X		X				
Nakl_na_pal	Náklady na palivo	Náklady na palivo podle ujetých km.	Kč			X		X	X			X
Nakl_na_vuz	Náklady na vozidlo za servis a opravy	Kolik peněz stojí údržba a opravy vozu.	Kč			X		X			X	
Plnost_voz	Přibližná naplněnost vozidla	Sleduje, jak je auto naplněno.	%	Vypočteno z nosnosti nákladu a nosnosti auta.		X	X	X				
Nosnost_nakl	Nosnost nákladu	Celková nosnost nákladu, které veze vůz.	kg, t	Součet váhy jednotlivých položek nákladu.		X	X	X				
pocet_ks	Počet kusů zboží	Počet jednotlivých položek zboží	Ks		X	X	X					
cetn_poruch	Četnost poruch vozidla	Sleduje, jak často se auto porouchá např. za určité období				X		X			X	

Na základě hrubého dimenzionálního modelu jsem mohla začít navrhovat sklad (Obr. 22). Tento návrh jsem vytvořila v programu Enterprise Architect. Jistě by se dal zvolit vhodnější program, to je ale v našem příkladu nepodstatné. Já zvolila tento program, jelikož jsem ho měla nainstalovaný.

Při návrhu jsem postupovala následovně. Ze zvolených ukazatelů jsem vytvořila tabulky faktů a k nim přiřadila jednotlivé dimenze. Vztahy mezi jednotlivými elementy jsou vytvořeny tak, jak bylo navrženo v hrubém dimenzionálním modelu.

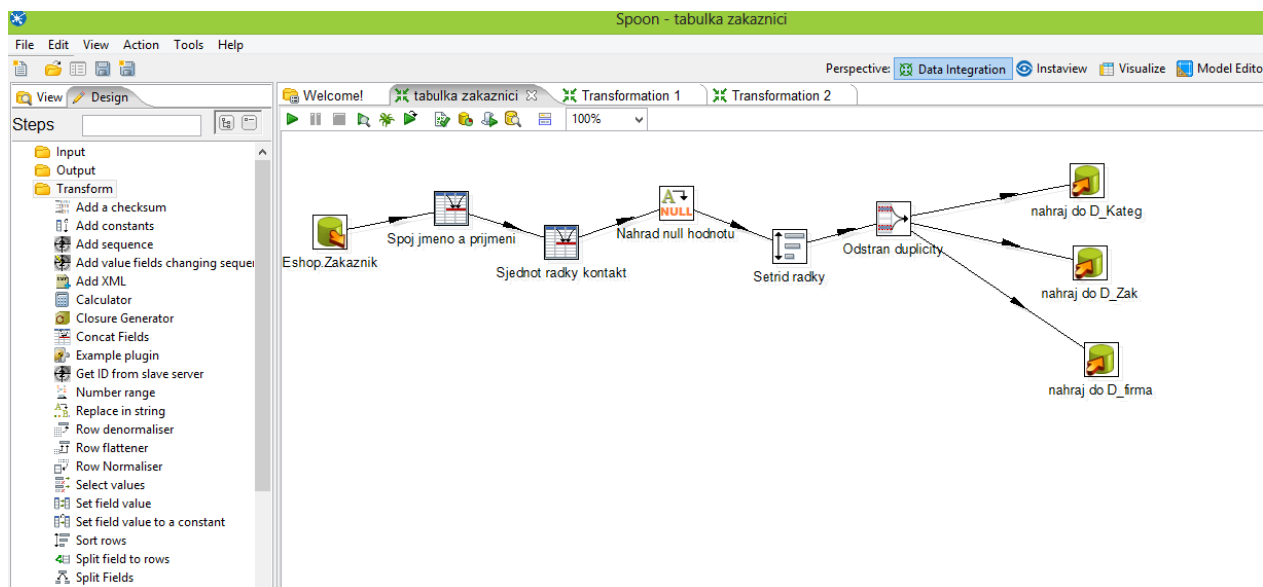


Obr. 22 Model datového skladu

5.2.2 ETL

Vybudovaný sklad je možné naplnit daty. Jelikož, ale struktura datového skladu je odlišná od struktur zdrojových databází, musela tato data projít transformačními úlohami. Transformačními úlohami jsou základní operace, jako například prosté kopírování sloupců, sloučení více sloupců do jednoho, rozdělení položky do více sloupců, změna formátování apod. Ale patří sem především složitější úlohy, jako sloučení dat z více zdrojů do jedné tabulky a následné odstranění duplicit, vytvoření a vypočítání nových agregací podle stanovených podmínek, odstranění NULL dat apod.

Na Obr. 23 je příklad jednoduché transformace. Kromě příkladu samotného je zde ukázka, jak vůbec program na provádění transformací vypadá. Jak už jsem psala, zvolila jsem Data Integration společnosti Pentaho.

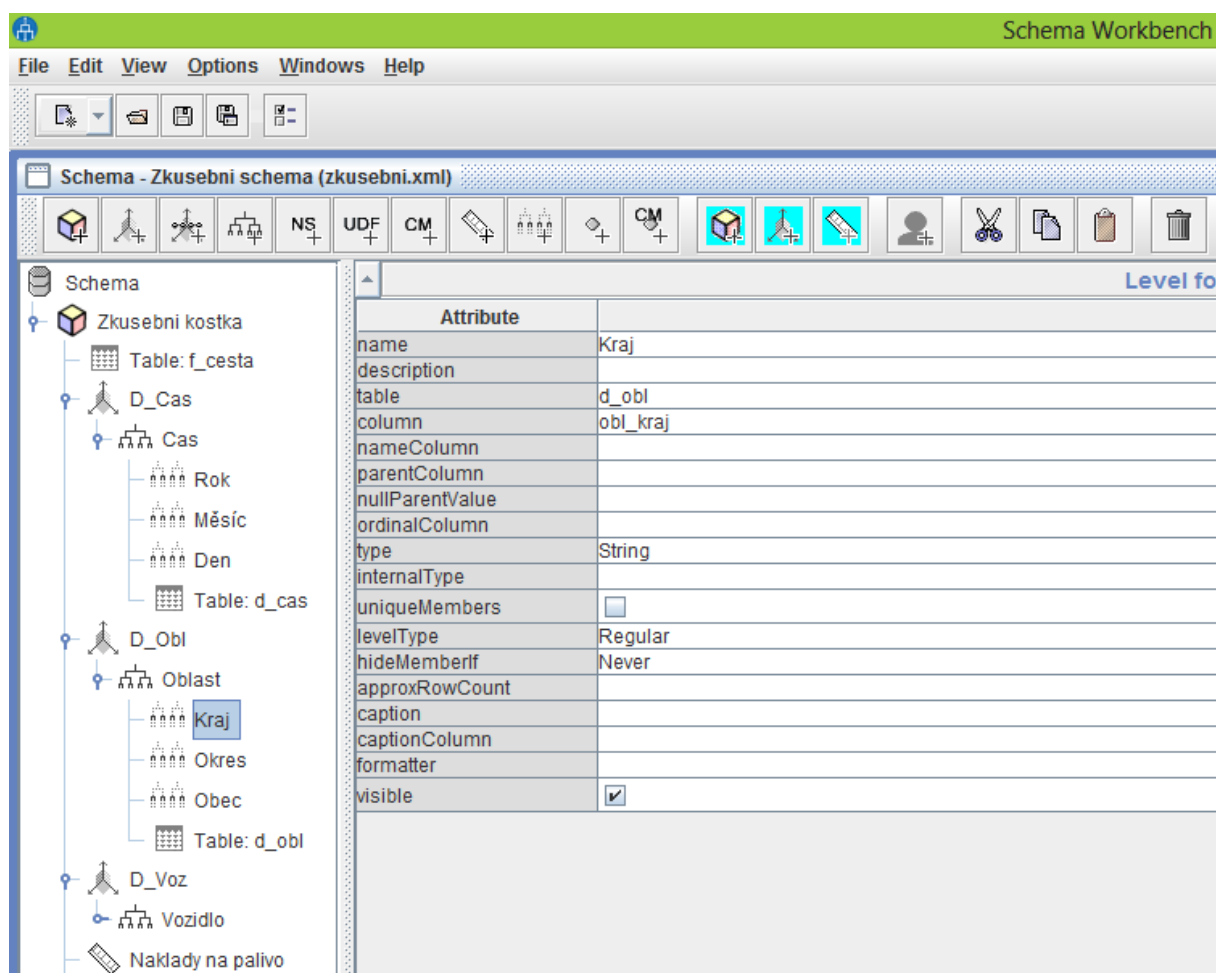


Obr. 23 Jednoduchý příklad transformací

V tomto příkladu jsem transformovala data z tabulky *Zákazníci*, která pochází z databáze E-shopu. Výhodou je, že má obdobnou strukturu jako *D_Zak* v datovém skladu. Provedla jsem jen triviální transformace, kdy jsem spojila sloupce *jméno* a *příjmení* do jednoho. To samé jsem provedla se sloupci obsahující kontaktní informace. Nahradila jsem null hodnoty za hodnotu „N“. Před odstraněním duplicit bylo nutné data seřadit. Poté se data přiřadily do odpovídajících struktur a zároveň se vygeneroval klíč.

5.2.3 OLAP kostky

Datový sklad byl vymodelován tak, aby se nad ním daly snadno vytvářet OLAP kostky. V tomto případě je možno pracovat s kostkami – *Položky*, *Objednávka*, *Cesta* a *Poruchy* a nebo vytvořit další. Na modelování OLAP kostek jsem použila Schema Workbench společnosti Pentaho (Obr. 24).



Obr. 24 Ukázka programu Schema Workbench

Postupovala jsem tak, že jsem nejprve zvolila jednotlivé dimenze kostky, jako čas, oblast nebo vozidlo. Ke každé dimenzi jsem zvolila hierarchii, např. pro oblast jsou úrovně Kraj -> Okres -> Obec. U jednotlivých úrovní si můžu zvolit i datový typ, formát atp. Nakonec jsem vložila vybrané ukazatele, které chci sledovat. Tím jsou např. náklady na palivo.

5.2.4 What-if analýza

Původně jsem chtěla ukázat what-if analýzu na OLAP kostkách, kdy vytváříme různé scénáře díky pomocným kostkám. Bohužel jsem nesehnala vhodný program, proto předvedu princip what-if analýzy v Excelu (obr. 25).

Obr. 25 What-if analýza v excelu


V prvním jednoduchém příkladu chci sledovat, jak mi cena paliva ovlivní náklady na cestu. Postup je jednoduchý. V nabídce „Citlivostní Analýza“ jsem zvolila možnost správce scénářů. Přidala jsem nový scénář, kde jsem učila název scénáře, které políčko se bude měnit („Cena paliva“) a na jakou hodnotu. Takhle jsem vytvořila několik scénářů. Poklepáním na určitý scénář se mi pak mění hodnota „cena za palivo“. Tímto způsobem můžu vytvořit i scénáře, kde se mění více hodnot najednou. Volbou tlačítka „Souhrn...“ jsem v kontingenční tabulce zobrazila, jak vypadá zvolená hodnota („cena za cestu“) pro různé scénáře (obr. 26).

	A	B	C
1	SD\$5;SE\$5 podle	(Vše)	
2			
3	Popisky řádků	\$G\$5	
4	Aktuální cena při nadměrné spotřebě	590,4	
5	Aktuální cena při průměrné spotřebě	442,8	
6	Zdražení benzínu při nadměrné spotřebě	638,4	
7	Zdražení benzínu při průměrné spotřebě	478,8	
8	Zlevnění benzínu při nadměrné spotřebě	494,4	
9	Zlevnění benzínu při průměrné spotřebě	370,8	
10			

Obr. 26 Souhrn scénářů what-if analýzy

V dalším příkladu jsem měla danou cenu benzínu a omezené finance na cestu. Zajímalo mě, jaká má být průměrná spotřeba, abych se vešla do této ceny. K tomu mi v „citlivostní analýze“ pomohla volba „Hledání řešení...“. Do nastavené buňky – „cena za cestu“ jsem zadala hodnotu 500. Měněnou buňkou byla právě „Průměrná spotřeba“. Po stisknutí tlačítka bylo vidět, jaká je ideální spotřeba, když nechci utratit více jak 500 Kč. (Obr. 27).

Cena paliva	Průměrná spotřeba	počet km	cena za palivo
35,9	13,9275766	100	500



Obr. 27 What-if analýza hledání řešení

A nakonec jsem vyzkoušela příklad, kdy chci v tabulce vidět jak je „cena za palivo“ ovlivněna průměrnou spotřebou a délkou trasy. K tomu posloužila volba „Tabulka dat...“. Vytvořila jsem si tabulku, kde v řádce byl počet ujetých km a sloupec obsahoval průměrnou spotřebu. Do rohu tabulky jsem umístila vzorec: $\text{cena_paliva} * (\text{průměrná_spotřeba}/100) * \text{počet_km}$. Poté jsem označila celou tabulku a zvolila „Tabulka dat...“, do políčka „Vstupní buňka řádku“ jsem nastavila buňku „počet km“ a do políčka „Vstupní buňka sloupce“ jsem nastavila „Průměrná spotřeba“. Po stisknutí OK se tabulka naplnila daty, obsahující celkovou cenu za palivo.

Cena paliva	Průměrná spotřeba	počet km	cena za palivo
35,9	10	100	359
359	50	100	150
10	179,5	359	538,5
11	197,45	394,9	592,35
12	215,4	430,8	646,2
13	233,35	466,7	700,05
14	251,3	502,6	753,9
15	269,25	538,5	807,75
16	287,2	574,4	861,6
17	305,15	610,3	915,45
18	323,1	646,2	969,3
19	341,05	682,1	1023,15
20	359	718	1077
Spotřeba			

Obr. 28 What-if analýza tabulka dat

5.2.5 Reporting

Vedle multidimenzionální analýzy jsem využila i klasický reporting. Hledám tedy řešení pomocí SQL dotazů. Jelikož se jedná o malé řešení a databáze obsahuje poměrně malý počet tabulek, je zde toto řešení na místě.

Pro znázornění uvedu dva jednoduché příklady. Zákazník chce mít přehled o neplacích faktur, cílem reportu je tedy u každého zákazníka zjistit počet nesplacených faktur. Pro to byl vytvořen tento dotaz:

```

SELECT D_Zak.Zak_jmeno,
       Count(F_Objednavka.Spl_ID)
FROM D_Zak
     INNER JOIN F_Objednavka
       ON D_Zak.Zak_ID = F_Objednavka.Zak_ID,
     D_Spl
WHERE F_Objednavka.Spl_ID = D_Spl.Spl_ID
     AND D_Spl.Spl_stav = 'nezaplaceno';

```

Obr. 29 SQL dotaz - nesplacené faktury

Další příklad je o trochu složitější. Zákazník chce mít přehled o jednotlivých jízdách, kde chce sledovat počet ujetých kilometrů, náklady na palivo, tržby za dovezené zboží a celkový zisk nebo ztrátu dané jízdy. K tomu byl vytvořen následující dotaz:

```

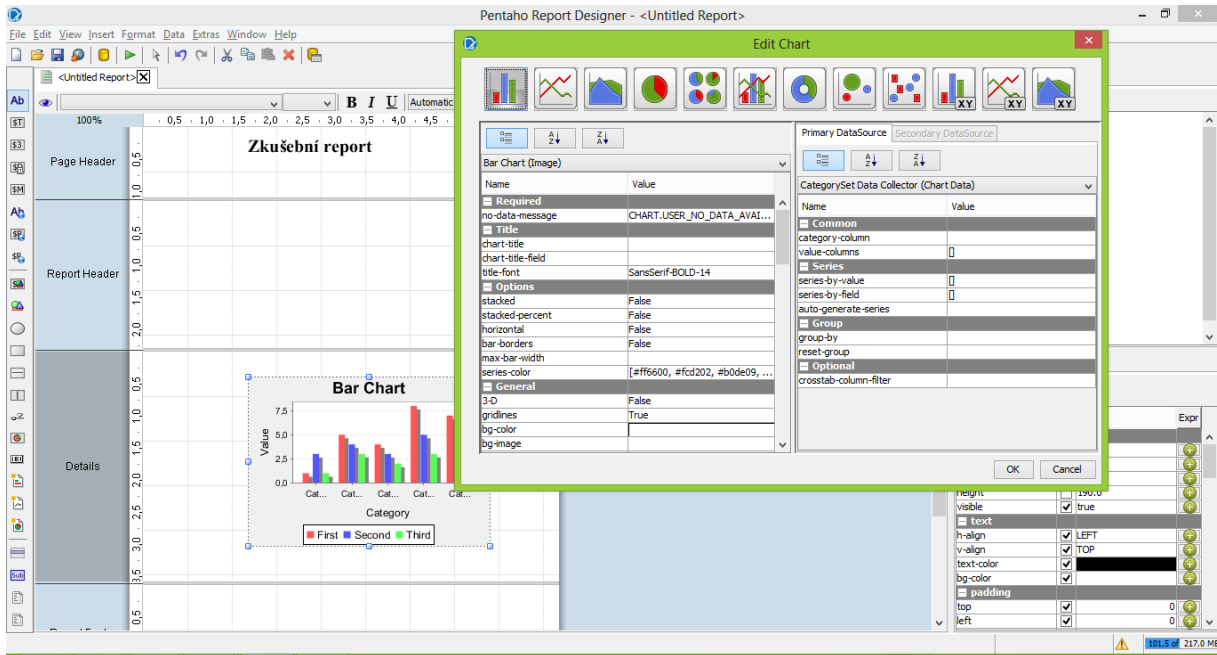
SELECT D_Cas.Cas_den + '.' + D_Cas.Cas_mesic + '.' + D_Cas.Cas_rok,
       D_Rid.Rid_jmeno,
       D_Voz.Voz_SPZ,
       F_Cesta.pocet_km + ' km',
       F_Cesta.nakl_pal + ' Kč' AS Palivo,
       F_Cesta.plnost + '%',
       Sum(F_Objednavka.trzby_celkem) + ' Kč' AS Trzby,
       Palivo - Trzby AS Zisk
FROM F_Cesta
     INNER JOIN D_Voz
       ON F_Cesta.Voz_ID = D_Voz.Voz_ID
     INNER JOIN D_Rid
       ON D_Voz.Rid_ID = D_Rid.Voz_ID
     INNER JOIN F_Objednavka
       ON F_Cesta.Cesta_ID = F_Objednavka.Cesta_ID
     INNER JOIN D_Cas
       ON F_Cesta.Cas_ID = D_Cas.Cas_ID
GROUP BY D_Cas.Cas_Rok,
         D_Cas.Cas_Mesic,
         D_Cas.Cas_Den,
         Zisk;

```

Obr. 30 SQL dotaz – doprava

5.2.6 Prezentace dat

Po provedení analýz je třeba získané výsledky prezentovat. Nejlépe v co nejpřehlednější formě. Pro tento účel jsem měla program Report Designer. Na obr. 31 je ukázka, jak tento program vypadá.



Obr. 31 Report Design

5.2.7 Kalkulace

Při kalkulaci nákladů projektu vycházím z odhadů a z toho, kolik času jsem věnovala jednotlivým částem. Je třeba ale navíc započítat součinnost se zákazníkem, čímž se nám čas práce prodlouží a také je třeba brát v potaz, že já jsem vytvářela poměrně triviální úlohy. Proto jsem veškerý čas vynásobila koeficientem 3. Dále je třeba spočítat cenu za člověkohodinu, která nezahrnuje jen hrubou hodinovou mzdu, ale i ostatní náklady na zaměstnance, tu jsem stanovila na 700 Kč.

Tabulka 3 Náklady na projekt

Část	můj čas	člk	cena
Návrh datového skladu	15	45	31 500 Kč
Implementace datového skladu	6	18	12 600 Kč
Transformační pravidla	30	90	63 000 Kč
OLAP kostky	10	30	21 000 Kč
What-if analýza	10	30	21 000 Kč
Reporting	10	30	21 000 Kč
Tvorba reportů	4	12	8 400 Kč
Celkem			178 500 Kč

Pro implementaci bylo zvoleno open source řešení, kde jsou nulové náklady na licence. Náklady se kterými se dále musí počítat je školení uživatelů. Školení trvá týden, každý den 2 hodiny. Počítám-li opět s částkou 700 Kč/člh, vychází náklady na školení na 7000 Kč. Zákazníku bude nadále poskytována podpora. Po zavedení bude třeba častější součinnosti tj. alespoň 12 hodin měsíčně. Předpokládá se, ale že počet hodin postupem času klesne.

5.3 Přínosy řešení

Přínosy řešení byly v podstatě shrnuty ve SWOT analýze v kapitole 5.1.2. Zavedení MIS přineslo zákazníkovi lepší přehled o podnikových procesech, efektivnější dopravu a možnost plánování.

Já se v této kapitole chci hlavně podívat nebo spíše zauvažovat nad návratností tohoto systému. Čistý roční zisk této firmy je 1,2 milionu Kč. Nasazení tohoto systému má přinést zvýšení tohoto zisku o 20%. To dělá 240 000 Kč. Náklady na nasazení systému není jen částka, kterou jsem spočítala v tabulce, ale i náklady na školení a následnou podporu. Dejme tomu, že první půl rok je průměrná součinnost 14 hodin měsíčně, další půl rok to klesne na 8 hodin měsíčně. Částku na člověkohodinu nechám opět 700 Kč. Když to sečteme: $(6*14+6*8)*700 = 92\,400$ Kč. Celkové náklady na systém za celý rok jsou pak: $178\,500 + 7\,000 + 92\,400 = 277\,900$ Kč. Už při porovnání těchto dvou čísel vidíme, že se systém zaplatí za rok něco. Spočítám, ale ještě ROI (= (čistý zisk – investice)/investice*100), to vychází cca -13%. Je tedy vidět, že za rok se systém sám nezaplatí, ale je splacen z cca 87%.

5.4 Zhodnocení případové studie

Jak jsem psala v úvodu kapitoly 5.2, v této studii jsem si spíše vyzkoušela BI nástroje, než abych vytvořila plnohodnotné řešení. Pro tuto práci jsem použila nástroje společnosti Pentaho, bohužel se mi nepodařilo spustit vše, co jsem chtěla vyzkoušet – např. Mondrian pro práci s OLAP kostkami či Business Analytics Community Edition, která by měla být spuštěna přes webové rozhraní. Omezila jsem se proto jen na nástroje Data Integration, Schema Workbench a Report Designer.

Při tvorbě této práce jsem se setkala s BI nástroji poprvé, takže věřím, že kdybych vytvářela systém znovu, udělala bych to lépe. Zvolila bych ale nástroje jiné společnosti. Nedá se říct, že by mi nástroje společnosti Pentaho vůbec nevyhovovali, ale myslím, že existují i lepší nástroje.

6 Závěr

Prvním cílem této práce bylo představit MIS a DSS a jednotlivé komponenty. Kromě toho, že jsem tyto termíny definovala, podívala jsem se hlavně na technické řešení. Myslím, že díky tomu by měl mít čtenář jasno nejen v tom, co jsou manažerské systémy, ale i v tom, jak tyto systémy fungují. Dále jsem již existující řešení prezentovala pohledem na poskytovatele BI a BA řešení. Mluvila jsem hlavně o nástrojích, které nabízí nejznámější společnosti.

Dalším cílem bylo ukázat možná využití systému a hlavně to, že systémy najdou uplatnění i v SME podnicích. To jsem demonstrovala na třech příkladech z různého odvětví. Ve všech příkladech figurovaly malé firmy. Ačkoliv každá funguje v jiném oboru je vidět, že postup řešení bude v podstatě stejný.

Cílem případové studie bylo ukázat detailně, jak má takové řešení probíhat. Já v této studii spíše představila nástroje společnosti Pentaho a ukázala postup řešení na jednotlivých příkladech.

Přínosem této práce je seznámení s MIS a DSS a hlavně jednotlivých nástrojů. V této práci byly představeny především nástroje společnosti Pentaho. Zároveň s tím čtenář poznal, jak vypadá postup při budování manažerského informačního systému. Práce měla přínos hlavně pro mě, jelikož před tím jsem s MIS ani DSS neměla žádné zkušenosti. Navíc jsem se naučila pracovat s některými BI nástroji.

Na práci by se dalo v budoucnu navázat, například by bylo zajímavé srovnání open source řešení s proprietárním.

7 Seznam použité literatury

- [1] NOVOTNÝ, Ota. *Business intelligence: jak využít bohatství ve vašich datech*. 1. vyd. Praha: Grada, 2005, 254 s. ISBN 80-247-1094-3.
- [2] POUR, Jan, Miloš MARYŠKA a Ota NOVOTNÝ. *Business intelligence v podnikové praxi*. 1. vyd. Praha: Professional Publishing, 2012, 276 s. ISBN 978-80-7431-065-2.
- [3] GÁLA, Libor, Jan POUR a Zuzana ŠEDIVÁ. *Podniková informatika: jak využít bohatství ve vašich datech*. 2., přeprac. a aktualiz. vyd. Praha: Grada, 2009, 496 s. Expert (Grada). ISBN 978-80-247-2615-1.
- [4] VOŘÍŠEK, Jiří, Jan POUR a Zuzana ŠEDIVÁ. *Principy a modely řízení podnikové informatiky*. Vyd. 1. Praha: Oeconomica, 2008, 446 s. Expert (Grada). ISBN 978-80-245-1440-6.
- [5] PARMENTER, David. *Key performance indicators: developing, implementing, and using winning KPIs*. 2nd ed. Hoboken, N.J.: John Wiley, c2010, xix, 299 p. ISBN 04-705-4515-1.
- [6] *Systemonline: Zpravodajský portál časopisu IT Systems* [online]. 2001-2013 [cit. 2013-12-11]. Dostupné z: <http://www.systemonline.cz/>
- [7] *Wikipedia: Otevřená encyklopedie* [online]. 2013 [cit. 2013-12-11]. Dostupné z: www.wikipedia.org
- [8] *Inter-Informatics Group: KPI - Key Performance Indicator* [online]. 2013 [cit. 2013-12-15]. Dostupné z: <http://www.mereniprocessu.cz/KPI-Key-performance-indicator.html>
- [9] *CIO BusinessWorld.cz: IT strategie pro manažery* [online]. 2007-2013 [cit. 2013-12-15]. Dostupné z: www.businessworld.cz
- [10] POUR, Jan. *Řízení výkonnosti podniku (CPM)*. *BPM Portál* [online]. 2008 [cit. 2013-12-15]. Dostupné z: <http://bpm-cz.blogspot.cz/2008/03/cpm.html>
- [11] HAVLENA, Matouš. *Co je Business Analytics?*. *Business Analytics & Intelligence* [online]. 18.1.2013 [cit. 2013-12-15]. Dostupné z: <http://www.havlena.net/business-analytics-a-intelligence/big-data-analytics-cast-1-co-je-business-analytics/>
- [12] MICROSOFT. *Microsoft* [online]. 2013 [cit. 2013-12-17]. Dostupné z: <http://www.microsoft.com/>
- [13] IBM. *Česká republika* [online]. 2013 [cit. 2013-12-17]. Dostupné z: www.ibm.cz
- [14] SAP [online]. 2013 [cit. 2013-12-17]. Dostupné z: www.sap.com
- [15] Oracle [online]. 2013 [cit. 2013-12-17]. Dostupné z: www.oracle.com
- [16] SAS. *Business Analytics and Business Intelligence software* [online]. 2013 [cit. 2013-12-18]. Dostupné z: <http://www.sas.com>
- [17] Helios [online]. 2013 [cit. 2013-12-18]. Dostupné z: <http://www.helios.eu>
- [18] CCA [online]. 2013 [cit. 2013-12-18]. Dostupné z: <http://www.cca.cz/>
- [19] CZM *Centrum znalostního managementu: Výuka* [online]. 2013 [cit. 2013-12-18]. Dostupné z: <http://czm.fel.cvut.cz/vyuka/default.aspx>
- [20] *Business Intelligence a datová analytika. Computerworld: Ucelený informační zdroj pro IT profesionály*. Praha: IDG Czech, a.s, 2013, listopad.

- [21] *Computerworld: Ucelený informační zdroj pro IT profesionály* [online]. Praha: IDG Czech, a.s., 2013 [cit. 2013-12-18]. Dostupné z: <http://computerworld.cz>
- [22] Jak fungují magické kvadranty?. In: *KPC-Group* [online]. 2013 [cit. 2014-05-13]. Dostupné z: <http://kpc-group.cz/wp-content/uploads/2013/07/magicke-kvadranty.pdf>
- [23] VÁLEK, Jan. *Srovnání komerčních BI nástrojů s nástroji Open Source*. 2008, Praha. Diplomová práce. VŠE v Praze.
- [24] The NIST Definition of Cloud Computing. [online]. [cit. 2014-05-13]. Dostupné z: <http://csrc.nist.gov/publications/nistpubs/800-145/SP800-145.pdf>
- [25] *Techopedia* [online]. 2010-2014 [cit. 2014-05-13]. Dostupné z: <http://www.techopedia.com/>
- [26] OLAP. In: DANEL, Roman. *WWW stránky Technické univerzity v Ostravě* [online]. 2010 [cit. 2014-05-13]. Dostupné z: http://homel.vsb.cz/~dan11/is_skripta/IS%202010%20-%20Danel%20-%20OLAP.pdf
- [27] HÁJEK, Vojtěch. *Implementace Business Intelligence v malé a střední firmě – JOLLY Trading s.r.o.* Praha, 2006. Diplomová práce. VŠE v Praze.
- [28] ORAL, Tomáš. *Případová studie zavádění nového informačního systému v podniku*. Brno, 2006. Diplomová práce. Masarykova univerzita v Brně.
- [29] POKORNÝ, Jiří. *What-if analýza v nástroji CPM*. Praha, 2011. Diplomová práce. VŠE v Praze.
- [30] *Pentaho: Business analytics and business intelligence leaders* [online]. 2014 [cit. 2014-05-20]. Dostupné z: <http://www.pentaho.com/>
- [31] *GoodData: Experience SaaS Business Intelligence* [online]. 2014 [cit. 2014-05-20]. Dostupné z: <http://www.gooddata.com/>
- [32] Manažerský informační systém. *Kisk: Kabinet informačních studií a knihovnictví* [online]. 2010 [cit. 2014-05-21]. Dostupné z: http://kisk.phil.muni.cz/wiki/Mana%C5%BEersk%C3%BD_informa%C4%8Dn%C3%AD_syst%C3%A9m
- [33] *Tableau Software: Business Intelligence and Analytics* [online]. 2014 [cit. 2014-05-21]. Dostupné z: <http://www.tableausoftware.com/>
- [34] *Solution Review* [online]. 2014 [cit. 2014-05-21]. Dostupné z: <http://solutions-review.com/>

8 Seznam použitých zkratek

Zkratka	Plný název
ABC	Activity Based Costing
BA	Business Analytics
BI	Business Intelligence
BSC	Balanced Scorecard
CRM	Customer Relationship Management – systém pro řízení vztahu se zákazníky
ČLH	Člověkohodina
DSS	Systém pro podporu rozhodování
DWH	Datový sklad
EAI	Enterprise Application Integration – nástroj pro integraci systémů
EIS	Executive Information System – Systém pro podporu vrcholového řízení
ELT	Extract, Load, Transform – nástroj pro získání, nahrání a úpravu dat
ERP	Enterprise Resource Planning – systém pro řízení podnikových zdrojů
ETL	Extract, Transform, Load – nástroj pro získání, úpravu a nahrání dat do DWH
IS	Informační systém
KPI	Key Performance Indicator – Klíčový ukazatel výkonnosti
KRI	Key Result Indicator – Klíčový ukazatel výsledků
MIS	Manažerský informační systém
OLAP	On-Line Analytical Processing
PI	Performance Indicator – Ukazatel výkonnosti
RI	Result Indicator – Ukazatel výsledků
RIS	Rezervační informační systém
SaaS	Software as a Service – Software jako služba
SME	Small and Medium Enterprises – Malé a střední podniky
TPS	Transaction Processing System - Transakční informační systém