

IT a analytika retailové firmy



doc. Ing. Ota Novotný, Ph.D.


doc. Ing. Jan Pour, CSc.

Ing. Martin Potančok, Ph.D.

Ing. et Ing. Soňa Karkošková, Ph.D.

V tisku

ISBN 978-80-88260-85-1.



Úvodní poznámky

(Vymezení účelu a obsahu publikace „Analytika retailové firmy“, charakteristika celkové struktury, zasazení do celkové struktury portálu MBI-AF a vazby na ostatní publikace.)

[A] Principy analytiky retailové firmy

(Vymezení podstatných komponent v řízení analytiky retailové firmy (úlohy, metriky, datové zdroje, faktory atd. Primární zaměření publikace je na deskriptivní a prediktivní analytiku.)

[B] Analytika retailové firmy podle oblastí řízení

(Přehled oblastí řízení retailové firmy, funkcionalita úloh deskriptivní i prediktivní analytiky podle vybraných oblastí řízení retailové firmy, vymezení metrik a dimenzí a jejich vazeb, návrh analytických otázek.)

[C] Přílohy

(Základní principy Machine Learning. Prediktivní analytika v řízení energií v retailu.)

Obsah

<i>Úvodní poznámky</i>	<i>9</i>
A. Principy analytiky retailové firmy.....	14
1. Analytika retailové firmy, celkový koncept.....	15
1.1 Přístupy k řešení analytiky v retailu	15
1.2 Oblasti řízení retailové firmy	16
1.3 Úrovně řešení analytiky.....	17
1.4 Závěry	17
2. Principy a komponenty deskriptivní analytiky	19
2.1 Analytické úlohy	19
2.2 Scénáře, analytické otázky	19
2.3 Role.....	20
2.3.1 Architekt podnikové analytiky	20
2.3.2 Byznys analytik	21
2.3.3 Datový analytik	21
2.4 Data, datové zdroje	21
2.5 Faktory ovlivňující deskriptivní analytiku v retailu.....	23
2.6 Metriky	24
2.7 Analytické dimenze.....	25
2.8 Postupy, metody, metodiky	29
2.9 IT aplikace a nástroje pro analytiku	30
2.10 Závěry.....	30
3. Principy a komponenty prediktivní analytiky.....	32
3.1 Úlohy plánování a prognóz	33
3.2 Hlavní principy prediktivní analytiky	33
3.3 Úlohy prediktivní analytiky	34
3.4 Příprava prediktivní analytiky	34
3.5 Vymezení dílčích funkcí prediktivní analytiky	35
3.6 Scénáře, analytické otázky	37
3.7 Role prediktivní analytiky.....	37
3.7.1 Doménový expert	38
3.7.2 Data a databázový expert	38
3.7.3 Expert prediktivního modelování	38
3.8 Faktory ovlivňující prediktivní analytiku v retailu	39
3.9 Cílové proměnné a prediktory.....	40
3.10 Metody a metodiky.....	40

3.10.1	Metodika CRISP-DM.....	40
3.10.2	Strojové učení, Machine Learning	41
3.10.3	Regresní analýzy	43
3.10.4	Rozhodovací stromy.....	44
3.10.5	Neuronové sítě	45
3.11	Závěry.....	46
Závěry k oddílu A: Principy analytiky retailové firmy.....		47
B.	Analytika retailové firmy podle oblastí řízení.....	48
1.	Analytika ve strategickém řízení retailové firmy.....	52
1.1	Strategické analýzy	52
1.2	Formulace strategie	52
1.3	Řešení analytiky v rámci strategického řízení.....	53
2.	Finanční analytika	54
2.1	Deskriptivní finanční analytika	54
2.1.1	Dimenze finanční analytiky	55
2.1.2	Metriky finanční analytiky	56
2.1.3	Funkce finanční analytiky	57
2.2	Deskriptivní analytika závazků	57
2.2.1	Dimenze analytiky závazků	58
2.2.2	Metriky analytiky závazků	59
2.2.3	Funkce analytiky závazků	59
2.3	Deskriptivní analytika pohledávek.....	60
2.3.1	Dimenze analytiky pohledávek	61
2.3.2	Metriky analytiky pohledávek.....	61
2.3.3	Funkce analytiky pohledávek.....	62
2.4	Řešení deskriptivní analytiky v rámci finančního řízení.....	62
2.5	Prediktivní finanční analytika	63
2.5.1	Cílové proměnné ve finančním řízení	64
2.5.2	Funkce prediktivní analytiky a plánování ve finančním řízení	64
2.6	Řešení plánování prediktivní analytiky v rámci finančního řízení	65
3.	Personální a mzdová analytika	67
3.1	Deskriptivní personální analytika	67
3.1.1	Dimenze personální analytiky	68
3.1.2	Metriky personální analytiky.....	68
3.1.3	Funkce personální analytiky.....	69
3.2	Deskriptivní mzdová analytika.....	69
3.2.1	Dimenze mzdové analytiky.....	70
3.2.2	Metriky mzdové analytiky	71
3.2.3	Funkce mzdové analytiky.....	71
3.3	Řešení deskriptivní analytiky v personálním řízení.....	71
3.4	Prediktivní personální analytika	72
3.4.1	Cílové proměnné v personálním řízení.....	73
3.4.2	Funkce prediktivní analytiky a plánování v personálním řízení	73
3.5	Prediktivní mzdová analytika	74
3.5.1	Cílové proměnné v řízení práce a mezd	75
3.5.2	Funkce prediktivní analytiky a plánování v řízení práce a mezd	75
3.6	Řešení prediktivní analytiky v personálním řízení	76

4.	<i>Analytika v marketingu</i>	77
4.1	Deskriptivní analytika v marketingu	77
4.1.1	Dimenze analytiky v marketingu	78
4.1.2	Metriky analytiky v marketingu	78
4.1.3	Funkce analytiky v marketingu	79
4.2	Řešení deskriptivní analytiky marketingu	79
4.3	Prediktivní analytika v marketingu	80
4.3.1	Cílové proměnné v marketingu	81
4.3.2	Funkce prediktivní analytiky a plánování v marketingu	81
4.4	Řešení prediktivní analytiky a plánování v marketingu	82
5.	<i>Analytika vztahů k zákazníkům</i>	84
5.1	Deskriptivní analytika vztahů k zákazníkům	84
5.1.1	Dimenze analytiky vztahů k zákazníkům	85
5.1.2	Metriky analytiky vztahů k zákazníkům	85
5.1.3	Funkce analytiky vztahů k zákazníkům	86
5.2	Řešení deskriptivní analytiky vztahů k zákazníkům	86
5.3	Prediktivní analytika řízení vztahů k zákazníkům	87
5.3.1	Cílové proměnné v řízení vztahů k zákazníkům	87
5.3.2	Funkce prediktivní analytiky a plánování v řízení vztahů k zákazníkům	87
5.4	Řešení prediktivní analytiky a plánování řízení vztahů k zákazníkům	88
6.	<i>Analytika v řízení nákupů</i>	90
6.1	Deskriptivní analytika nákupů	90
6.1.1	Dimenze analytiky nákupů	91
6.1.2	Metriky analytiky nákupů	91
6.1.3	Funkce analytiky nákupů	92
6.2	Řešení deskriptivní analytiky nákupu	93
6.3	Prediktivní nákupní analytika	93
6.3.1	Cílové proměnné v řízení nákupů	94
6.3.2	Funkce prediktivní analytiky a plánování v řízení nákupů	94
6.4	Řešení prediktivní analytiky a plánování nákupů	95
7.	<i>Skladová analytika</i>	97
7.1	Deskriptivní skladová analytika	97
7.1.1	Dimenze skladové analytiky	98
7.1.2	Metriky skladové analytiky	98
7.1.3	Funkce skladové analytiky	99
7.2	Řešení deskriptivní analytiky skladů a skladových zásob	99
7.3	Prediktivní analytika v řízení skladů	100
7.3.1	Cílové proměnné v řízení skladů	101
7.3.2	Funkce prediktivní analytiky a plánování v řízení skladů	101
7.4	Řešení prediktivní analytiky a plánování skladů	102
8.	<i>Analytika prodeje</i>	104
8.1	Deskriptivní analytika prodeje	104
8.1.1	Dimenze analytiky prodeje	105
8.1.2	Metriky analytiky prodeje	105
8.1.3	Metriky výkonnosti prodeje	106
8.1.4	Metriky prodeje prostřednictvím eShopu	106
8.1.5	Funkce analytiky prodeje	106

8.2	Řešení deskriptivní analytiky prodeje	107
8.3	Prediktivní prodejní analytika.....	108
8.3.1	Cílové proměnné v řízení prodeje	109
8.3.2	Funkce prediktivní analytiky a plánování v řízení prodeje	109
8.4	Řešení prediktivní analytiky a plánování prodeje	110
9.	Analytika logistiky.....	112
9.1	Deskriptivní analytika logistiky.....	112
9.1.1	Dimenze analytiky logistiky.....	113
9.1.2	Metriky analytiky logistiky	113
9.1.3	Funkce analytiky logistiky	114
9.2	Řešení deskriptivní analytiky v řízení logistiky	115
9.3	Prediktivní analytika v logistice	116
9.3.1	Cílové proměnné v řízení logistiky	117
9.3.2	Funkce prediktivní analytiky a plánování logistiky	117
9.4	Řešení prediktivní analytiky v řízení logistiky.....	118
10.	Cenová analytika	120
10.1	Deskriptivní cenová analytika.....	120
10.1.1	Dimenze cenové analytiky	121
10.1.2	Metriky cenové analytiky.....	121
10.1.3	Funkce cenové analytiky	121
10.2	Řešení deskriptivní cenové analytiky	122
10.3	Prediktivní cenová analytika.....	122
10.3.1	Cílové proměnné v řízení cen.....	123
10.3.2	Funkce prediktivní analytiky a plánování cen.....	123
10.4	Řešení prediktivní analytiky a plánování cen.....	124
11.	Analytika majetku, investic, údržby a zajištění energiemi.....	126
11.1	Deskriptivní analytika majetku	126
11.1.1	Dimenze analytiky majetku.....	127
11.1.2	Metriky analytiky majetku	127
11.1.3	Funkce analytiky majetku	127
11.2	Deskriptivní analytika investic a údržby	128
11.2.1	Dimenze analytiky investic a údržby	128
11.2.2	Metriky analytiky investic a údržby	129
11.2.3	Funkce analytiky investic a údržby	129
11.3	Deskriptivní analytika energií.....	129
11.3.1	Dimenze analytiky energií	130
11.3.2	Metriky analytiky energií	131
11.3.3	Funkce analytiky energií	131
11.4	Řešení deskriptivní analytiky v řízení majetku, investic, údržby a energií	132
11.5	Prediktivní analytika investic, údržby	133
11.5.1	Cílové proměnné a prediktory	133
11.5.2	Funkce prediktivní analytiky a plánování v řízení investic a údržby	134
11.6	Prediktivní analytika v plánování potřeby energií.....	134
11.6.1	Cílové proměnné v řízení energií	135
11.6.2	Funkce prediktivní analytiky a plánování v řízení energií	135
11.7	Řešení prediktivní analytiky v plánování investic, údržby a energií.....	135
12.	Analytika obchodních center	137

12.1	Deskriptivní analytika obchodního centra	137
12.1.1	Dimenze deskriptivní analytiky obchodního centra	138
12.1.2	Metriky pro deskriptivní analytiku obchodního centra	139
12.1.3	Funkce deskriptivní analytiky obchodního centra	140
12.2	Řešení deskriptivní analytiky obchodního centra	141
12.3	Prediktivní analytika v řízení obchodních center	142
12.3.1	Cílové proměnné v řízení obchodních center	143
12.3.2	Funkce prediktivní analytiky a plánování v řízení obchodních center	143
12.4	Řešení prediktivní analytiky a plánování obchodních center	143
Závěry k oddílu B: Analytika podle oblastí řízení retailové firmy		145
C.	Přílohy	146
1.	Strojové učení (Machine Learning)	146
1.1	Principy machine learning (ML)	146
1.2	Klasifikace ML podle řízení učení	147
1.2.1	Řízené učení („supervised learning“)	147
1.2.2	Neřízené učení („unsupervised learning“)	147
1.2.3	Semi-supervised learning	147
1.2.4	Self-supervised learning	148
1.2.5	Reinforcement learning	148
1.3	Dávkové a online učení	148
1.3.1	Dávkové učení („batch learning“)	148
1.3.2	Učení online („online learning“)	148
1.4	Učení založené na instancích nebo modelech („instance-based / model-based learning“)	148
1.4.1	Instance-based learning	148
1.4.2	Model-based learning	148
1.5	Faktory machine learning	148
1.5.1	Nedostatečné množství trénovacích dat	149
1.5.2	Nereprezentativní trénovací data	149
1.5.3	Špatná kvalita dat	149
1.5.4	Validace a ladění modelů	149
1.5.5	Vyhodnocení modelu	149
1.6	Využití machine learning	150
1.7	Prediktivní analytika a machine learning	150
2.	Příklad: Využití IoT pro chladicí zařízení v supermarketovém řetězci	151
2.1	Využití IoT v maloobchodním prodeji	151
2.2	Prediktivní model	151
2.2.1	TimeSeriesSplit	151
2.2.2	Referenční model	152
2.2.3	XGBoost	153
2.2.4	Dlouhodobý datový model	153
2.2.5	SHAP hodnoty	154
2.3	Predikce na 24 hodin	157
2.4	Interpretace	158
2.5	Vyhodnocení výsledků	158
Zdroje		159

Úvodní poznámky



Analytika retailové firmy tvoří dnes běžnou součást řízení těchto typů firem, a to nejen těch velkých. **Účelem** této publikace je specifikovat obsah, možnosti a přístupy k analytice retailové firmy se zaměřením zejména **na deskriptivní a prediktivní analytiku** s cílem poskytovat podklady manažerům a analytikům ke zkvalitňování řízení firmy a zajištění její dlouhodobé konkurenceschopnosti.

Struktura textu je rozdělena do několika základních oddílů, jak ukazuje úvodní schéma. Tato publikace je součástí **publikací řady „IT a anatomie firmy“** umístěných na portálu <https://mbi-af.cz>. Rozlišují se na **základní**, zobecněné, bez přímé vazby na některý sektor ekonomiky a **odvětvově** orientované. V současné době jsou obsahem portálu odvětvové publikace zaměřené na „*Strojírenskou firmu*“ a „*Samosprávu*“.

Záměrem celé řady je, aby odvětvově orientované publikace zahrnovaly pro každé odvětví minimálně jejich dva typy, a to **první** – publikaci zaměřenou na **obsah řízení a jeho základní komponenty**, jako např. [\[Strojírenská firma\]](#) a **druhou** – publikaci orientovanou na **analytiku firmy**, např. [\[Analytika strojírenství\]](#). Oba typy publikací se vždy na sebe váží a odkazují se sebe, stejně tak i na některé publikace základní. Totéž platí i pro texty věnované retailu.


Pro texty uvedené řady je charakteristické, že se zejména pro odvětvové publikace musí některé části zákonitě opakovat. Smyslem ale přitom je poskytnout pro každý odvětvový typ firmy, pokud možno komplexní obraz. Řešení je zde v tom, že u textů jako je tento, mají některé části pouze přehledový nebo rekapitulační charakter a pro další informace uvádíme odpovídající zdroje prezentované na portálu s přímým odkazem, jako např. [\[Podniková analytika\]](#). Jde o vybrané zdroje a proto Obrázek 0-1 dokumentuje vazby textu „*Analytika retailové firmy*“ pouze na ty hlavní na portále MBI-AF:



Obrázek 0-1: Vazby publikace "Analytika retailové firmy" na ostatní publikace

K uvedeným vazbám doplníme schémata publikací a **několik poznámek**:

IT a anatomie retailové firmy




Obrázek 0-2: Struktura publikace "Anatomie retailové firmy"

Anatomie retailové firmy představuje obsah řízení retailové firmy podle jednotlivých oblastí řízení a vymezení vybraných komponent řízení, na které se „Analytika“ odkazuje. Strukturu textu dokumentuje Obrázek 0-2. **Odkazy** jsou v tomto případě především **na obsah řízení**, resp. jednotlivých úloh, vymezení rolí v řízení v retailu, faktory ovlivňující řízení, a tedy i analytiku a IT aplikace jako zdroje dat pro analytiku.

IT a anatomie firmy (Oblasti a komponenty)


„*IT a anatomie firmy (Oblasti a komponenty řízení)*“ [[Oblasti a komponenty](#)], prezentuje obsah řízení firem obecně, bez ohledu na odvětví. Poskytuje pro analytiku retailu přehled a **vymezení převážně standardních metrik** a jejich dimenzí a datových zdrojů. Strukturu publikace ukazuje Obrázek 0-3.



Obrázek 0-3: Struktura publikace "IT a anatomie firmy (Oblasti a komponenty řízení)

IT a anatomie firmy (Podniková analytika)

„*IT a anatomie firmy (Podniková analytika)*“ [[Podniková analytika](#)] souhrnně prezentuje přístupy, metody, postupy a technologie uplatňované v řešení úloh podnikové analytiky, v tomto případě rovněž bez ohledu na odvětví. Strukturu dokumentuje Obrázek 0-4. V tomto případě se využívá **odkazů na** detailní charakteristiky analytických metod a postupů a charakteristiky zejména nástrojů pro podnikovou analytiku, jako business intelligence a dalších.



Obrázek 0-4: Struktura publikace "IT a anatomie firmy (Podniková analytika)"

Kompletní **přehled literatury** je uveden v závěru publikace. Vedle uvedených online textů vychází další text především z **těchto zdrojů**:

- ABBOTT, D.: **Applied Predictive Analytics. Principles and Techniques for the Professional Data Analyst**. John Wiley & Sons, Indianapolis, 2014. ISBN: 978-1-118-72796-6.
- BRAGG, S. M.: **Retail Management**. Accounting Tools, 2024. ISBN: 978-1-64221-241-9.
- CIMLER, P., ZADRAŽILOVÁ, D. a kol.: **Retail management**. Praha, Management Press, 2007. ISBN: 978-80-7261-167-6
- COX, E.: **Retail Analytics. The Secret Weapon**. John Wiley & Sons. 2012. ISBN: 978-1-118-09984-1
- GÉRON, A.: **Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow**. O'Reilly, 2023. ISBN: 978-1-098-12597-4.
- LEVY, M., GREWAL, D.: **Retailing Management**. McGraw Hill, 2023. ISBN: 978-1-265-07246-9.
- MITCHELL, D. K.: **Data-Driven Retail. Leveraging Analytics for Smarter Decisions**. North Haven, CT, 2025. ISBN: 9798286206964.
- TORRES, D.: **Business Analytics with Python. A Practical Guide for Data Analysts & Business Professionals**. Organica AI Solutions LLC, 2024. ISBN: 9798319482006.
- WILSON, J., E.: **Predictive Analytics for Business Forecasting and Planning**. Graceway Publishing Company, 2021. ISBN 978-0-9839413-8-5.

Poznámky k textu:

- V dalším průběhu textu je k jeho oživení a pro lepší představu témat použita řada **obrázků a fotografií**. Ty jsou buď vlastní nebo „online obrázky“ společnosti Microsoft pouze s licencí **Creative Commons**, tj. jsou využity pouze pro studijní nikoli komerční účely.
- Text publikace je provázán **odkazy na další publikace a pracovní dokumenty** na portále MBI-AF, stejně tak jsou použity **odkazy na jednotlivé části textu** v rámci dané publikace. Všechny přímé odkazy jsou uvedeny **v hranatých závorkách []**.
- V textu jsou použity termíny „**podnik**“ i „**firma**“ ve stejném nebo obdobném smyslu. Termín „**firma**“ pokládáme za základní, ale v mnohém kontextu je využití termínu „**podnik**“, „**podnikový**“ apod. přirozenější. Využíváme je tak podle obvyklých použití v praxi.
- Obdobně používáme podle kontextu termíny „**retailová firma**“ nebo „**maloobchodní firma**“, „**retail**“ nebo „**maloobchod**“.

Další kapitoly se i na základě uvedených zdrojů budou věnovat uplatnění analytiky v retailové firmě s hlavním **zaměřením na deskriptivní a prediktivní analytiku**.

A. Principy analytiky retailové firmy



[1] Analytika retailové firmy, celkový koncept

(Přehled a rekapitulace hlavních oblastí řízení retailové firmy, úrovně řešení analytiky v retailu, přístupy k řešení analytiky v retailové firmě.)

[2] Principy a komponenty deskriptivní analytiky

(Úlohy analytiky v retailu, podstata scénářů, resp. analytických otázek, přehled hlavních datových zdrojů, vymezení faktorů ovlivňujících deskriptivní analytiku, vymezení metrik a obsah analytických dimenzí, specifikace využívaných metod a postupů, vymezení aplikací a nástrojů deskriptivní analytiky v retailu.)

[3] Principy a komponenty prediktivní analytiky

(Úlohy plánování a prognóz, podstata scénářů, resp. analytických otázek, hlavní principy prediktivní analytiky, přehled hlavních datových zdrojů, vymezení faktorů ovlivňujících prediktivní analytiku, vymezení cílových proměnných a prediktorů, specifikace využívaných metod a metodik, vymezení aplikací a nástrojů prediktivní analytiky v retailu.)

1. Analytika retailové firmy, celkový koncept



Otázky podnikové analytiky představují velmi široký rozsah informací, přístupů, analytických úvah a nástrojů. **Účelem** této kapitoly je vymezit základní **podstatu analytiky** v retailové firmě zejména na základě jejích oblastí řízení, vymezení různých úrovní uplatňované analytiky a specifických přístupů k jejímu řešení a užití.

Podniková analytika představuje zastřešující pojem, případně i synonymum pro různé specifické, či dílčí disciplíny a pojetí jako je business analytika, datová analytika a další a s nimi spojené dnes již obvyklé nástroje a technologie, jako je business intelligence, competitive intelligence, nástroje prediktivní analytiky a další.

1.1 Přístupy k řešení analytiky v retailu

Na základě aktuální praxe i klíčových zdrojů (Mitchell, D. K., 2025, Bragg, S. M., 2024, Cox, E. 2012) jsou významné přístupy k analytice retailových firem formulovány v následujících bodech:


- Retailové firmy se v současné době pohybují **ve vysoce konkurenčním prostředí**, v prostředí velmi rychlých technologických změn. **Analytika tak zde má klíčový význam** pro podporu rozhodnutí jako např., jaké zboží objednávat a prodávat zákazníkům, jak udržovat, doplňovat a optimalizovat skladové zásoby, jak umisťovat zboží na prodejnách, jak nastavovat konkurenceschopné ceny, jak predikovat zákaznickou poptávku, jak identifikovat potřeby, přání a zvyklosti zákazníků, jak racionalizovat provoz prodejen a mnoho dalších.
- **Na rozdíl od transakčních úloh a aplikací** je při řešení analytiky nutné **respektovat tyto momenty**:
 - I když trh nabízí určité typové analytické aplikace, přesto převažující zaměření analytických aplikací je **v jejich individualizaci** podle potřeb uživatelů, především manažerů a marketingových, obchodních a dalších specialistů firmy. Tomu musí **odpovídat i způsob a forma poskytovaných informací**. Na druhé straně s rozvojem nových technologií se uplatnění analytiky postupně dostává i na nižší úrovně řízení retailových firem.
 - Právě individualizace řešení je i základem obvykle skloňovaného jejich efektu, tedy hlavní **přínos pro konkurenceschopnost firmy** a získávání konkurenčních výhod.
- Podstatný rozdíl transakčních aplikací a aplikací analytiky spočívá v tom, že zatímco **transakční aplikace obvykle datové zdroje** vytvářejí (např. na základě vstupních dokladů), pak **analytika tyto zdroje využívá** pro realizaci analýz, plánů, prognóz. Kromě toho analytika v retailu využívá i data přímo z technologií instalovaných na prodejnách (např. POS, IoT), z komunikace se zákazníky na eShopech, v CRM systémech nebo na sociálních sítích. Je tak zřejmé, že k dispozici se nabízejí obrovské objemy dat, které jsou v rámci analytiky systematicky získávány, integrovány a využívány pro posilování konkurenceschopnosti firmy.
- Analytika retailových firem zaznamenává **podstatné rozšíření** od úloh hodnotících aktuální stav (**deskriptivní analytika**) k úlohám podporujícím plánování a prognózování, tedy určující budoucí stav (**prediktivní analytika**), viz dále.
- Úlohy deskriptivní i prediktivní analytiky nacházejí významný prostor **v optimalizaci skladových zásob**, snižování nepřiměřeně vysokých zásob s rizikem výprodeje při výrazných slevách a na druhé straně nedostatečných zásob, a tedy nižšího objemu prodeje.
- Analytika v řídicí praxi retailových firem posiluje jejich výkonnost, agilitu a rychlost posuzování změn na trhu a **využívání nových obchodních příležitostí** ve vztahu ke konkurenci („competitive advantage“).
- **Při praktickém užití aplikací analytiky** manažeři a specialisté firmy pracují a vyhodnocují podnikové ukazatele podle různých dimenzí, v delším časovém vývoji, s predikcemi na delší časové horizonty, s identifikací problémů, které jsou jinak obtížně identifikovatelné. Z toho současně vyplývá, že **přístupy k řešení deskriptivní a prediktivní analytiky se podstatně liší**. Tento text se snaží právě tyto rozdíly objasnit.
- Při formulování, řešení i implementaci úloh deskriptivní i prediktivní analytiky je účelné **se dobře orientovat v principech**, na kterých jsou založeny, a rovněž **součástech nebo**

komponentách řízení (úloh, scénářů apod.), které jejich řešení tvoří, což je náplní dalších dvou kapitol tohoto oddílu A.

- Na druhé straně je kvalitní řešení analytiky závislé především na **pochopení podstaty a potřeb byznysu** podle jednotlivých oblastí řízení retailové firmy. Tomu jsou pak věnovány jednotlivé kapitoly celého oddílu B.

1.2 Oblasti řízení retailové firmy

Na tomto místě jako vstup pro další řešení analytiky rekapitulujeme základní oblasti řízení, které jsou detailněji charakterizovány v publikaci „*Anatomie retailové firmy*“. Celkovou strukturu řízení představuje Obrázek 1-1, s tím, že v této publikaci je uveden pod číslem 12 „*Controlling a řízení výzkumu*“, který zde neuvádíme, ale naopak je zde uvedena „*Analytika obchodních center*“, kapitola 11, které je v publikaci „*Anatomie...*“ věnován speciální oddíl.



Obrázek 1-1: Oblasti a komponenty řízení retailové firmy

Rekapitulace oblastí řízení retailové firmy je v následujícím přehledu:

- **Strategické řízení firmy** – strategické analýzy, formulace strategie, vytvoření byznys modelu, řízení inovací atd.
- **Finanční řízení retailové firmy** – účetní evidence, finanční transakce, finanční reporting, finanční analýzy, plánování, zpracování rozpočtů. Zahrnuje také:
 - **Řízení závazků** – evidence závazků a jejich zpracování, reporting závazků, analýzy závazků.
 - **Řízení pohledávek** – evidence pohledávek a jejich zpracování, reporting pohledávek, analýzy pohledávek.
- **Personální řízení a řízení mezd** – personální evidence, řízení personálu, přijímání a propouštění zaměstnanců, řízení kvalifikačního rozvoje, evidence mzdových složek, evidence a zpracování mezd, personální a mzdový reporting, analýzy a plánování mezd.
- **Řízení marketingu** – evidence, příprava a řízení marketingových akcí, marketingové analýzy, plánování marketingových akcí.

- **Řízení vztahů k zákazníkům** – vytváření zákaznické databáze, operativní aktivity ve vztahu k zákazníkům.
- **Řízení nákupu zboží a služeb** – evidence a řízení obchodních operací spojených s nákupem zboží a souvisejících služeb, reporting nákupů, analýzy nákupů, specifikace potřeb a plánování nákupů.
- **Řízení skladů** – evidence skladů a skladových zásob, řízení skladových transakcí, reporting zásob (regleta a další), analýzy zásob.
- **Řízení prodeje zboží a služeb** – evidence a řízení obchodních operací prodeje, řízení poprodejního servisu, reklamací, reporting prodeje, prodejní analýzy, plánování a prognózování prodeje.
- **Řízení logistiky** – evidence logistiky, dopravy a dopravních prostředků, řízení požadavků na logistiku a jejich zajištění, reporting logistiky, analýzy, plánování dopravních kapacit.
- **Tvorba cen** – průzkumy cenové úrovně na trhu, strategie tvorby cen, vytváření ceníků zboží a služeb.
- **Řízení majetku, investic, údržby a energií** – evidence majetku, řízení majetkových transakcí, řízení odpisů, reporting majetku, analýzy majetku, plánování rozvoje majetku a investic, řízení spotřeby energií, analýzy energií, plánování potřeby energií.
- **Controlling a rozvoj firmy** – kalkulace a analýzy na bázi controllingu, zpracování controllingových plánů, organizační a technický rozvoj firmy, řízení firemního výzkumu.

1.3 Úrovně řešení analytiky

Další podkapitoly podávají stručnou charakteristiku jednotlivých úrovní analytiky tak, jak je vymezila společnost Gartner:

Deskriptivní analytika (*Descriptive analytics*) je proces **shromažďování a interpretací dat** k popisu **událostí, které v řízení firmy nastaly**, a to jak v ekonomice nebo obchodu. Naprostá **většina reportů** v praxi se vztahuje **k minulosti**, které se pokouší objasnit minulé události a aktivity a popsat, jak se liší jedna od druhé, např. v analýzách prodeje, problémů v řízení vztahů k zákazníkům, dosažených ekonomických a obchodních výsledků apod.

Diagnostická analytika (*Diagnostic analytics*) je proces shromažďování a interpretace dat. **Identifikuje anomálie, detekuje vzory událostí a určuje souvislosti**, které se v rámci nastalých událostí objevily.


Prediktivní analytika (*Predictive analytics*) představuje typ analýzy **využívající data a prediktivní modely pro předpověď jevů** na mikroekonomické úrovni. Učí se ze zkušeností a dat a předvídá budoucí chování jedinců, zahrnuje v sobě množství statistických a analytických technik. Sleduje a predikuje takové hodnoty, které jsou dosud neznámé, ale mimořádně užitečné, např. ukazatele vývoje prodeje zboží a služeb, možností nákupu apod.

Preskriptivní analytika (*Prescriptive analytics*) se zabývá tím, **co je třeba v budoucnosti dělat**. Vychází tedy z předchozích kroků, tedy zejména **z deskriptivní analytiky a prediktivní analytiky**. Závěry vytvořené v prediktivní analytice, tedy to, co se stane, jsou doplněny o to, co s tím můžeme udělat.




Jak jsme již uvedli, tak tento text se bude **primárně zabývat deskriptivní a prediktivní analytikou**, což koresponduje i s naprostou většinou publikací na našem i světovém trhu.

1.4 Závěry



Z kapitoly vyplývají následující **závěry**:

- S rozvojem informačních technologií se uplatnění analytiky dostává nejen do **vyšších úrovní managementu** retailových firem, ale postupně **i na nižší úrovně** jejich řízení a z toho vyplývají i podstatně širší požadavky na kvalifikační přípravu



uživatelů.

- **Potřebu** analytiky ovlivňuje celá škála faktorů, k nimž se dostaneme v dalším textu.
- Analytiku, a stejně tak analytiku v retailu je třeba vidět **na různých úrovních řešení** jejich komplexnosti a se zaměřením **na minulost nebo budoucnost**. Takové rozlišení nabízí klasifikace společnosti Gartner zahrnující **deskriptivní, diagnostickou, prediktivní a preskriptivní analytiku**.

2. Principy a komponenty deskriptivní analytiky



Účelem kapitoly je uvést **principy deskriptivní analytiky** s vymezením podstaty a obsahu jednotlivých komponent řízení, které jsou součástí řešení projektů v této oblasti.

2.1 Analytické úlohy

Analytické úlohy jsou **součástí prakticky každé oblasti řízení**. Pracovně lze přijmout následující **rozlišení** analytických úloh:

- Analýzy **ekonomických a obchodních ukazatelů** podle zvolených dimenzí, jako např. objem tržeb za zboží a služby, objem mezd, objem odpisů z majetku apod.
- Analýzy **výkonových ukazatelů**, resp. ukazatelů **procesního charakteru** podle zvolených dimenzí, jako např. počet přijatých objednávek, počet vydaných faktur, počet servisních úkonů apod.
- Analýzy ukazatelů **organizačního charakteru** podle zvolených dimenzí, jako např. počet zákazníků, počet nových zákazníků, počet dodavatelů apod.
- Analýzy **trendů, resp. časového vývoje** vybraných ukazatelů podle časové a dalších dimenzí (tzv. „**time intelligence**“), např. podle jednotlivých let, čtvrtletí, měsíců, zahrnuje sledování hodnot ukazatelů k počátečnímu datu, např. začátku roku, meziroční srovnání nebo srovnání mezi odpovídajícími obdobími, výpočty a sledování různých typů indexů, např. řetězových nebo bazických (předpokladem je zde však dostupnost dat za delší časová období).
- **Srovnávací analýzy** ukazatelů podle dimenzí, např. porovnávání plánovaných hodnot se skutečnými, případně podle variant plánů, porovnání dosažených obchodních výsledků podle vybraných regionů, druhů zboží, skupin zákazníků apod.
- Zpracování **pořadí určitých objektů** podle zvolených hodnot ukazatelů („**ranking**“), např. zákazníků podle objemu tržeb, dodavatelů podle objemu dodávek, reklamací podle jejich počtu nebo objemů apod.



Tyto typy analytických úloh jsou i základem **vymezení analytické funkcionality** v rámci jednotlivých oblastí řízení a příslušných kapitol uvedených v oddíle [B].

2.2 Scénáře, analytické otázky

Scénář je chápán jako sada **analytických otázek** ve vztahu k požadavkům nebo problémům retailové firmy a jejích pracovníků. Smyslem je nabídnout **možnost kvalitnější přípravy** analytika na diskuse s manažery a specialisty firmy při formulování obsahu analytických úloh. S tím souvisí i hledání jejich adekvátních řešení, respektive případná doporučení.

Některé z analytických otázek mají **obdobné zaměření** a pouze se modifikují podle obsahu dané oblasti řízení, jiné jsou pro danou oblast zcela **specifické**. **Další přehled** obsahuje zmíněné **standardní otázky** rozdělené pracovně na skupinu „Vztahu k byznysu“ a „Obsahu a kvality analýz“.

Otázky vztahu úloh deskriptivní analytiky k byznysu:

- Jak zvýšit **úspěšnost a výkonnost** retailové firmy uplatněním kvalitních byznys analýz?
- Provádí se **vyhodnocení ekonomiky** útvarů, případně prodejen pravidelně?
- Jsou nastavena **kritéria pro vyhodnocení** obchodních činností a výkonnosti obchodních útvarů a pracovníků?
- Dochází k hlubší **analýze dosahovaných parametrů** zboží a služeb a dalších aspektů?
- Jak zajistit potřebnou požadovanou **komplexnost a kvalitu** analýz ekonomiky a obchodu vzhledem k potřebám jednotlivých manažerů retailové firmy a jejích útvarů?
- Jak dosáhnout potřebné **kvalifikace a motivace** manažerů a specialistů firmy pro řešení úloh deskriptivní analytiky?

- Jak dosáhnout **konsensu mezi pracovníky** firmy a jednotlivých útvarů na navrženém obsahu a strukturách úloh deskriptivní analytiky?
- Jak posilovat **samostatnost pracovníků** při řešení úloh analytiky a využívání analytických nástrojů?
- Jak správně stanovit **perspektivu datových zdrojů** a klíčových aplikací z pohledu dalšího řešení a nasazení analytických úloh?
- Jak dosahovat **zkracování doby a časové náročnosti** na přípravu úloh deskriptivní analytiky?
- Jak racionálně určovat **očekávané efekty** uplatnění úloh deskriptivní analytiky?

Otázky k obsahu a kvalitě úloh deskriptivní analytiky:

- Které **reporty** a s jakým obsahem budou adekvátní jednotlivým úrovním a pozicím řízení?
- Které **metriky** budou pro úlohy deskriptivní analytiky významné, které budou mít charakter KPI?
- Které **dimenze** ve vztahu k metrikám budou při návrhu úloh relevantní?
- Jak správně nastavit **analytická pravidla** ve vztahu k ukazatelům pro generování varovných zpráv (*alertů*)?
- Jak dosáhnout požadované **flexibility analýz** vzhledem k momentálním potřebám manažerů a specialistů v různých oblastech řízení retailu?
- Jak dosáhnout požadovanou **granularitu dat** v rámci jednotlivých operací při realizovaných analýzách? Jak k tomu zajistit **potřebné datové zdroje** na požadované úrovni granularity?
- Jak zajistit vysokou **prezentační úroveň** výsledků řešení analýz?



Tento základ je v rámci jednotlivých oblastí řízení v oddíle [B] **doplněn a modifikován** ve vztahu k retailu **o další analytické otázky**.

2.3 Role

Role určují, jaké **funkce** bude mít pracovník v řešení problémů a úloh, v daném případě při řešení úloh deskriptivní analytiky. **Smyslem rolí** je přesněji vyjádřit, jak jsou, nebo mají být, úlohy analytiky personálně zajištěny, resp. jaká je personální náročnost realizace jednotlivých úloh. V každé pracovní pozici může pracovník **vykonávat řadu různých rolí**. Rolím jsou **přirazovány pracovní činnosti a zodpovědnosti** ve firmě.

Komplex rolí v retailové firmě je vymezen v publikaci „Anatomie retailové firmy“ v kapitole 2. Pro **řešení analytiky** retailové firmy je nezbytné vymezit i následující role:

2.3.1 Architekt podnikové analytiky

Architekt podnikové analytiky je specialistou v oblasti celkového návrhu aplikací a návrhu IT infrastruktury pro analytiku retailové firmy. Analyzuje a navrhuje vhodnou aplikační a technologickou architekturu celé podnikové analytiky firmy. Přípravuje podklady pro konfigurování hardware a software. Monitoruje a řeší problémy s optimalizací výkonu aplikací. Realizuje **tyto činnosti**:

- řeší **datovou a technologickou architekturu**,
- určuje **umístění datového skladu na servery**, umístění jednotlivých datových tržišť, technická řešení OLAP databází,
- zajišťuje výběr a realizaci **produktů pro klientské aplikace**, využití portálů pro reportování z aplikací,
- analyzuje současný **stav infrastruktury vzhledem k aktuálním uživatelským požadavkům**,
- analyzuje **stav datových zdrojů** a jejich technickou dostupnost,
- zpracovává návrh **technologické infrastruktury s respektováním požadavků** na její výkon včetně špičkových zatížení, bezpečnost provozu, flexibilitu, možnosti škálování i pracovní náročnost obsluhy.

2.3.2 Byznys analytik

Byznys analytik řeší obsahovou a logickou stránku jednotlivých úloh a přípravu analytických a plánovacích aplikací v rámci projektů podnikové analytiky. Podle povahy projektu zajišťuje podle jednotlivých úloh a fází řešení projektů např. tyto **činnosti**:

- **konzultuje s uživateli** jejich problémy a požadavky na analytické a plánovací aplikace,
- posuzuje **kvalitu zdrojových databází**,
- specifikuje rámcový **obsah a strukturu hlavních reportů**, ukazatelů a jim odpovídajících dimenzí,
- definuje základní **funkcionalitu** analytických a plánovacích aplikací,
- řeší **celkovou koncepci transformací dat** (ETL / ELT apod.),
- zajišťuje **analýzu současného stavu řešení** a disponibilních zdrojových databází a aplikací,
- kooperuje na **analýzách požadavků** uživatelů a na jejich konsolidaci,
- navrhuje a projednává s uživateli **hrubý dimenzionální model** řešení,
- navrhuje **datový model datového skladu i datových tržišť**,
- navrhuje strukturu a způsob **využití OLAP databází**,
- řeší **analytické otázky transformací dat**, tj. vlastní transformace dat, granularitu transformovaných dat a další,
- **navrhuje kontrolní a opravné procedury** v souvislosti s čištěním, resp. zajištěním kvality dat,
- navrhuje způsob **aktualizace při změnách dimenzí**,
- kooperuje na **přípravě datové základny** pro zahájení provozu aplikací,
- podílí se na **řešení analytických problémů nebo chyb** vyplývajících s přípravou provozu.

2.3.3 Datový analytik


Datový analytik zajišťuje zejména správné **mapování dat ze zdrojových systémů do cílového systému**, konzistenci dat apod. Zajišťuje podle jednotlivých úloh řešení projektů tyto **činnosti**:

- zajišťuje **analýzu datových struktur zdrojových systémů**, jejich kvalitu a dostupnost,
- spolupracuje s architektem podnikové analytiky na návrhu **datové architektury**,
- spolupracuje na **vyhodnocení stavu a kvality dat** na formulaci principů řízení jejich kvality,
- konzultuje a posuzuje možné **varianty přístupů k řešení** projektů z pohledu datové architektury,
- definuje **datové struktury cílového systému**, tj. datového skladu, datových tržišť a dalších,
- spolupracuje na **specifikaci nástrojů pro transformace dat**,
- spolupracuje s byznys analytiky na **určení oblastí**, jež budou v rámci datových transformací **prioritní**,
- definuje **tabulky nutné pro plnění cílové databáze**, např. datového skladu a tržišť, které se nenacházejí ve zdrojových systémech,
- definuje **detailní pravidla a procedury transformací dat**, popis transformací polí mezi zdrojovými a cílovým systémem (datové typy, délka polí, plnění konstantami),
- spolupracuje na **implementaci databázových schémat** a transformačních procedur,
- spolupracuje na **vytváření prvotních databází** datového skladu a datových tržišť.

2.4 Data, datové zdroje

Daty, datovými zdroji nebo dokumenty se v anatomii firmy rozumí jakákoli datová struktura, která zde představuje podstatný **vstup do analytické úlohy**. Základní klasifikaci datových zdrojů nabízí publikace

[[Oblasti a komponenty](#)] v kapitole 5. Datové zdroje jsou zde členěné podle různých hledisek, v našem případě je budeme sledovat podle technologické realizace, zejména podle typů aplikací, které je vytvářejí. To dokumentuje Obrázek 2-1:



Obrázek 2-1: Primární datové zdroje pro deskriptivní analytiku v retailu

Na tomto místě doplníme několik poznámek podle (Mitchel, 2025, upraveno):

- **ERP** (*Enterprise Resource Planning*) – celopodniková transakční aplikace, většinou s centralizovanými databázemi pokrývajícími funkce téměř všech oblastí řízení retailové firmy.
- **WMS** (*Warehouse Management System*) – pro komplexní řešení řízení skladového hospodářství, poskytuje data a skladech a jejich kapacitách, skladových zásobách, operacích další.
- **SCM** (*Supply Chain Management*) – v případech, že se na dodávce konečnému zákazníkovi podílí více podniků nebo jednotek jednoho podniku a tyto podniky nebo jednotky utvářejí tzv. dodavatelský řetězec. SCM nabízí informace o celém dodavatelském řetězci, jeho fázích a jednotlivých dodávkách.
- **TMS** (*Transportation Management Systém*), případně *Spediční systém* – specializovaný systém pro řízení dopravy a optimalizaci dopravních tras.
- **CRM** (*Customer Relationship Management*) – nabízí podrobná data o zákaznících, informace o požadavcích a problémech zákazníků, demografická data, data pro marketing.
- **SRM** (*Supplier Relationship Management*) – je základem efektivního řízení retailové firmy se zaměřením na dodavatele, jejich profily, hodnocení, dodávky zboží.
- **eByznys** – poskytuje data z několika typů systémů, zejména eCommerce, resp. eShop, převážně data a prodejích koncovým zákazníkům, eProcurement, resp. elektronické zásobování pro výměny dokumentů s partnery, zejména dodavateli, VMI (Vendor Manage Inventory), resp. dodavatelem řízené zásobování.
- **POS** (*Pont of Sale*) – kontrolní pokladny na prodejnách poskytují okamžitá data o uskutečněných nákupech, platbách, data o dané prodejně a další.
- **Webová analytika** (*Web Analytics*) – pod touto položkou se rozumí poskytování dat na základě nástrojů webové analytiky, data, která může retailová firma čerpat ze sociálních sítí a další.

- **IoT (Internet of Things)** – jsou nejrůznější technologie poskytující obrovské množství dat na základě různých senzorů na regálech, instalované kamery sledující pohyby zákazníků po prodejně, z nichž lze pak usuzovat na různé nákupní zájmy a zvyky, RFID pro identifikaci zásob zboží a jejich další manipulace apod.

Alespoň **hlavní datové zdroje** pro analytické úlohy jsou **podle využití v oblastech řízení** uvedeny v oddíle [B].

2.5 Faktory ovlivňující deskriptivní analytiku v retailu

Faktor představuje v anatomii firmy **souhrnné vyjádření pro organizační, technické a další podmínky** řešení jednotlivých úloh, problémů a projektů. Účelem faktorů je vymezit pro jednotlivé úlohy **byznys i technické prostředí**, které řešení úloh výrazněji ovlivňuje a co je tedy účelné nebo dokonce nezbytné brát v úvahu.

Faktory mohou být vnější nebo vnitřní. K vnějším faktorům lze zařadit ty, které lze pojmenovat akronymem PESTEL (politické, ekonomické, sociální, technologické, environmentální a legislativní), ale také např. to, zda firma je nebo není součástí dodavatelského řetězce. K vnitřním faktorům lze zařadit např. právní formu, způsob dosahování souladu byznysu s informatikou („*Business – IT – Alignment*“), firemní kulturu apod.

Přehled a vymezení obsahu faktorů vzhledem k řízení retailové firmy je v publikaci „*Anatomie retailové firmy*“ v oddíle C.

Ve vztahu k analytice v retailu je dobré zdůraznit zejména **faktory**, jak jsou zmíněny v publikaci [Podniková analytika]:

- Pro analytické aplikace jsou charakteristické **velmi těsné vazby na ostatní aplikace** podnikové informatiky. Jejich úspěch závisí proto i **na kvalitě podnikové a aplikační architektury**, úrovni zajištění integrace podnikové informatiky, kvalitním plánování a zadávání nových projektů.
- Analytika retailové firmy je postavena na **využití datových zdrojů** vznikajících převážně **v transakčních aplikacích**. Je nutné řešit celý **komplex otázek zajištění kvality dat**, což není záležitostí pouze projektů analytiky, ale procesů řízení celé podnikové informatiky. S jejich nízkou kvalitou klesá kvalita nebo úplně zaniká řešení podnikové analytiky.
- Pro kvalitní a systematické řízení rozvoje podnikové analytiky je předpokladem i **systematické a kvalitní řízení datových zdrojů**, v současné době obvykle založené **na principech Data Governance**.
- S předchozí poznámkou souvisí **řízení změn** v IT aplikacích. Pokud není zajištěno **efektivní a včasné předávání informací** o změnách v primárních aplikacích správcům analytických aplikací dochází **k chybám ve vstupních datových strukturách**, v ETL, resp. transformačních procedurách, načítání chybných dat a následně k chybám ve výstupních reportech a dashboardech.
- Úspěch podnikové analytiky ovlivňuje i **úroveň řízení provozu** celé informatiky, zejména správa databázových serverů, řízení provozu datových skladů, plánování a kontrola průběhu ETL procesů, zařazení problematiky analytiky do služeb help-desku atd.
- Pravidlo **silného sponzora** je v oblasti podnikové analytiky již všeobecně známé. S ohledem na konečný úspěch by tyto projekty (BI a další) měly být uvnitř firmy vždy podporovány **osobností se značnou mírou vlivu a s nezbytnými rozhodovacími pravomocemi**. Jde o osobnost, která navíc vedle svého vlivu a prezentovaného zájmu o řešení, je schopna vidět podnik a jeho aktivity ve všech podstatných souvislostech, ve vztahu k podnikovému okolí, je schopna formulovat a rozhodovat o klíčových prioritách řešení a samozřejmě je schopna řešit finanční zajištění projektu a dalšího provozu.
- Strategické otázky řešení podnikové analytiky se promítají na nejvyšší úrovni **do informační strategie** firmy jako celku a na nižší úrovni do strategie analytických projektů. Při převládajícím **značném rozsahu** těchto projektů, jejich **finanční a časové náročnosti**, mimořádně rychlém **rozvoji technologií**, na nichž jsou založeny, je určení správné strategie odpovídající potřebám a možnostem firmy **velmi podstatným faktorem** řešení. Stanovení strategie by tak mělo zohlednit i vyhodnocení všech dílčích faktorů, a to zejména:

- určení **rozsahu** projektu a jeho **priorit** ve vztahu k podnikovým procesům, resp. oblastem řízení firmy,
 - určení **přístupu** k řešení projektu a s tím související i zapojení adekvátních pracovníků do celého projektu,
 - zaměření řešení na určitý **typ produktu a produkt**,
 - určení rozsahu **outsourcingu** v implementaci a provozu analytických řešení, určení podílu vlastních řešitelských kapacit a **způsobu výběru** dodavatelské společnosti.
- K tomu, aby **potřeba aplikací** analytiky byla kvalifikovaně posuzována, je nezbytné **formulovat jejich potenciální efekty** s ohledem na danou situaci firmy. Určování a **posuzování efektů** analytiky je v porovnání s ostatními typy aplikací poněkud **specifické**, obvykle se dostávají s delším časovým horizontem. V každém případě je vymezení očekávaných efektů a sledování jejich naplnění podstatné s ohledem na to, že analytické přípravě a využití těchto aplikací musí **věnovat čas na uživatelské straně manažeři** a podnikoví specialisté, jejichž časové možnosti jsou vesměs omezené. Musí proto, pokud možno, přesně vědět, co jim takto vynaložená časová i finanční investice přinese.
 - Na druhé straně však efekty podnikové analytiky **nemusí** být vždy zcela **přesně kvantifikovatelné**, resp. ve finančním vyjádření. Často se v těchto případech jedná o **kvalitativní efekty** znamenající dosažení vyšší konkurenceschopnosti firmy, získání lepší pozice na trhu, poskytování kvalitnějších informačních služeb obchodním partnerům atd. Je dobré si v tomto kontextu i položit **otázku „jaký bude mít dopad na firmu situace, kdy nebude investovat do podnikové analytiky, zatímco konkurence ano?“**.
 - Navíc má dosažení těchto efektů **delší časový horizont** způsobený potřebnou dobou na vytvoření a naplnění datového skladu, vytvoření časových řad sledovaných ukazatelů, osvojení si náročnějších analytických aplikací uživateli apod.
 - Úspěch řešení podnikové analytiky je silně **závislý na efektivní kooperaci dodavatelů a uživatelů** především v analytické fázi řešení. Průzkumy v české i zahraniční praxi však mnohokrát ukázaly, že právě **nedostatečná kooperace** a komunikace mezi byznysem a IT specialisty je zde překážkou kvalitnějších výsledků. Jednou z cest je **vytvoření kompetenčních center** pro podnikovou analytiku, které byly i v praxi mnohokrát ověřeny. Jejich **podstatou** je to, že formálně organizačně a systematicky **sdrůžují pracovníky uživatelských a IT útvarů**, kde se společně řeší klíčové problémy a úlohy projektů podnikové analytiky. Jsou postaveny na jasně definované organizaci, pracovních procedurách, dokumentačních a dalších standardech.
 - Cloud computing v podnikové analytice nabízí možnost **soustředit se více na předmět podnikání** a analýzy z byznysového hlediska než na správu IT infrastruktury. **Cloud computing** lze zde vymezit jako **model, ve kterém je alespoň některá komponenta podnikové analytiky umístěna v cloudovém prostředí** (tj. mimo infrastrukturu firmy). Komponenty, které se obvykle umísťují do cloudového prostředí jsou ETL/ELT řešení, datový sklad a reportingové, analytické a další vizualizační nástroje.

Faktory **podle oblastí řízení** v oddíle [B] **neuvádíme**, protože zde mají více méně obdobný charakter a omezíme se pouze na výše zařazený přehled.

2.6 Metriky

Analytika retailové firmy je založená na celé soustavě metrik, resp. ukazatelů. S ohledem na jejich značné množství, jsou do textu vybrány pro každou oblast řízení pouze ty obvykle nejpoužívanější. **Z hlediska obsahu metrik** je účelné v analytice podle jednotlivých oblastech řízení sledovat zejména:

- metriky **finančního, resp. ekonomického** charakteru (objem výnosů, nákladů, příjmy, výdaje, objem majetku, objem odpisů, objem reklamací apod.),
- metriky **výkonového, nebo procesního** charakteru (počet daňových dokladů, počet prodejních nebo nákupních transakcí, počet vyřízených reklamací, počet realizovaných školení apod.),
- metriky **organizačního charakteru** (počet pracovníků, útvarů, počet zákazníků, dodavatelů apod.).

Detailnější vymezení metrik je rozsahem značně náročné. Proto v rámci jednotlivých oblastí řízení v oddíle [B] uvádíme pouze jejich přehled a **pro detailnější informace odkazujeme** na publikaci [Oblasti a

[komponenty](#)] a její příslušné kapitoly nebo podkapitoly. Pouze metriky významně vázané na retail uvádíme v širším rozsahu.

2.7 Analytické dimenze

Dimenzí se rozumí **analytické hledisko** pro identifikaci a hodnocení sledovaných metrik, resp. ukazatelů a je tak součástí de facto každé metriky. Má obvykle **hierarchickou strukturu prvků**. **Smyslem dimenzí** je v kombinaci s metrikami vytvořit **základnu pro komplexnější analýzy a plánování** firmy.

Dimenze jsou podle souvislostí rozděleny do skupin, kde každá jejich skupina má pro rychlou orientaci svou zvláštní ikonu. **Souhrnný přehled dimenzí** pro analytika retailové firmy s ikonami prezentuje další **tabulka** s tím, že jde o vstupní náměty, které analytik musí doplnit a modifikovat podle konkrétních podmínek dané retailové firmy.

	Základní dimenze:
	Čas – časová dimenze představuje de facto podnikový kalendář. Slouží pro sledování vývoje jednotlivých ukazatelů. Prvky dimenze jsou dány běžným kalendářem v definovaném datovém intervalu ve tvaru rrrmmdd, např. 20251001 – 20261231. Je nezbytné nadefinovat dostatečný časový rozsah dimenze, aby pokryla jak události v čase zpět, tak události v budoucnosti. Prvky dimenze mohou být v jednotlivých úlohách prezentovány v různých hierarchických strukturách, a to většinou: ▪ Rok – Pololetí – Kvartál – Měsíc – Týden – Den. ▪ Rok – Měsíc – Den. ▪ Rok – Kvartál – Měsíc apod.
	Regiony – zahrnuje základní strukturu regionů, kde firma má obchodní aktivity, případně vlastní prodejny, pobočky, sklady apod. Základní struktura může být: kontinent – stát – region – případně místa.
	Podniková organizace:
	Podnikové procesy – zdrojem je dokumentace podnikových procesů. Slouží pro analýzy obsahu a objemu práce spojené s jednotlivými procesy a jejich časové a finanční náročnosti. Jedním z podstatných atributů dimenze procesy je určení, zda jde o proces hlavní, podpůrný nebo řídicí.
	Činnosti – představují jednotlivé vybrané dílčí činnosti uskutečňované v rámci obchodních a dalších aktivit retailové firmy, které jsou základem pro analýzy nákladů nebo pracnosti.
	Podnikové útvary – vychází ze standardní organizační struktury a účelem je hodnotit ekonomické a obchodní výsledky útvarů retailové firmy. V praxi je třeba uvažovat i paralelní organizační struktury (realizované na jedné dimenzi), jako např. maticové, projektové apod.
	Střediska – je společné vyjádření dimenze pro hospodářská, nákladová, resp. zisková střediska firmy a slouží pro hodnocení jejich ekonomických a obchodních výsledků.
	Ekonomické dimenze:
	Finanční ústavy – pro analýzy stavů a pohybů finančních zdrojů, kterými firma disponuje v jednotlivých finančních ústavech. Dimenze finančních ústavů zahrnuje banky a pojišťovny, případně

	specifické společnosti působící na finančních trzích a slouží pro analýzy objemu předávaných dat, objemu finančních prostředků, např. úvěrů.
	Měny – struktura využívaných měn, pokud je pro danou firmu významná. Zahrnuje kursy a vychází obvykle z kursovního lístku ČNB.
	Nákladové druhy – standardní struktura nákladů vynaložených v souvislosti s realizací obchodních aktivit. Struktura dimenze je obvykle tato: ▪ Spotřeba materiálu, energie a externích služeb. ▪ Mzdové a ostatní osobní náklady (platy, odměny, provize, náklady na sociální zabezpečení). ▪ Odpisy hmotného i nehmotného dlouhodobého majetku. ▪ Finanční náklady (nákladové úroky).
	Účetní období – je nepřetržitě po sobě jdoucích dvanáct měsíců, není-li stanoveno jinak a slouží pro analýzy vývoje nákladů a výnosů a jejich porovnání.
	Účetní osnova – je struktura účtů hlavní knihy a analytického účetnictví.
	Externí partneři:
	Dodavatelé – představují všechny dodavatele zboží a služeb, režijního materiálu apod. Strukturalizaci dodavatelské dimenze lze řešit podle různých hledisek, tedy podle významu dodavatelů, jejich velikosti, podle odvětvové orientace apod.
	Zákazníci firmy – struktura zákazníků firmy z pohledu poskytovaných zboží i služeb. Strukturalizaci zákaznické dimenze lze realizovat podle různých hledisek, např. podle významu zákazníků, jejich velikosti, podle odvětvové orientace, podle lokality apod.
	Poskytovatelé školicích, logistických a dalších služeb – nabízející školení, konzultace a celé rekvalifikační programy v řízení ekonomiky a obchodu i IT.
	Konkurence – představuje strukturu hlavních konkurentů retailové firmy, které je účelné sledovat z pohledu poskytovaných produktů a služeb zákazníkům a získávaných konkurenčních výhod.
	Lidské zdroje:
	Zaměstnanci – zahrnuje všechny pracovníky, resp. zaměstnance firmy. Základní struktura dimenze má obvykle dvě úrovně, a to profesní kategorie a zaměstnanci. Úroveň profesních skupin je založena na katalogu profesí dané retailové firmy.
	Kvalifikační struktura – zahrnuje všechny kvalifikační stupně a základní typy škol a vzdělávacích institucí.
	Mzdové složky – představuje vnitřní strukturu mezd a slouží pro analýzy mezd a mzdového vývoje podle jednotlivých definovaných složek. Mzdy zahrnují jednak pevnou složku (paušální objem mzdy) a pohyblivou složku (příplatky, osobní ohodnocení, prémie atd.).
	Věková struktura – rozdělení zaměstnanců podle věkových skupin. Dimenze obvykle nemá hierarchickou strukturu, představuje věkové intervaly, např. 18 – 25, 26 – 35 apod.
	Vzdělávání – představuje strukturu kvalifikačních a rekvalifikačních programů, odborných školení a kursů.

	Obchodní dimenze:
	Platební podmínky – představují definované způsoby a termíny plateb (úvěrování zákazníka), např. bankovní převod, dokumentární platby (typické při placení do zahraničí, ale i při placení uvnitř země).
	Dodací podmínky – mezinárodní podmínky platné pro přepravu zboží – Incoterms (International Commercial Terms). Upravuje platby za dopravu, rizika a povinnosti mezi dopravcem, kupujícím a prodávajícím. Dodací podmínky určují, do jakého okamžiku (místa) nese rizika a náklady na dodání zboží prodávající, a kde tato rizika a náklady přecházejí na kupujícího. Neupravují okamžik přechodu vlastnictví, který je spíše spojen s platebními podmínkami nebo jiným smluvním ujednáním. Tyto standardní podmínky se tradičně dělí na univerzálně použitelné (bez ohledu na druh dopravy) a na specifické podmínky pro lodní přepravu. Proávající s kupujícím si samozřejmě mohou dohodnout jakékoli dodací podmínky, pro zjednodušení však byly vytvořeny standardy, které mají jednotný výklad a nevyžadují proto obsáhlé smluvní úpravy. Stačí, že obchodní partneři uvedou ve smlouvě či objednávce mezinárodně používanou zkratku dodací podmínky a upřesní místo dodání, a obě strany mají jasno, kam má být zboží dodáno, kdo zajistí dopravu, kdo nese náklady na dopravné anebo pojistné, případně kdo uhradí případné škody vzniklé během přepravy.
	Segmenty trhu – dimenze obsahuje přehled segmentů trhu, na nichž podnik působí. Vymezení segmentů trhu se realizuje na základě segmentačních kritérií, tj. charakteristik daného trhu, případně segmentu. Mezi nejvýznamnější kritéria patří (zdroj Wikipedia): ▪ Geografická kritéria – světová oblast, stát, nižší teritoriální oblast, velikost oblasti, velikost města podle obyvatel, typ osídlení a jeho charakter, podnebí oblasti, ráz krajiny, morfologie. ▪ Demografická kritéria – věk, pohlaví, velikost rodiny, rodinný stav. ▪ Socioekonomická kritéria – příjem rodiny, povolání, vzdělání. ▪ Etnografická kritéria – náboženství, rasa, národnost. ▪ Fyziografická kritéria – kvantitativní charakteristiky, kvalitativní charakteristiky. ▪ Behaviorální kritéria – postoje ke zboží, věrnost značce, míra užívání, frekvence nákupu, uživatelský status. ▪ Sociopsychologická kritéria – sociální třída, životní styl, osobnost.
	Obchodní dokumenty – typy obchodních dokumentů realizovaných ve vztahu k řízení marketingu, nákupů, prodeje, skladů, dopravy. Dimenze, které se váží k dokumentům firmy jsou obvykle pojaty jako degenerované, tj. bez dimenzionální tabulky. Využívá se např. pouze číslo faktury v rámci tabulek faktů. Sem spadají např.: ▪ Nákupní objednávky. ▪ Dodací listy přijaté. ▪ Dodací listy vydané. ▪ Faktury přijaté. ▪ Faktury vydané. ▪ Dobropisy. ▪ Příjemky. ▪ Výdejky. ▪ a další.
	Obchodní kanály – reprezentují různé způsoby prodeje.
	Obchodní zástupci, agenti – reprezentují firmu u zákazníků, zajišťují marketing, případně i realizaci obchodů.


	Zboží – struktura a typy nabízeného a prodáváného zboží.
	Služby – struktura a typy poskytovaných a prodáváných služeb.
	Servisní činnosti – typy servisních činností a jednotlivé činnosti realizované u zákazníků.
	Reklamáce – typy reklamací k dodavatelům, resp. zákazníků na dodané produkty a služby.
	Posouzení reklamace – přijatá, odmítnutá, v posuzování apod.
	Dimenze skladového hospodářství:
	Sklady – představují strukturu vlastních případně pronajatých skladů pro zboží.
	Skladová místa – zahrnuje přehled skladových míst, členěných podle jejich typů.
	Skladové technologie – představuje přehled používaných technologií využívaných ve skladovém hospodářství. Jejím účelem je sledovat i jejich využití.
	Dimenze logistiky:
	Dopravní prostředky – představuje přehled všech vlastních dopravních prostředků firmy a slouží zejména k hodnocení dopravních nákladů.
	PHM – obsahuje základní druhy PHM pro hodnocení jejich spotřeby, vlastních zásob a plánování potřebných nákupů.
	Poskytovatelé dopravy – představují přehled dodavatelů v oblasti dopravy, resp. poskytovatelů těchto služeb, resp. dopravců pro hodnocení jejich výkonu, nákladovosti, kvality poskytovaných služeb.
	Dimenze majetku, investic a energií:
	Majetek – obsahuje přehled majetku firmy podle jednotlivých druhů.
	Úroveň stavu majetku – vyjadřuje kvalitativní a technický stav jednotlivých druhů majetku. Obsahuje pouze několik prvků stavu majetku (např. v běžném provozu, po generální opravě (GO), před GO, nevyužívaný, vyřazený apod.).
	Druhy investic – představuje přehled plánovaných, aktuálně realizovaných, nebo již uskutečněných investic firmy. Skupina investic zahrnuje: ▪ Reálné investice – jsou vázány na nějaký konkrétní předmět nebo podnikatelskou činnost a mají charakter dlouhodobého užití. ▪ Finanční investice – slouží k vytváření investičního majetku. ▪ Dematerializované akcie, akcie na jméno, akcie na doručitele, Pojistky a životní renty, Směnky, šeky, Finanční spoluúčasti.
	Druhy energií – obsahují základní druhy energií pro hodnocení jejich spotřeby a energetické náročnosti.

	Měřidla – představují přehled měřidel v rozlišení podle druhů energií.
	Dodavatelé energií – představují dodavatele a poskytovatele energií a s nimi spojené služby.

V rámci jednotlivých **oblastí řízení** v oddíle [B] je uveden **pouze přehled relevantních dimenzí pro danou oblast**.

2.8 Postupy, metody, metodiky

Pokud jde o **postupy řešení** úloh analytiky tak se **liší podle typu použitého řešení** (business intelligence, self service business intelligence, competitive intelligence atd.), podle konkrétní metodiky, podle implementovaného produktu, podle dodavatelské firmy, případně i dalších. Bylo by tedy velmi obtížné a prostorově náročné tyto nuance postihnout, navíc je k těmto tématům dostatek literatury. Omezíme se proto na souhrnné schéma vyjadřující rámcově řešení aplikací na bázi business intelligence (Obrázek 2-2).



Obrázek 2-2: Postup řešení projektu business intelligence

Naznačený **postup je dokumentován** v publikaci [Podniková analytika], v kapitole 9.

S úlohami podnikové analytiky se váže i řada metod, pro vybrané 2 využijeme rovněž odkazy:

- Metody dimenzionálního modelování: [Podniková analytika], kapitola 4.1.
- Metody datového modelování: [Podniková analytika], kapitola 4.2.

2.9 IT aplikace a nástroje pro analytiku

V tomto případě jde o souhrn všech aplikací, které tvoří **aplikační portfolio** retailové firmy. Z pohledu analytiky představují na jedné straně analytické nástroje a na nich realizované aplikace, především:

- **business intelligence**, resp. komplexní analytické systémy založené na celém spektru komponent, tj. datových skladů a tržišť, transformačních prostředcích (ETL / ELT), prostředcích pro kontroly a čištění dat, prostředcích reportingu a finálních analytických aplikacích,
- **self service business intelligence**, určené pro menší skupiny uživatelů, umožňují realizovat efektivní uložení a zpracování dat, nabízejí relativně jednoduché přístupy k datům. Příklady produktů jsou Power BI, Tableau, Qlick Sense apod.,
- **competitive Intelligence** se zabývá sběrem, zpracováním a ochranou informací s cílem získat konkurenční výhodu pro firmu. Je postaveno primárně na externích informačních zdrojích, často nestrukturovaných s cílem provádět na nich analýzy převážně k prostředí trhu.

Zdrojové aplikace, tedy aplikace vytvářející zdrojová data pro analytiku (ERP, CRM, eBusiness a další), mohou ale současně nabízet analytickou funkcionalitu. Charakteristiky těchto aplikací jsou obsahem oddílu D v publikaci „*Anatomie retailové firmy*“. Zdrojová data vytvářejí **značný potenciál pro realizaci analytiky** prodeje, úspěšnosti nabízeného a prodáváného zboží, analytiku zásob potřeby jejich doplňování, analytiku pro řízení rozvoje zákaznických služeb, personalizaci nabídky a zvyšování jejich loajality a další. Analytické nástroje mohou být v tomto směru i podkladem pro aplikace komplexního řízení výkonnosti prodeje **SPM (Sales Performance Management)**, výkonnosti a porovnání jednotlivých prodejen, pro predikce a odhadování trendů na trhu.

V některých případech velkých obchodních řetězců vede nárůst objemu dat z prodeje a jejich dalších aktivit i k přechodu na koncept a technologie **Big Data a Big Data Analytics**. Dalšími technologiemi specializovanými pro potřeby retailu jsou **AI agenti nebo chatboty**, zaměřenými na monitorování prodeje a jednotlivých regálů, doporučení produktů zákazníkovi, orientaci zákazníka v prodejně, řešení případných problémů apod.

Velký potenciál pro analytiku přináší dynamický rozvoj nasazení a využívání **eShopů**, resp. i dalších aplikací eByznysu a mobilního byznysu, resp. mByznysu.

2.10 Závěry



Z kapitoly vyplývají následující **závěry**:

- Základem řešení deskriptivní analytiky retailové firmy jsou **jednotlivé úlohy analytiky** rozlišené pracovním podle jejich typů.
- Podstatným vstupem do řešení úloh nebo projektů jsou **scénáře, resp. sady analytických otázek** zaměřených na potenciální požadavky nebo problémy retailové firmy.
- Role určují, jaké **funkce** bude mít pracovník v řešení projektů deskriptivní analytiky a jaké jsou **nároky na jeho znalosti**. V předchozím textu jsou specifikovány vybrané role ve vztahu k analytice retailové firmy, a to architekt, byznys analytik a datový analytik.
- **Data, resp. datové zdroje** představují vstupy do analytických aplikací a je tedy nezbytné dobře pochopit a posoudit jejich obsah, kvalitu, dostupnost a další parametry.
- **Faktory** vyjadřují organizační, technické a další podmínky řešení jednotlivých úloh, problémů a projektů. Vztahují se jak k řízení celé retailové firmy, tak speciálně k řešení retailové analytiky.
- **Metriky**, resp. ukazatelé jsou hlavní náplní analytiky v retailu. Jejich popis je obvykle detailní a je nutné se s ním pro řešení dobře seznámit.
- **Dimenze** představuje **analytické hledisko** pro identifikaci a hodnocení

sledovaných metrik, resp. ukazatelů a je tak součástí de facto každé metriky. Systém dimenzí vytváří základní kostru řešení analytiky firmy.

- **Postupy řešení** úloh analytiky se liší podle celé řady charakteristik a je nutné na počátku postup nebo metodiku kvalifikovaně vybrat. K nim se váží analytické metody, z nich nejvýznamnější je dimenzionální modelování a datové modelování.
- **IT aplikace a nástroje** představují aplikace mající charakter zdrojových aplikací a nástroje nebo aplikace pro vlastní implementace analytických aplikací.

3. Principy a komponenty prediktivní analytiky



Účelem kapitoly je uvést přehled **základních principů prediktivní analytiky**. Ty budou konkretizovány podle oblastí řízení retailové firmy.


Na úvod **k prediktivní analytice** ve firmě doplníme následující **odkazy na vybraná dokumentační videa**:


- [[The Fundamentals of Predictive Analytics - Data Science Wednesday - YouTube](#)],
- [[What is predictive analytics? Transforming data into future insights - YouTube](#)].



Následně nabízíme i odkazy webových stránek ke dvěma titulům literatury uvedených v úvodu této publikace:

- ABBOTT, D.: **Applied Predictive Analytics. Principles and Techniques for the Professional Data Analyst**. John Wiley & Sons, Indianapolis, 2014. ISBN: 978-1-118-72796-6. [[PA-Abbott](#)]
- GÉRON, A.: **Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow**. O'Reilly, 2023. ISBN: 978-1-098-12597-4. [[Scikit-Learn](#)]





3.1 Úlohy plánování a prognóza

Využití technologií podnikové analytiky je velmi účelné i pro řešení plánovacích úloh (plánů tržeb, nákladů, investic atd.), kdy je **třeba nejen data zpřístupňovat podle nejrozumnějších definovaných dimenzí** a analyzovat je podle nich, ale i nová data, tedy **plány tvořit**. Plánovací úlohy sledují **několik základních cílů**, zejména:

- vytvořit a **využít plánovací systém** respektující v podniku uplatňované plánovací a rozvrhové metody,
- **zajistit konsolidace vytvářených plánů** vznikajících na různých organizačních jednotkách, tj. pobočkách, prodejnách, úsecích, nebo naopak rozpouštění centrálně stanovených plánů na tyto jednotky,
- **zajistit konsolidace hodnot z různých druhů plánů**, např. plánu investičního, nákupního, prodejního, personálního apod. do výsledného, obvykle finančního plánu,
- **zajistit konsolidace plánů z pohledu různých měn** a přepočty na výslednou požadovanou měnu,
- automatizovat **řízení pracovního toku (workflow)** při přípravě plánu, resp. plánů, na kterém se podílejí různí manažeři, plánovači a další pracovníci podniku,
- efektivně **zpřístupňovat sestavené plány** zainteresovaným pracovníkům podniku, např. obchodním manažerům a vedoucím prodejen,
- zajistit **potřebnou bezpečnost a nastavení přístupových práv** pro zpracování plánů i pro jejich prezentaci v podniku, případně mimo podnik, kde jde o možnosti jejich čtení, zápisu a schvalování.

3.2 Hlavní principy prediktivní analytiky

Obsah plánování a prediktivní analytiky je **velmi variantní** podle odvětví, typu a zaměření firem a jeho zvládnutí je pro analytiky hodně náročné. Z pohledu řízení firmy je ale samotným základem pro prediktivní analytiku plánování a prognózování („forecasting“).

Prognózování a plánování v řízení firmy jsou aktivity, které **spolu souvisejí**, i když reálně jsou v některých případech realizovány nezávisle na sobě. Platí ale, že čím kvalitnější a přesnější jsou prognózy, tím kvalitnější jsou plány a plánování.

Rozvoj plánování a prognózování, jejich funkcionality ve vazbě na prediktivní analytiku je možné považovat za jednu z **klíčových oblastí rozvoje byznysu** a investic v retailových firmách bez ohledu na jejich velikost a složitost. Současné firmy v retailu disponují obrovskými objemy dat a smyslem konceptu, metod a nástrojů prediktivní analytiky je z nich vytěžit právě takové informace, které povedou k **posilování kvality plánování a prognózování** a tím i jejich konkurenceschopnosti a získávání nových konkurenčních výhod.

Není zde smyslem opakovat veškeré charakteristiky řízení, které jsou již detailněji **uvedeny v souvisejících publikacích na portálu MBI-AF**, a proto v tomto oddíle vybíráme pouze podstatné informace významné pro řešení plánování a prediktivní analytiky v prostředí retailových firem.

3.3 Úlohy prediktivní analytiky

(Zdroj: Pechová, K., 2025, upraveno)

Prognózování v podnikových oblastech je podle odborné literatury definováno jako **proces využívající analytických a datových poznatků a zkušeností k vytvoření předpovědi a odpovědi** na otázky týkajících se různých obchodních potřeb (Wilson, 2021).

Prediktivní analytika je sestavena na základě jiných analyticky orientovaných disciplín jako je **data mining, machine learning, statistika nebo rozpoznávání vzorů**. (Praus 2013)

Zároveň disciplína prediktivní analytiky využívá data a prediktivní modely pro **předpověď jevů na mikroekonomické úrovni**. Z dostupných dat a pomocí analytických technik je prediktivní analytika schopná identifikovat důležité podobnosti a vztahy a využít je k předpovědi nejrozumnějších jevů událostí a aktivit. (Siegel 2016)

Wilson tvrdí, že úkolem prediktivní analytiky je **odhalit možné budoucí stavy ale i posoudit proč k dané situaci došlo nebo jaké faktory**, které ovlivní něco, co nastane v budoucnu. V rozhodování o podnikových procesech je prognóza často tvořena **na základě vymezených technik** (Wilson, 2021):

- **Kvalitativní prognózování** založené na znalostech – využití názoru nebo kvalifikovaného odhadu.
- **Kvantitativní deduktivní prognózování** – vypracování prognózy budoucnosti na základě údajů z minulosti pomocí matematických modelů.
- **Strojové průmyslové učení prognózování** – využívá informace z předchozích iterací nebo tréninkového souboru dat a používá je jako pomoc při sestavování aktuálního budoucího modelu.

3.4 Příprava prediktivní analytiky

(Zdroj: Pechová, K., 2025, upraveno)

Nejdůležitější částí jakéhokoli projektu tedy i návrhu řešení analytického zpracování je vymezení si cíle, a tedy hlavní předmět zájmu. K tomu, aby bylo možné si cíl vymežit je důležité pochopit byznys daného podniku a **analyzovat potřeby v oblasti prediktivní analytiky**. V této úvodní fázi jsou analyzovány problémy a požadavky na dané řešení podle konkrétních podmínek oblasti podniku. Cílem této fáze je vymežit uživatele a účel prediktivního řešení. Musí být tedy známo, **k čemu bude řešení sloužit, jak bude aplikováno a jak svou predikci pomůže**.

Před zahájením prediktivního modelování je nezbytné provést několik „klíčových kroků k zajištění správnosti a připravenosti dat pro analytický proces. Prvním a zásadním krokem je definování cíle studie, tedy jasné vymezení problému nebo otázky, na kterou má prediktivní analýza odpovědět. Bez přesného cíle může být příprava dat neefektivní a zbytečně rozsáhlá. Jakmile je cíl jasně stanoven, je možné vytvořit **knihovnu provozních otázek**, které lze opakovaně a automatizovaně řešit.

Mezi **příklady prvotních otázek** spadají například tyto otázky:

- Je prediktivní analýza možná na dostupných datech, je zajištěna proveditelnost?
- Jaké zdroje dat budou využity?
- Pro realizaci bude zapotřebí provést změny v samotných datových zdrojích?
- Jaké analytické nástroje budou použity?

Po vymezení prvotních cílů a zodpovězení klíčových otázek je možné pokračovat s následujícím krokem a tedy **získání dat**. V tomto kroku jsou shromažďovány relevantní informace z dostupných zdrojů. V tomto kroku a v návaznosti na definované otázky je například odhalena **potřeba dodatečných dat, které jsou následně získávány pomocí senzorů nebo jiných zařízení**. Tato fáze se liší od běžného rutinního sběru dat v zavedených analytických prostředích, protože často vyžaduje jednorázové získání specifických údajů pro účely analýzy. Následuje **výběr a čištění dat**, což je zásadní krok, který pomáhá zajistit, že použité údaje budou relevantní a kvalitní. Tento proces zahrnuje **identifikaci nejdůležitějších datových atributů** a řešení problémů s kvalitou dat, jako jsou chybějící hodnoty nebo

nesrovnalosti v záznamech. V kontextu prediktivní analytiky se primárně pracuje s kvantitativními daty, nicméně i kvalitativní údaje mohou být v některých případech transformovány do číselné podoby pro účely modelování. Po dokončení přípravy dat následuje **fáze průzkumu dat (Data exploration)**, která se zaměřuje na podrobné zkoumání a vizualizaci shromážděných informací. Cílem této fáze je **identifikovat vzorce**, vztahy mezi proměnnými a potenciální korelace, které mohou být využity při tvorbě prediktivních modelů. Tento krok hraje zásadní roli při výběru vhodných analytických technik a modelů, které se budou v predikci používat.

Data pro prediktivní proces musí být uvedena **ve dvoudimenzionální formě**, tedy řádky a sloupce s tím že každá řádka reprezentuje jednotku analýzy. Sloupce v tabulkách označují atributy, deskriptory, proměnné a vlastnosti. Tato fáze procesu **identifikuje, které datové zdroje a v jaké míře mohou být použity pro model** prediktivní analytiky a také zdali jsou dostupná. Tedy zda pro vybrané proměnné existují data, či je lze získat. Další otázkou je třeba položit **v rámci datové kvality**, tedy zda je na dostupných datech prediktivní analytika proveditelná, jaké zdroje dat budou využity, či zda budou pro realizaci **potřeba změny v datových zdrojích** a jaké nástroje budou využity.

Zásadním krokem je v prediktivní analytice **vizualizace dat** a exploratorní analýza dat, která umožňuje identifikovat vzory a souvislosti ještě před provedením jakýchkoli úprav. Následuje proces **čištění dat**, při němž se odstraňují chyby a zajišťuje jejich úplnost, správnost a aktuálnost. Klíčovým krokem je však **pochopení obsahu dat a souvislostí**, které data poskytují. Pro zajištění kvality dat je nezbytné poznat jejich zdroj, tedy ověřit jejich původ, způsob správy a cestu, kterou data prošla. **Profilování dat** pomáhá odhalit jejich strukturu i možné problémy s kvalitou. Profilování by mělo být doplněno vizualizací, která poskytuje grafický přehled o jejich stavu (Wilson, 2021)

3.5 Vymezení dílčích funkcí prediktivní analytiky

K **hlavním funkcím** uplatňovaným v prediktivní analytice patří (podle Provost, F., Fawcett, T., 2013, zkráceno):

- **Clustering:**
 - hlavním **cílem je seskupovat data**, která se k sobě váží do jednotlivých skupin. Seskupuje tak objekty na **základě jejich podobnosti**. Vznikají tak klastry zákazníků, dodavatelů, služeb apod.,
 - s clusteringem je spojena i metoda **segmentace**. Ta představuje proces definování a rozdělení velkých homogenních datových sad do jasně identifikovaných segmentů, které mají podobné charakteristiky,
 - **Příklad:** „Klastry zákazníků založené na demografických charakteristikách, jako je věk, pohlaví, nebo jak často nakupují u dané maloobchodní firmy“.
- **Klasifikace a hodnocení pravděpodobnosti tříd (Classification and class probability estimation):**
 - je přístup nebo kombinace metod, kde primárním **cílem je určovat cílovou třídu** s využitím sledovaných hodnot.
 - predikuje pro každý objekt, do které sady tříd patří, přičemž obvykle jsou třídy vzájemně disjunktní,
 - určuje, do které třídy objekt patří a s tím související **scoring**, tj. odhad pravděpodobnosti správnosti takového zařazení.
 - **Příklad:** „Klasifikuje zákazníky do jednotlivých tříd, hodnotí pravděpodobnost, že tam zákazník skutečně patří?“.
- **Rozhodovací pravidla**
 - použití rozhodovacích pravidel je podobné jako u rozhodovacích stromů (viz dále),
 - rozhodovací pravidla jsou **zapisována ve tvaru „IF Ant THEN Class“** a umožňují klasifikovat kategorii cílového atributu z kombinace kategorií vstupních atributů. **Ant** je nazýván jako **antecedent neboli předpoklad**, **Class** reprezentuje **třídu neboli kategorii cílového atributu**.
- **Asociační pravidla**
 - **U asociačních pravidel není** na rozdíl od pravidel rozhodovacích definován **cílový atribut pro zařazení příkladu do určité třídy** (v rámci nastavení konkrétního algoritmu

lze nastavit omezení na vybrané atributy jako možné závěry pravidla), naopak nás zajímají **vazby mezi různými atributy v předpokladu a v závěru**. S tím souvisí problematictější vyhodnocování těchto pravidel.

- **Predikce vazeb (Link prediction)**
 - predikce vazeb predikuje **vazby mezi datovými položkami** a obvykle navrhuje, že taková vazba by měla existovat a jaká je síla této vazby.
 - **Příklad:** „Jestliže úloha analýza prodeje je ovlivněna faktorem úroveň managementu, pak by měla být ovlivněna i faktorem kultura firmy, a to s obdobnou silou tohoto vztahu“.
- **Redukce dat (Data reduction)**
 - redukce dat **redukuje velké objemy dat pro analýzy** pouze na ty nejpodstatnější informace,
 - menší objemy vybraných dat jsou snáze využitelné, nakonec i lépe poskytují právě relevantní informace.
 - **Příklad:** „Disponujeme daty o několika milionech zákazníků. Bude účelné omezit objem dat omezit podle vybraných kritérií, např. podle objemu tržeb, významu zákazníka apod.“
- **Náhodné modelování (Casual modeling)**
 - Náhodné modelování pokouší se **pochopit, které události nebo akce aktuálně ovlivňují** ty ostatní. Často je založené na náhodně vybraných a řešených experimentech.
 - **Příklad:** „Snahou je vyhodnotit kvalitu dodávek jednotlivých dodavatelů založenou na analýze vybraných dodávek, nebo vybraných parametrech dodavatelů, např. ekonomická síla, personální síla, lokalita, kde působí apod.“.
- **Profilování (Profiling)**
 - profilování charakterizuje **typické chování jednotlivce** nebo skupiny, označuje se také jako „*Popis chování*“.
 - **Příklad:** „Jaké jsou hlavní charakteristické rysy nejvýznamnějších dodavatelů firmy?“
- **Predikce vazeb (Link prediction)**
 - predikce vazeb predikuje **vazby mezi datovými položkami** a obvykle navrhuje, že taková vazba by měla existovat a jaká je síla této vazby.
 - **Příklad:** „Jestliže úloha analýza prodeje je ovlivněna faktorem úroveň managementu, pak by měla být ovlivněna i faktorem kultura firmy, a to s obdobnou silou tohoto vztahu“.
- **Zpracování časových řad**
 - Zpracování časových řad z pohledu detekce anomálií, trendů, očekávaných hodnot a odchylek.
 - **Příklad:** „Použití je např. v rámci hodnocení procesního řízení, kontroly obchodního procesu“.
- **Forecasting poptávky**
 - Predikce počtu objednávek na jednotlivé dny/hodiny (s využitím sezónnosti, počasí, svátků či akcí).
- **Řízení skladových zásob**
 - Časové řady slouží k plánování, kolik čerstvých produktů je třeba naskladnit (minimalizace expirace a ztrát).
- **Optimalizace logistiky**
 - Predikce vytížení kurýrů a plánování doručovacích oken.
- **Monitoring kvality procesů**
 - Sledování reálných doručovacích časů oproti slibovaným, detekce zpoždění jako anomálie.
- **Akční kampaně a promo**
 - Vyhodnocení vlivu slev a marketingových akcí na časové řady objednávek a tržeb.

Současná literatura věnovaná prediktivní analytice nabízí **obrovské množství jednotlivých metod a modelů**, jejich variant a modifikací.

3.6 Scénáře, analytické otázky

Scénář je obdobně, jako v případě deskriptivní analytiky, chápán jako sada **analytických otázek** ve vztahu k požadavkům nebo problémům retailové firmy v oblasti plánování, prognózování a s tím související retailové analytiky. **Další přehled** obsahuje **otázky** rozdělené pracovním na skupinu „Vztahu plánování, prognózování a prediktivní analytiky k byznysu“ a „Obsahu a kvalitě přípravy plánů“.

Otázky ke vztahu plánování, prognózování a prediktivní analytiky k byznysu

- Jak zvýšit **úspěšnost a výkonnost byznysu** díky vysoké kvalitě plánování a prognózování?
- Jak identifikovat **hlavní problémy firmy** vzhledem k úrovni a kvalitě plánování, jaké dopady mají do úspěšnosti jejího byznysu?
- Jak zajistit **kvalitní přípravu specialistů plánovačů** vzhledem k charakteru a potřebám firmy a současně vzhledem k vybraným softwarovým nástrojům pro plánování a prognózování?
- Jak systematicky **plánovat a regulovat stav zásob** pro provoz prodejny?
- Jak správně a racionálně aplikovat **plánovací metodiky firmy** do řešení plánovacích úloh?
- Jaké **cílové proměnné a prediktory** stanovit vzhledem k aktuálním a očekávaným potřebám řízení retailu?
- Jak zajistit **propojení různých typů plánů**, zejména naturálního plánování na finanční vyjádření plánů?
- Jaké možnosti nabídnout v rámci **individuálních plánů** pro jednotlivé manažery a specialisty v oblasti řízení?

Otázky k obsahu a kvalitě přípravy plánů

- Jak nastavit **různé možnosti** alokace plánovaných hodnot na útvary, resp. prodejny?
- Jak zajistit pro přípravu plánů adekvátní a **kvalitní datové zdroje**?
- Jak dosáhnout požadovanou **granularitu dat** v rámci plánovacích operací?
- Jak připravovat a realizovat plány pro **různé časové horizonty**?
- Jak umožnit a realizovat **sofistikované predikce** plánovaných hodnot?
- Jak připravovat **plány ve variantách** s jejich adekvátním ohodnocením a stanovením priorit a zajistit i **verzování** plánů?
- Jak **respektovat dislokaci firmy** a realizovat **konsolidaci plánů** vzhledem k různým obchodním jednotkám a útvarům?
- Jak nastavit **zodpovědnosti a kompetence** za přípravu plánů?
- Jaké **podstatné faktory** (ekonomické, legislativní, personální, organizační) je třeba při přípravě plánů brát v úvahu?
- Jak zajistit efektivní **kooperace a průběh schvalování** připravovaných plánů?
- Jak správně vyhodnotit potřebu **specializovaných plánovacích nástrojů, resp. metod a modelů prediktivní analytiky**?

3.7 Role prediktivní analytiky

Role v prediktivní analytice a při řešení projektů v této oblasti zahrnují **obdobnou škálu rolí**, jak byly vymezeny v publikaci „Anatomie retailové firmy“ v kapitole 2. Na druhé straně se v literatuře prediktivní analytiky zdůrazňují role Data Engineer, ML engineer/Data Scientist, DevOps Engineer a zejména ty na **principu „stoličky o třech nohách“** („The Three-Legged Stool“) (Wilson, J., E., 2021), a to:

- doménový expert,
- data a databázový expert,
- expert prediktivního modelování.

3.7.1 Doménový expert

Doménový expert **rozumí byznys problematice**, a tedy potřebám byznysu, jednotlivých oblastí řízení vzhledem k možnostem prediktivní analytiky:

- specifikuje charakter a **nároky na prognózování a plánování** v rámci firmy i ve vztahu k jednotlivým oblastem jejích aktivit,
- formuluje **žadání nových plánovacích aplikací** a reportů, specifikuje nároky na jejich kvalitu, tj. funkcionalitu, dostupnost, uživatelské rozhraní apod.,
- **konzultuje požadavky** na řešení prediktivní analytiky v rámci své oblasti řízení, a to z pohledu hlavních potřeb firmy,
- zajišťuje **hodnocení funkcionality** stávajících řešení a aplikací prediktivní analytiky vzhledem k vývoji potřeb firmy, případně k vývoji požadavků partnerů,
- určuje **požadavky na funkce operací** prediktivní analytiky,
- **analyzuje požadavky** uživatelů na prediktivní funkce, řeší jejich konsolidaci,
- poskytuje informace a zkušenosti o **stavu a kvalitě relevantních zdrojových databází**,
- definuje specifikace **cílových proměnných**, resp. ukazatelů,
- konzultuje specifické otázky **transformací dat**,
- podílí se na řešení **problémů spojených s kvalitou dat**,
- podílí se na **kvalifikační přípravě** všech ostatních uživatelů.

3.7.2 Data a databázový expert

Data a databázový expert se orientuje v datových zdrojích a datových strukturách. Zajišťuje podle jednotlivých úloh řešení prediktivní analytiky tyto **činnosti**:

- zajišťuje **analýzu datových struktur zdrojových systémů**, jejich kvalitu a dostupnost,
- spolupracuje na **vyhodnocení stavu a kvality dat** na formulaci principů řízení jejich kvality,
- konzultuje a posuzuje možné **varianty přístupů k řešení** prediktivní analytiky z pohledu datové architektury,
- spolupracuje na **specifikaci nástrojů pro transformace dat**,
- spolupracuje s doménovým expertem na **určení oblastí**, jež budou v rámci datových zdrojů **prioritní**,
- definuje **detailní pravidla a procedury transformací dat**, transformace polí mezi zdrojovými systémy a cílovým systémem (datové typy, délka polí, plnění konstantami).

3.7.3 Expert prediktivního modelování

Expert prediktivního modelování je specializovaný na vytváření modulů a využívání jednotlivých metod a algoritmů. Zajišťuje podle jednotlivých oblastí řešení tyto **činnosti**:

- **konzultuje s doménovými experty** jejich problémy a požadavky na aplikace pro podporu prognózování a plánování ve firmě,
- kooperuje na **analýzách požadavků** na prediktivní modely a na jejich konsolidaci,
- posuzuje **kvalitu zdrojových databází**,
- specifikuje rámcový **obsah a strukturu výstupů**, cílových proměnných, jejich hodnot a vizualizace,
- zajišťuje výběr a definuje základní **funkcionalitu** prediktivních modelů,
- zajišťuje **analýzu současného stavu** disponibilních zdrojových databází a aplikací,
- řeší **analytické otázky transformací dat**, tj. vlastní transformace dat,
- **navrhuje kontrolní a opravné procedury** v souvislosti s čištěním, resp. zajištěním kvality dat,

- podílí se na **řešení problémů nebo chyb** vyplývajících s přípravou provozu prediktivní analytiky,
- realizuje **nasazení modelů** prediktivní analytiky ve firmě.

3.8 Faktory ovlivňující prediktivní analytiku v retailu

Faktory prediktivní analytiky jsou svým zaměřením i strukturou obdobné těm, které jsou definovány pro podnikovou analytiku. Na druhé straně mají svá **specifika** vycházející z podstaty prediktivní analytiky. Při řešení úloh prediktivní analytiky jsou významné „**předpoklady**“, za nichž řešení probíhá. Kromě toho každý z faktorů představuje vymezení konkrétního prostředí, kde se úlohy prediktivní analytiky realizují, a to se musí ve většině případů důsledně respektovat, v opačném případě je možné připravovat kvalitní prediktivní modely, ale které nikdo nechce nebo nepotřebuje. Jak je rozmanité prostředí, tak jsou poměrně rozmanité i sady faktorů.

V dalších bodech jsou uvedené ty **faktory**, které při řešení plánování, prognózování a prediktivní analytiky lze **považovat za významné** (Wilson, J., E., 2021):

- V minulosti byla řešení prediktivní analytiky záležitostí převážně velkých společností, v současnosti se **posouvá i do středních a menších firem** a uplatňuje se prakticky na všech úrovních jejich velikosti. Je nutné ale zdůraznit, že ve velkých firmách jsou obchodní, ekonomické i další aktivity většinou podstatně komplexnější a složitější, a tedy i jejich prognózování a plánování je náročnější vyvolávající tak i i silnější potřebu prediktivních úloh. Na druhé straně disponují obvykle dostatečnými **finančními a personálními zdroji** pro jejich realizaci. Jsou zde většinou i **složitější zdrojové systémy**, a tedy i náročnější transformace dat do datových souborů prediktivní analytiky.
- Konkurence, zákazníci, dodavatelé a další partneři, jejich hodnocení, jejich očekávaný vývoj, jejich **nároky a očekávání se stávají velmi významnou součástí prediktivní analytiky** a obvykle tvoří také jádro prediktivních aplikací zaměřených na strategické řízení, marketing, nebo prodej. Faktor konkurenčního prostředí znamená **výraznější potřebu a uplatnění externích datových zdrojů** a s tím spojené nezbytné aktivity, jako např. jejich kvalifikované hodnocení kvality, dostupnosti, finanční náročnosti.
- Zřejmě výchozím a nejpodstatnějším faktorem je **potřeba** kvalitního prognózování a plánování a samotný **zájem vedení společnosti** o úlohy a řešení prediktivní analytiky. Ty jsou určeny primárně **pro manažersky nebo analyticky orientované uživatele**. Z toho vyplývá, že kvalita jejich řešení a zejména užití není primárně dána předpisy, metodikami, resp. disciplínou pracovníků, **ale zájmem, motivací a invencí** na straně zejména managementu.
- Úlohy prediktivní analytiky se silně váží i na hodnocení a plánování aktivit ve vztahu k externím partnerům. **Nabídka této prediktivní funkcionality s pochopením a respektováním potřeb i externích subjektů** může ovlivnit výsledný obchodní a ekonomický úspěch firmy.
- Při převládajícím **značném rozsahu** těchto projektů, jejich **finanční a časové náročnosti**, mimořádně rychlém **rozvoji technologií**, na nichž jsou založeny, je určení správné strategie odpovídající potřebám a možnostem podniku **velmi podstatným faktorem** řešení. Stanovení strategie by tak mělo zohlednit určení **priorit** řešení ve vztahu k oblastem řízení, určení **pří stupu** k řešení a **využití** různých disponibilních funkcí a metod a správný **výběr technologií** a produktů:
- Určování a **posuzování efektů** prediktivní analytiky je v porovnání s ostatními typy aplikací poněkud **specifické**. V každém případě je vymezení očekávaných efektů a sledování jejich naplnění podstatné s ohledem na to, že analytické přípravě a využití těchto aplikací musí **věnovat čas** experti, jejichž časové možnosti jsou vesměs omezené. Na druhé straně však efekty prediktivní analytiky **nemusí** být vždy zcela **přesně kvantifikovatelné**, resp. ve finančním vyjádření. Často se v těchto případech jedná o **kvalitativní efekty** znamenající dosažení vyšší konkurenceschopnosti firmy, získání lepší pozice na trh atd.
- Otázka kvality zdrojových provozovaných aplikací, je v souvislosti s úlohami prediktivní analytiky **posuzována v několika úhlech pohledu**:
 - do jaké míry jsou tyto aplikace **schopné poskytovat úplná, konsistentní a přesná data**, tj. jak je navržena jejich **datová základna**, jaký **systém kontrol** zahrnuje jejich

funkcionalita, jak odpovídají potřebám firmy z pohledu poskytovaných funkcí i zpracovávaných dat,

- zda zahrnují **vlastní plánovací funkcionalitu**, do jaké míry je využívána, jak může posloužit i jako vstup pro řešení prediktivní analytiky.

3.9 Cílové proměnné a prediktory

Vstupem prediktivní analytiky jsou data, která se promítají do **cílové proměnné a její hodnoty (targetu)**, která má být predikována. Data se v rámci prediktivní analytiky uspořádají, pročistí a vytvoří se nový datový zdroj. Na něj jsou poté **aplikovány prediktivní funkce a metod**. „*Prediktivní model je tak kombinace metod, kde primárním cílem je predikovat pravděpodobnost kategoriálních nebo kontinuálních hodnot s využitím hodnot prediktorů*“ (Wilson, 2021). Prediktorem, resp. „*vysvětlující proměnná*“ je hodnota, nebo charakteristika, která ovlivňuje zjišťování a výpočty cílové proměnné. Příkladem může být pro cílovou proměnnou „*objem tržeb*“ prediktor „*počet zákazníků*“, nebo „*počet položek v sortimentu zboží*“ apod.

Výstupem je nejúspěšnější prediktivní model, schopný s určitou pravděpodobností hodnotu cílové proměnné předpovídat.

3.10 Metody a metodiky

V rámci této podkapitoly uvádíme pouze základní charakteristiku obvykle používané metodiky CRISP-DM a následně i několik vybraných metod. Omezujeme se pouze na stručné vymezení s ohledem na dostupnou literaturu, např. i publikaci [\[Podniková analytika\]](#) zaměříme se spíše na jejich využití v oblastech řízení retailu v oddíle [\[B\]](#).


3.10.1 Metodika CRISP-DM

Nejčastěji užívanou metodiku je již od roku 1990 metodika **CRISP-DM**, která se primárně váže k projektům data miningu. Je to dáno tím, že prediktivní analytika a data mining mají k sobě velmi blízko, používají i obdobné algoritmy. Prediktivní analytika tvoří jistou nadstavbu nad data miningem.

CRISP-DM značí „**Cross-Industry Standard Process for Data Mining**“ (CRISP-DM, n.d.). **Cílem** je vytvoření standardního **procesního modelu, bez vazby na konkrétní prostředí**, který je zdarma a veřejně dostupný, se zacílením na praktickou aplikaci prediktivní analytiky (povětšinou komerční). Obsahuje nejen jednotlivé kroky a postupy, ale i nezbytnou dokumentaci, která má být s projektem vytvářena. Metodika je užitečná pro analytiky i proto, že jim poskytuje argumentaci pro manažery, co v rámci projektu dělají a proč to dělají (Obrázek 3-1).

CRISP-DM zahrnuje přímo kroky věnující se **formulaci zadání společně s pochopením problematiky a finálnímu využití výsledku**.

Návraty na předchozí fáze jsou dány např. nedostatečnými daty a jejich špatnou kvalitou pro vytváření modelů, nebo při vyhodnocení modelů se dojde k tomu, že výsledky nejsou adekvátní předpokladům apod.




Obrázek 3-1: Fáze procesního modelu CRISP-DM (CRISP-DM), (CRISP-DM, n.d.) (Berka, 2003, stránky 24-28)

Obsah jednotlivých etap je uveden v publikaci [[Podniková analytika](#)], v kapitole 18.

V dalších podkapitolách jsou uvedeny alespoň **základní charakteristiky metod** uplatňovaných v prediktivní analytice.

3.10.2 Strojové učení, Machine Learning

Machine Learning představuje klíčové metody a přístupy k prediktivní analytice. Proto je mu v tomto textu věnován větší prostor, a to v rámci celé **přílohy 1**. Příklad využití Machine Learning obsahuje **příloha 2** (Gorylová, 2025) zaměřená na prediktivní analytiku chladících zařízení v retailovém řetězci. V rámci příkladu jsou vymezeny i modely **SARIMAX a XGBoost** s tím, že sarimax je model časových řad a xgboost je univerzální model založený na rozhodovacích stromech.




Obrázek 3-2: Machine Learning v kontextu umělé inteligence (Zdroj: Microsoft, 2025)

Machine Learning (Wilson, 2021) je **podmnožina umělé inteligence**. Je to soubor různých technik, metod, modelování a programování, které dovolují systému se automaticky učit.

3.10.2.1 Základní principy machine learning

Machine learning (ML) je postaven na následujících principech:

- Je to **algoritmus nebo technika**, která dovoluje systému být **trénován a učit se na vzorech** ze vstupů a následně je upravovat podle zkušeností, aniž by musely být explicitně programovány.
- **Základní termíny** využívané při řešení nebo uplatňování ML jsou:
 - trénovací sada („*training set*“): případy, které systém využívá k učení,
 - jednotlivé trénovací případy: trénovací instance („*training instance*“),
 - model: část ML systému, která se učí a vytváří predikce (např. neuronová síť),
 - přesnost („*accuracy*“): míra kvality a výkonu systému.
- **Přístup k řešení ML**, viz obrázek:



Obrázek 3-3: Přístup k řešení ML (Zdroj: Géron, 2023)

3.10.2.2 Klasifikace ML podle způsobu řízení učení:

Způsobů řízení učení modelů v rámci machine learning je několik. Na tomto místě uvádíme dva nejčastější

- **Řízené učení** („*supervised learning*“):
 - Tréninková sada na vstupu algoritmu **obsahuje požadovaná strukturovaná řešení** („*labels*“).
 - **Typickou úlohou** je zde **klasifikace**, nebo predikování cílové ceny produktu, požadovaných vlastností produktu na bázi **regrese, regresní analýzy** apod.
 - Pokouší se **modelovat vztahy** a závislosti **mezi cílovou predikcí, cílovou proměnnou, prognózou a vstupními vlastnostmi** tak, že **mohou predikovat výstupní hodnoty pro nová data založené na vztazích**, které byly „naučeny“ na předchozích datových sadách. Spoléhají se zde na **experty**, kteří fungují jako učitelé k naplnění trénovacích dat, která pomáhají modelu získávat správné odpovědi.
- **Neřízené učení** („*unsupervised learning*“)
 - Učí se **z prostých, jasných příkladů** bez připojených odpovědí, kde algoritmu je ponechána možnost určit, které datové vzory využije.
 - Systém **nevyužívá přítomnost učitele**.
 - **Typickými úlohami jsou**:
 - **clustering**, resp. hierarchický clustering, který **dělí jednotlivé skupiny prvků na podskupiny** („*hierarchical clustering*“),

- **redukce dimenzí** pro zjednodušení obsahu dat („dimensionality reduction“),
- výběr, resp. **vyloučení určených vlastností** („feature extraction“),
- **identifikace anomálií** („anomaly detection“),
- **identifikace nových instancí** odlišujících se od ostatních („novelty detection“),
- **zjišťování asociačních pravidel** („association rule learning“).

Další charakteristiky Machine Learning obsahuje **Příloha 1**.

3.10.3 Regresní analýzy

Představuje **třidu modelů typu „příčina – následek“**, kde je definován vztah mezi příčinou (**vysvětlující proměnná**) a následkem (**vysvětlovaná proměnná**). Ty jsou využity k řešení predikcí, mezi vstupy, prediktory (vysvětlující, nezávisle proměnné) a cílovými proměnnými (vysvětlované, závisle proměnné). Odhaduje nebo predikuje pro každý objekt numerickou hodnotu určité proměnné.

Regresní analýza představuje souhrn statistických postupů a metod sloužících k analýze vztahu středních hodnot numerické proměnné **y** a hodnot numerické proměnné **x** nebo většího počtu takových proměnných (Hindls a další, 1999).

K principům regresní analýzy patří (podle Hindls a další, 1999, podrobněji statistická literatura):

- směřuje k **nalezení vhodných funkcí**, pomocí nichž bude možné odhadovat neznámé střední nebo individuální hodnoty **proměnné y** pomocí známých hodnot **proměnné x**, označované jako **regresní odhady**,
- **měřitelné činitele**, které se při odhadech mají brát v úvahu, představují **okruh vysvětlujících proměnných**,
- pokud se využívá pouze **jedna vysvětlující proměnná**, jde o **jednoduchou regresní analýzu**, pokud se využívá **více** proměnných, jde o **vícenásobnou regresní analýzu**,
- podkladem pro jednoduchou regresní analýzu je **n dvojic**, pro vícenásobnou regresní analýzu **n trojic, čtveřic** atd. hodnot,
- **úkolem** regresní analýzy je specifikace funkce přiřazující hodnotám vysvětlujících proměnných střední hodnoty vysvětlované proměnné – **regresní funkce**, tj. přímkové, parabolické, hyperbolické regresní funkce,
- při jednoduché regresní analýze se využívá **bodový diagram**, kde každá z **n dvojic hodnot x_i, y_i** je znázorněna jako bod v pravoúhlé soustavě souřadnic,
- v případě **více vysvětlujících proměnných** je nutné brát v úvahu jejich **vzájemná závislost**. Pokud **jsou nezávislé**, pak každá z nich přispívá k vysvětlení variability hodnot **proměnné y**,
- při regresní analýze se vychází z předpokladů formulovaných **v pravděpodobnostních regresních modelech**,
- nejjednodušším typem regresního modelu je **klasický lineární model**, model s lineární regresní funkcí vysvětlujících proměnných, jež nejsou náhodnými veličinami.

Výhody:

- **lineární regrese:**
 - Je **relativně jednoduché vytvořit** na této bázi model a rovněž jednoduché je **interpretovat** výsledky.
 - Může pracovat s téměř **jakýmkoli objemem dat** i při jednoduchém jejich začlenění do modelu.
 - Funguje velmi efektivně, kde **vlastnosti jsou lineární** a rovněž dobrá interpretace výsledků
- **vícenásobné regrese:**
 - Je široce využívána, protože je **velmi efektivní** a nevyžaduje příliš mnoho výpočetních zdrojů.
 - Může být implementována **jednoduše a rychle**.

Omezení:

- **lineární regrese:**
 - Předpokládá, že **data jsou nezávislá**, což nemusí vždy platit.
 - Může být velmi citlivá na **abnormální data** (outliers).
 - Předpokládá, že **vazba „příčina – následek“ zůstává neměnná** a lineární, což rovněž nemusí vždy platit.
- **vícenásobné regrese:**
 - **Není jedinou metodou** pro řešení komplexních problémů.
 - **Nefunguje dobře s nezávislými proměnnými**, které nejsou korelovány k cílové proměnné.

3.10.4 Rozhodovací stromy

Rozhodovací stromy jsou prakticky **nejpopulárnější metodou** v prediktivní analytice, pouze regresní analýza je podle průzkumů využívána častěji. Důvody popularity jsou uvedeny v kapitole jejich efektů. Rozhodovací strom je grafickou reprezentací logického vývoje časově na sebe navazujících alternativních rozhodnutí. (Friebelová, 2006). Jde o zvláštní případ grafu, kdy rozhodovací strom je tvořen z:

- **kořene a vnitřních uzlů** – označených atributem, ze kterých vede jedna hrana pro každou možnou hodnotu tohoto atributu,
- **listů**, které jsou označeny predikovanou hodnotou cílového atributu, za předpokladu, že ostatní atributy nabývají hodnot na cestě od kořene do listu (pokud se některé atributy na cestě nevyskytují, pak na jejich hodnotě v rámci klasifikace nezáleží),
- **podmínek** („split“), na jejichž základě se data dělí na 1 nebo více podskupin, resp. větví („branch“),
- **hloubkou** („depth“), která je vyjádřena počtem podmínek mezi kořenem a nejhlubším koncovým uzlem.

Klasifikaci příkladů na základě rozhodovacích stromů lze jednoduše provést tak, že z výchozího uzlu postupujeme přes vnitřní uzly (z uzlu volíme hranu odpovídající hodnotě daného atributu) až do listu, který je klasifikací daného příkladu.

3.10.4.1 Řešení rozhodovacích stromů

Podstatným **úkolem** v případě metod rozhodovacích stromů, je **jejich konstrukce**. Postupuje se metodou „**rozděluj a panuj**“ („Divide and Conquer“). Tato metoda znamená, že jsou data postupně rozdělována na stále menší podmnožiny, s cílem nalézt tu podmnožinu, ve které převládají příklady jedné třídy (hodnoty cílového atributu).

Základní algoritmus vycházející z této metody je **TDIDT** („Top down induction of decision trees“). Hlavním cílem je nalézt strom, jakožto reprezentaci získané znalosti, konsistentní s trénovacími daty. Konsistentních s trénovacími daty může být více různých stromů, v tom případě je dáována přednost stromům menším a jednodušším. Algoritmus zahrnuje tyto kroky (Berka, 2003 str. 86):

- zvol jeden atribut jako kořen dílčího stromu,
- rozděl data v tomto uzlu na podmnožiny podle hodnot zvoleného atributu a přidej uzel pro každou podmnožinu,
- existuje-li uzel, pro který nepatří všechna data do téže třídy, pro tento uzel opakuj postup od bodu 1, jinak skonči.

Proto je v praktických algoritmech často aplikováno takzvané **prořezávání stromů**, kdy dojde k nahrazení určitého podstromu jediným listem. Výsledkem je **jednodušší a srozumitelnější podoba rozhodovacího stromu**, strom méně zatížený případným šumem v datech, avšak většinou za cenu zhoršeného chování při klasifikaci nových příkladů.

Tento typ modelu je **jedním z nejoblíbenějších** prediktivních modelů pro svoji **jednoduchost a dobré výsledky** (Siegel, 2013). **Ze vstupních proměnných vybírá** model na základě algoritmů ty, které jsou statisticky **nejdůležitější a vytváří pravidla, kterými segmentuje bázi dat**. Poskládaná pravidla naučeného modelu se dají schematicky zobrazit jako strom s kořenem nahoře a listy dole. Rozhodovací

stromy tak umožňují **zpětnou interpretaci a vyvození dalších závěrů**. Oproti jiným modelům je možné do nich nahlédnout a **zkoumat jednotlivá rozhodnutí a pravidla** z nich vyplývající.

Výhody:

- Jsou **jednoduché** na pochopení a interpretaci. Mohou být interpretovány jako posloupnosti „if-then-else“ pravidel, které generují nakonec prediktivní hodnoty buď jako pravděpodobné poměry kategoriálních proměnných nebo jako průměrnou hodnotu cílové proměnné.
- Jsou **jednoduché na vytváření**. Jsou lehce rozšiřitelné, pokud se rozsah záznamů nebo polí zvyšuje.
- Mají zabudovaný **výběr proměnných**, což je výhodné v situacích se stovkami proměnných.
- Jsou **neparametrické, tedy nepracují s žádnými předpoklady** o rozdělení vstupů nebo o cílových proměnných.
- Mohou automaticky řešit **chybějící data**.
- Jsou flexibilní vzhledem k **užití numerických i kategoriálních dat**.
- **Nevyžadují velké objemy času** v souvislosti s přípravou dat.

Omezení:

- **Chybná rozhodnutí** na základě rozhodovacího stromu mohou mít **značný dosah** a dopad.
- I **malé změny** ve vstupních datech vyvolávají **velké dopady** na výsledky.
- Postupem doby a s rozvojem se mohou stávat **velmi složitými**, vyžadující **značný čas na řešení** a aktualizace.
- Pokud je hloubka (počet úrovní) rozhodovacího stromu větší než 3, pak se většinou **hůře interpretuje**.
- Rozhodovací stromy zahrnují **pouze jednu proměnnou** na každou podmínku.
- Rozhodovací stromy představují spíše nestabilní modely, **malé změny dat znamenají významné změny v rozhodovacím stromu**.

3.10.5 Neuronové sítě

Myšlenka „umělých neuronových sítí“ vychází ze znalostí o biologických neuronových sítích. Umělé neuronové sítě (*Artificial Neural Networks, ANN*) **se skládají z jednotlivých navzájem propojených neuronů**. Neuron je jednotka, která přijímá na vstupu podněty, vstupující do součtového členu. Forma vyjádření pro neuronové sítě, je obdobná jako pro lineární regresní model (viz kapitola 3.10.3):

$$Y_i = w_0 + w_1.X_1 + w_2.X_2 + \dots + w_n.X_n. \text{ kde:}$$

Y_i je cílová proměnná, tedy výstup,

X_1, X_2 atd. jsou vstupy, vysvětlující proměnné,

w_0, w_1 atd. jsou váhy, resp. koeficienty,

Váhy přiřazené každému vstupu jsou využívány v procesu učení (v okamžiku počátku procesu učení jsou váhy nastaveny na náhodná, malá čísla, blízká nule (Berka, 2003, str. 160) a učením se modifikují).

V prediktivním modelování se **umělá neuronová síť také skládá z neuronů**, které jsou navzájem propojeny a jsou **schopné přijímat vstupy a odesílat výstupy**. Každý neuron je aktivován, tedy produkuje výstup, **pouze pokud hodnoty do něj vstupující** (po vynásobení s váhami a sečtení) **překročí definovanou, prahovou hodnotu**.

Neurony jsou složeny v několika vrstvách:

- **Vstupní vrstva (input layer)** – představuje proměnné, které vstupující do modelu.
- **Vnitřní schovaná vrstva (hidden layer)** – může být složena z 0 až N vrstev. Hodnoty ze vstupní vrstvy jsou v této vrstvě propagovány dále, jsou násobeny se svými váhami, sečteny a aplikovány na nelineární funkci.
- **Výstupní vrstva (output layer)** – představuje modelem predikované hodnoty.

Všechny neurony vnitřní a výstupní vrstvy jsou **propojeny se všemi neurony** vrstvy předchozí (Statsoft, 2013). Určení počtu skrytých vrstev a počtu neuronů v nich je jedním z nejdůležitějších rozhodnutí, které ovlivňuje schopnost predikce a generalizaci neuronové sítě. **Rozhodnutí závisí na počtu vstupních proměnných a vlastnostech a velikosti učících dat**.

Existují **různé druhy** umělých neuronových sítí. V praxi **nejvyužívanějším typem neuronové sítě je Multilayer Perceptron (MLP)** (SAS, 2013). Jedná se o typ sítě s *feed-forward* topologií (hodnoty jsou sítí propagované pouze jediným směrem – vpřed) s možností specifikace počtu skrytých vrstev, počtu jednotek ve skrytých vrstvách a dalšími možnostmi (Statsoft, 2013). **Nevýhodou** neuronových sítí je fakt, že produkované výstupy nejsou zpětně refaktorovatelné – **není možné s určitostí říci, proč je výsledek takový, jaký je**.

Po trénovacích fázích dochází na fáze strojového učení. Síť se sama učí, respektive upravuje váhy tak, aby zpřesnila výstupy. Pro učení jsou pak fáze následující:

- **Příprava vstupních dat** – zde se jedná jen o přípravnou fázi celého učitelského modelu. Dochází v ní totiž k přípravě datové sady, která bude pro následné učení využita. Datová sada by měla být rozdílná oproti trénovacím sadám.
- **Učení** – síť obdrží datovou sadu, na které se pokouší dosáhnout požadovaného výsledku.
- **Testování a validace výstupů** – v rámci testování síť pracuje s datovou sadou, kdy zná výsledky, kterých má dosáhnout. Po aplikování naučeného postupu pak dochází k validaci jednotlivých výstupů se známými výsledky.
- **Aplikování změn nebo přeučování modelu** – pokud tedy dosažené výstupy splňují kritéria známých výsledků, pak může dojít na aplikování postupu vůči reálným datům. Ne vždy je ale dosaženo pozitivních výsledků. V takovém případě dochází k přeučování modelu. Model se tedy vrací do své fáze učení a upravuje algoritmy, pomocí kterých dosáhl předešlých výstupů.

Výhody:

- Mohou generalizovat **vazby** v datech, které **nejsou zjištěitelné** tradičními metodami.
- **Neexistují omezení**, pokud jde o **vstupní proměnné**, mohou zpracovávat výstupy i na základě nekompletních znalostí.
- Mohou být **provozně efektivnější** než ostatní modely, zejména při využití paralelního zpracování.

Omezení:

- **Efektivní architektura neuronové sítě** může být často navržena pouze na základě metody pokus – omyl.
- **Nedostatek vysvětlení** výstupních řešení může u uživatelů způsobovat nedůvěru k získaným výsledkům.

3.11 Závěry



Modelů a metod spojených s prediktivní analytikou je velké množství, v této kapitole jsme se omezili pouze na 4 z nich.

- V dalších kapitolách se **nezabýváme dílčími charakteristikami** těchto metod, ale především **využitím prediktivní analytiky pro účely plánování** a případně prognózování v daných oblastech řízení.
- V kapitolách věnovaných jednotlivým oblastem řízení **se omezíme na některé funkce prediktivní analytiky** s tím, že předpokládáme i **uplatnění** výše uvedených a dalších metod podle konkrétních potřeb a podmínek.
- Dílčí funkce (clustering a další), které jsou spojeny s prediktivní analytikou můžeme pracovně pokládat za jednotlivé stavební kameny jejich řešení.
- Funkce se velmi často **prolínají s modely a metodami prediktivní analytiky**, současně jsou ale aplikovány samostatně. Při rozsahu uvedených funkcí na jedné straně a metod na straně druhé je jednoznačné jejich **vzájemné přiřazení obtížné**.

Závěry k oddílu A: Principy analytiky retailové firmy



Smyslem oddílu A bylo zejména **shrnutí a rekapitulace** informací jako východiska pro formulaci obsahu deskriptivní a prediktivní analytiky v retailové firmě.

Hlavním obsahem tak zde byla **stručná rekapitulace obsahu řízení retailové firmy** podle jejích jednotlivých oblastí řízení s tím, že jejich popis je součástí publikace „*Anatomie retailové firmy*“.

Za podstatný vstup považujeme rámcovou **charakteristiku přístupů** k řešení analytiky v retailu a **vymezení úrovní analytiky** podle společnosti Gartner (deskriptivní, diagnostická, prediktivní, preskriptivní). V další části publikace se ale zaměříme výlučně na **uplatnění deskriptivní a následně prediktivní analytiky** v jednotlivých oblastech řízení v oddíle **[B]**.

Tato publikace se primárně **zaměřuje na obsah řešení analytiky** pro retailovou firmu. Detailnější **charakteristiky metod a nástrojů** analytiky nejsou předmětem tohoto textu, ale jiných publikací včetně textu [\[Podniková analytika\]](#), na kterou se podle potřeby odvoláváme.

Ke všem dalším kapitolám v rámci následujících oddílů pokládáme za nutné uvést, že prezentují především **náměty na řešení**, nikoli striktní návrhy nebo doporučení. Je tak na analytikovi a jeho reálných projektech, jak je bude **konkretizovat** podle skutečných potřeb a podmínek dané retailové firmy.

B. Analytika retailové firmy podle oblastí řízení




[1] Analytika ve strategickém řízení retailové firmy		
[2] Finanční analytika	[3] Personální a mzdová analytika	
[4] Analytika v marketingu	[5] Analytika vztahů k zákazníkům	
[6] Analytika nákupu	[7] Skladová analytika	
[7.2] Analytika prodeje	[9] Analytika logistiky	[10] Cenová analytika
[11] Analytika majetku, investic a energií	[12] Analytika obchodních center	



Účelem celého tohoto oddílu je prezentovat obsah a možnosti jak deskriptivní analytiky, tak prediktivní analytiky podle jednotlivých oblastí řízení retailové firmy, a to v návaznosti na části, resp. komponenty řešení prezentované v oddílu [A]. Každá kapitola má **2 základní části**, tedy část věnovanou **deskriptivní** analytice a část věnovanou **prediktivní** analytice.

Pokud jde o část, resp. podkapitolu **deskriptivní analytiky**, má většinou tuto **strukturu**:

- **Celkové schéma řešení**, které má nabídnout souhrnný a velmi stručný pohled na současti úlohy deskriptivní analytiky v dané oblasti řízení retailové firmy (viz další obrázek). Obsah schématu určují následující body:
 - V horní části každého schématu jsou uvedeny možné **analytické nástroje**, jak standardní (BI, SSBI, CI), tak analytika často integrovaná do transakčních systémů (ERP, CRM, SCM apod.).
 - Levá strana schématu vymezuje možné **datové zdroje** vznikající na základě standardních typů transakčních aplikací a jejich databází. Ty jsou vstupem po obvyklých kontrolách a úpravách do analytických databází, resp. databází nebo datových setů deskriptivní analytiky.
 - Prostřední část schématu je označena obecně jako „**Analytické databáze**“, přičemž na tomto místě nerozlišujeme, zda jde o datový sklad, datové tržiště, dataset, zda je v cloudu nebo on premise apod. Je zaměřená výlučně na obsah, tedy přehledy pouze hlavních dimenzí a metrik, které jsou vymezeny v dalších částech podkapitoly.
 - Pravá část schématu **Funkce / Reporty** nabízí příklady funkcí analytických úloh nebo výstupních reportů.




Další části podkapitoly jsou v následujících bodech:

- Přehled a **užití analytických dimenzí** navazujících na jejich vymezení v kapitole 2.7 oddílu [A]. Dimenze jsou na tomto místě uvedeny jako náměty souhrnně, jejich přiřazení k jednotlivým metrikám je zde ponecháno na analytikovi podle konkrétních podmínek řešení.


- Přehled klíčových **metrik, resp. ukazatelů** pro danou oblast řízení. Na tomto místě je třeba zdůraznit, že řada standardních, často využívaných metrik byla již vymezena v publikaci „Novotný, O. a další: IT a anatomie firmy (Oblasti a komponenty řízení)“ [Oblasti a komponenty], a proto je zde neopakujeme a odkazujeme na příslušnou kapitolu zmíněné publikace. Na druhé straně některé metriky specifické pro retail mají příslušné vymezení.
- **Funkce, resp. výstupy úlohy** deskriptivní analytiky obsahují pouze jejich stručnou charakteristiku.
- **Řešení deskriptivní analytiky** je poslední součástí podkapitol věnovaných deskriptivní analytice a zahrnuje:
 - formulace **analytických otázek** potřebných jako vstup do řešení a diskusí analytiků s manažery a specialisty retailové firmy,
 - charakteristiky **datových zdrojů** obvykle využívaných (nikoli všech) v dané oblasti řízení pro analytiku,
 - **poznámky k řešení** a implementaci deskriptivní analytiky v dané oblasti řízení retailové firmy.

Druhá hlavní podkapitola v rámci každé oblasti řízení (a kapitoly) je věnována **prediktivní analytice** a obsahem jsou tyto části:

- **Celková charakteristika řešení** na bázi schématu prediktivní analytiky v dané oblasti řízení (viz další obrázek):
 - **Horní část** schématu obsahuje relevantní **metody** a **modely** pro řešení prediktivní analytiky v rámci oblasti řízení.
 - **Levá část** obrázku je přehled vybraných **cílových proměnných**, které se pravděpodobně nejvíce váží k potřebám řízení v dané oblasti.
 - **Pravá část** zahrnuje přehled **hlavních prediktorů**, tj. dat, které významně ovlivňují predikované hodnoty cílových proměnných.
 - **Spodní část** schématu je věnována stručné **charakteristice funkcí**, resp. výstupů prediktivní analytiky v oblasti.



- Přehled **vybraných cílových proměnných** (které jsou předmětem plánů a prognóz, a tedy i prediktivní analytiky) a jim obvykle **odpovídajících prediktorů**, tedy



dat, atributů, které plánované a predikované hodnoty cílových proměnných výrazně ovlivňují.

- **Řešení prediktivní analytiky**, jsou rovněž poslední součástí každé podkapitoly a, obdobně jako v případě deskriptivní analytiky, obsahují zejména formulace analytických otázek potřebných jako vstup do řešení. Na závěr jsou zařazeny doplňující dílčí poznámky k řešení.

Další kapitoly pokrývají již jednotlivé **oblasti řízení retailové firmy** z pohledu řešení deskriptivní i prediktivní analytiky. Ty odpovídají přesně oblastem, jejichž obsah je vymezen v publikaci „*Anatomie retailové firmy*“ pouze s jednou výjimkou. Oblast zaměřenou na rozvoj firmy je zde nahrazena analytikou obchodních center, jejichž dílčí charakteristiky obsahuje oddíl E výše zmíněné publikace.

1. Analytika ve strategickém řízení retailové firmy



Analytika ve strategickém řízení představuje součást zejména úlohy **strategických analýz**. Účelem je zajistit funkce deskriptivní analytiky především **nad vybranými hlavními ukazateli firmy** na strategické úrovni, tj. z pohledu strategie celé firmy a všech podstatných souvislostí mezi nimi. Jde tedy pouze o klíčové ukazatele sledované na globální úrovni bez detailů. S ohledem na specifický charakter strategického řízení, s tím, že řada funkcí se promítá i do ostatních oblastí řízení, má kapitola **charakter pouze stručného shrnutí**.

1.1 Strategické analýzy

Strategické analýzy jsou založeny na metrikách, které jsou **rozděleny podle hlavních oblastí řízení**, na které se strategie retailové firmy orientuje (finance, prodej, nákup, ceny, investice atd.). Zahrnují vybrané **skupiny strategických metrik**, resp. **klíčových ukazatelů**, jejichž vymezení je v dalších kapitolách odpovídajících oblastem řízení retailové firmy.

Součástí strategického řízení a strategických analýz je analytika **strategických obchodních jednotek** (SBU, *Strategic Business Unit*), které představují **určité skupiny subjektů** a které mají mít relativně oddělené strategické plánování.

1.2 Formulace strategie

Strategické řízení firmy lze chápat jako základ a **vstup pro formulaci všech plánů a projektů** ve firmě. Do strategického řízení, které je primárně **záležitostí nejvyššího vedení firmy**, patří **definování jejího poslání (mission)**, tj. smysl existence ve vztahu k vlastníkům a dalším zainteresovaným skupinám lidí, dále zpracování **vize firmy**, formulace **byznys modelu** a specifikace **hlavních a dílčích cílů**.

Formulace strategie zahrnuje např. tyto funkce:

- vytvoření vize celé firmy. Současným základem je **marketingová koncepce managementu**,
- na základě analýzy trhu se určuje **konkurenční prostředí** a potenciální vlastní **konkurenční výhody**,
- určování hlavní **cenové strategie**, a to i v rámci obchodní, resp. marketingové strategie firmy,
- **zajištění dodávek zboží a spektra služeb** zákazníkům s potřebnou úrovní jakosti, spolehlivosti, včasnosti,
- formulace požadavků na **ekonomická rozhodnutí** v souvislosti s rozvojem obchodu začleněná do **finanční strategie** firmy.

1.3 Řešení analytiky v rámci strategického řízení



Analytické otázky:

Strategické analýzy:

- Jak řešit **hodnocení prostředí**, v němž firma podniká, kde jsou hlavní problémy a omezení?
- Jaké jsou současné i budoucí podnikatelské možnosti, jaký je jejich reálný potenciál?
- Jak efektivně využít **metodu SWOT**, s jejíž aplikací se může uskutečnit **analýza podstatných faktorů řízení a rozvoje firmy**?
- Jak přistoupit k vytvoření a průběžné **aktualizaci byznys modelu firmy**?

Formulace strategie:

- Navazují **roční plány** na dlouhodobou strategii a záměry firmy?
- Jsou všechny **vstupy a výstupy jednoznačně oceněny** a jsou stanoveny možné výkyvy v průběhu roku?
- Jsou stanoveny **principy a postupy** pro tvorbu strategických plánů?
- Jsou stanoveny seznamy aktuálně **sledovaných klíčových metrik** z jednotlivých procesů?
- Obsahuje plán **rezervu** na možná rizika?
- Využívá firma v oblasti strategického řízení metody a nástroje **prediktivní analytiky**?


2. Finanční analytika



Účelem úloh **deskriptivní finanční analytiky** je zpracovávat **finanční analýzy** retailové firmy podle různých kritérií a v různých úrovních dekompozice. Výstupy těchto analýz mají sloužit pro lepší hodnocení hospodaření a finanční situace firmy a přijímání rozhodnutí o jejím budoucím vývoji. Účelem užití **prediktivní analytiky** je efektivní podpora a zpřesňování finančního plánování a tvorby rozpočtů.

2.1 Deskriptivní finanční analytika

Souhrnný pohled na součásti deskriptivní finanční analytiky prezentuje Obrázek 2-1:



Obrázek 2-1: Deskriptivní finanční analytika

2.1.1 Dimenze finanční analytiky

	Základní dimenze:
	Čas – dimenze určující dobu platnosti finančních ukazatelů , resp. finančních operací. Je základem pro sledování časového vývoje finančních zdrojů.
	Regiony – struktura států a regionů kde se nacházejí jednotlivé pobočky nebo prodejny a kde se realizují ekonomické výsledky a finanční operace. Slouží pro porovnávání ekonomické úspěšnosti retailové firmy podle místa.
	Ekonomické dimenze:
	Finanční ústavy – pro analýzy stavů a pohybů na účtech, kterými firma disponuje v jednotlivých finančních ústavech.
	Měny – pro analýzy finančních zdrojů podle struktury využívaných měn, pokud jsou pro danou firmu významné.
	Nákladové druhy – pro analýzy nákladů na provoz firmy podle jednotlivých nákladových druhů (zboží, mzdy apod.).
	Účetní období – pro analýzy vývoje nákladů a výnosů a jejich porovnání v účetních obdobích.
	Účetní osnova – pro analýzy finančních ukazatelů ve vztahu na účty hlavní knihy a analytického účetnictví.
	Podniková organizace:

	Podnikové procesy – pro analýzy objemu nákladů, a výnosů vzhledem k jednotlivým procesům firmy.
	Podnikové útvary – zejména pro analýzy jejich ekonomických přínosů jednotlivých útvarů a na druhé straně nákladů na jejich provoz.

2.1.2 Metriky finanční analytiky

Úloha je postavena na analýzách **následujících základních finančních metrik, resp. ukazatelů**, na jejichž základě je možné hodnotit ekonomickou **úspěšnost** jednotlivých útvarů retailové firmy (jejich detailnější vymezení je v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.1.2):

- **Hospodářský výsledek** – rozdíl mezi výnosy a náklady firmy za určité období.
- **Obrat** – všechny výnosy z tržeb zboží a služeb.
- **Objem nákladů** – celkové náklady firmy, spotřeba prostředků a činností spojených s funkcemi firmy v daném období.
- **MVA (Market Value Added)** – tržní přidaná hodnota jako rozdíl mezi tržní hodnotou, tj. hodnotou, kterou by akcionáři a investoři získali prodejem svých akcií a dluhopisů a hodnotou, kterou do firmy vložili.
- **EVA (Economic Value Added)** – ekonomická přidaná hodnota vyjadřující rozdíl mezi provozním ziskem po zdanění (NOPAT) a náklady firmy na kapitál:
 - **EAT (Earnings after Taxes)** – zisk po zdanění (výsledek hospodaření za účetní období).
 - **EBT (Earnings before Taxes)** – zisk před zdaněním ($EAT + \text{daň z příjmů}$).
 - **EBIT (Earnings before Interest and Taxes)** – zisk před úhradou daně z příjmů a nákladových úroků.
- **EBITDA (Earnings Before Interest, Taxes, Depreciation and Amortization)** – zisk před úroky, zdaněním a odpisy.
 - **EBITDA Margin** – relativní ukazatel provozní výkonnosti vztážený poměrem ukazatele EBITDA k celkovým výnosům.
- **Stav účtů** – aktuální stavy jednotlivých účtů hlavní knihy – konečný zůstatek účtu, stav na bankovním účtu, položky obrátů a další.

Vedle základních ukazatelů je analytika založena i na **následujících skupinách finančních metrik, resp. ukazatelů** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.1.3):

- **Ukazatelé trendů** – porovnávání změn na sledovaných položkách výkazů.
- **Ukazatelé procentního rozboru** – procentní vyjádření podílu položek účetních výkazů k jediné zvolené základně.
- **Ukazatelé cash-flow** – reálný tok peněžních prostředků firmy v určeném období.
- **Ukazatelé rentability a nákladovosti** – vycházejí ze základního vztahu „ $Rentabilita = \text{Zisk} / \text{Investovaný kapitál}$ “.
- **Ukazatelé aktivity** – sledují výkonnost (intenzitu), s níž podnik dokáže využívat aktiva s cílem dosáhnout tržeb.
- **Ukazatelé zadluženosti a finanční struktury** – vztah mezi cizími a vlastními zdroji financování a měří tedy úroveň zadlužení firmy.
- **Ukazatelé likvidity** – souhrn všech potencionálně likvidních prostředků, kterými firma disponuje pro úhradu svých splatných závazků.
- **Ukazatelé kapitálového trhu** – jsou spojeny s vývojem cen akcií nebo výplatou dividend, tj. tržní cena kmenové akcie kótované na burze nebo na mimoburzovním trhu.

- **Ukazatelé finančních fondů a cash-flow** – umožňují vyjádřit a poměřit vnitřní finanční sílu (finanční potenciál) firmy, tj. schopnost firmy vytvářet z vlastní hospodářské činnosti finanční přebytky použitelné k financování existenčně důležitých potřeb. K těmto účelům obvykle slouží **ČPK (čistý pracovní kapitál)**.
- **Ukazatelé majetkové struktury firmy** – představují celkovou hodnotu majetku, resp. aktiv firmy podle účetní rozvahy.
- **Ukazatelé kapitálové struktury firmy** – představují celkovou hodnotu kapitálu, pasiv firmy podle účetní rozvahy.


2.1.3 Funkce finanční analytiky

Funkcionalita této analytické úlohy je rovněž založena na hodnocení **vybraných finančních metrik**. Zahrnuje např. **tyto funkce**:

- Analýzy **finančních ukazatelů** podle zvolených dimenzí, jako např. obratu, objemu nákladů (viz předchozí kapitola).
- Analýzy počtu **zpracovávaných finančních dokumentů** (daňových dokladů, dobropisů atd.).
- Analýzy počtu a objemu **účetních transakcí**.
- Analýzy časového **vývoje disponibilních finančních zdrojů**. Hodnocení **faktorů** ovlivňujících finanční operace, úvěrové zatížení, zpracování kumulativních hodnot finančních ukazatelů v čase apod.
- Analýzy **plnění finančních plánů a rozpočtů**, tj. sledování plnění v absolutních i relativních hodnotách, v rozlišení podle útvarů apod.
- **Alokace nákladů**, resp. rozdělení neadresných nákladů na určené objekty, např. rozdělení nákladů na centrální správu na jednotlivé útvary, rozdělení nákladů na infrastrukturu IT na útvary, rozdělení nákladů na servis na skupiny produktů apod. Alokace se realizují **podle hodnot vztažných veličin**, např. u servisu podle doby provozu zařízení prodejny apod.
- Analýzy **majetkové a kapitálové struktury** firmy.
- Analýzy **komplexních finančních ukazatelů**, a to např.:
 - Analýza trendů, procentní rozbor, analýza cash-flow.
 - Analýza ukazatelů rentability a nákladovosti, analýza ukazatelů aktivity, analýza ukazatelů zadluženosti a finanční struktury, analýza ukazatelů likvidity.
 - Analýza ukazatelů kapitálového trhu, analýza ukazatelů na bázi finančních fondů.
 - Součástí analytiky v rámci finančního řízení jsou i analýzy majetkové a kapitálové struktury firmy.

2.2 Deskriptivní analytika závazků

Souhrnný pohled na součásti deskriptivní analytiky závazků prezentuje Obrázek 2-2:



Obrázek 2-2: Deskriptivní analytika závazků

2.2.1 Dimenze analytiky závazků

	Základní dimenze:
	Čas – dimenze určující dobu platnosti závazků , pro sledování data splatnosti a hodnocení plnění finančních závazků k dodavatelům retailové firmy.
	Regiony – struktura států a regionů, případně míst působnosti dodavatelů a současně poboček firmy, které jsou nositeli závazků.
€	Ekonomické dimenze:
	Finanční ústavy – pro analýzy závazků podle bank dodavatelů, resp. partnerů.
	Měny – měny, pokud je dimenze vzhledem k závazkům pro danou firmu významná.
	Účetní období – pro analýzy objemu závazků vzhledem k účetním obdobím.
	Účetní osnova – struktura účtů, kde jsou vedeny závazky a které mohou být předmětem analýz.
	Podniková organizace:
	Podnikové procesy – zejména nákupní, k nimž se váží závazky, pro sledování zodpovědnosti za jejich vznik a řešení.
	Podnikové útvary – pro analýzy vzniku a vypořádání závazků obvykle podle obchodních útvarů firmy.

	Externí partneři:
	Dodavatelé – pro analýzy objemu závazků podle dodavatelů, jejich významu a termínů splatnosti.
	Poskytovatelé školicích, logistických a dalších služeb – pro analýzy obdobné, jako v případě dodavatelů.
	Obchodní dimenze:
	Platební podmínky – pro analýzy objemu závazků vzhledem k platebním podmínkám nastavených ve smlouvách.
	Zboží – pro analýzy závazků podle nakupovaných zboží.
	Služby – pro analýzy závazků podle nakupovaných služeb.

2.2.2 Metriky analytiky závazků


Analytika závazků pracuje zejména **s těmito metrikami** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.1.4):

- **Objem závazků** k dodavatelům firmy – celkový objem závazků za dodávky zboží a služeb od jednotlivých dodavatelů.
- Objem **závazků po splatnosti**.
- Objem **realizovaných úhrad závazků**.
- Objem **penále podle dodavatelů**.
- Objem **dlouhodobých závazků** – se splatností delší než 1 rok, představují celkový objem dlouhodobých závazků.
- Objem **krátkodobých závazků** – se splatností kratší než 1 rok, představují celkový objem krátkodobých závazků.

2.2.3 Funkce analytiky závazků

Analytika závazků pokrývá **následující skupiny funkcí**:


- Analýzy **ekonomických ukazatelů** závazků podle vybraných dimenzí, tj. hodnocení jejich objemu, struktury apod. (Obrázek 2-3).
- Analýzy závazků **vzhledem k dodavatelům a jejich skupinám**.
- Analýzy závazků **po splatnosti**.
- Analýzy závazků **podle platebních podmínek**.
- Analýzy závazků **podle nakupovaných zboží a služeb**.
- Analýzy **uložených penále a jejich vypořádání**.
- Analýzy **časového vývoje objemu závazků** vzhledem k pobočkám a prodejnám firmy, vzhledem k dodavatelům.
- Hodnocení **faktorů** ovlivňujících objem závazků, jejich splatnost a úhrady.



Obrázek 2-3: Příklad 1: Analytika závazků (Zdroj: Marek, 2024)

2.3 Deskriptivní analytika pohledávek

Souhrnný pohled na součásti deskriptivní analytiky pohledávek prezentuje Obrázek 2-4:



Obrázek 2-4: Deskriptivní analytika pohledávek

2.3.1 Dimenze analytiky pohledávek

	Základní dimenze:
	Čas – dimenze určující dobu vzniku a splatnosti pohledávek , pro analýzy vývoje objemu pohledávek v čase a pro analýzy pohledávek vzhledem ke splatnosti.
	Regiony – struktura států a regionů případně míst působnosti poboček, pro analýzy pohledávek podle regionálního rozložení.
	Ekonomické dimenze:
	Finanční ústavy – pro analýzy stavů a pohybů na účtech, kterými firma disponuje v jednotlivých finančních ústavech.
	Měny – měny pohledávek, pokud jsou pro danou firmu významné.
	Účetní období – pro analýzy objemu pohledávek vzhledem k účetním obdobím.
	Účetní osnova – struktura účtů, kde jsou vedeny pohledávky, a které mohou být předmětem analýz.
	Podniková organizace:
	Podnikové procesy – zejména řízení prodeje, obvykle ve vztahu k velkým zákazníkům.
	Podnikové útvary – pro analýzy vzniku a řešení pohledávek obvykle podle prodejních útvarů firmy.
	Externí partneři:
	Zákaznické firmy – pro sledování pohledávek podle skupin zákazníků, případně dalších podstatných charakteristik.
	Obchodní dimenze:
	Platební podmínky – pro analýzy objemu pohledávek vzhledem k platebním podmínkám nastavených ve smlouvách., zejména u velkých zákazníků.
	Zboží – pro analýzy pohledávek podle prodávaných zboží.
	Služby – pro analýzy pohledávek podle prodávaných služeb.

2.3.2 Metriky analytiky pohledávek

Analytika pohledávek je založena na **těchto metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.1.5):

- **Počet pohledávek** – celkový počet pohledávek za dodávky zboží a služeb jednotlivým zákazníkům retailové firmy.
- **Objem pohledávek**, např. v tis. Kč.
- **Počet pohledávek po splatnosti** – celkový počet, které dosud nebyly splaceny v termínu splatnosti.
- **Objem pohledávek po splatnosti.**
- **Počet urgencí.**
- **Podíl počtu pohledávek po splatnosti** na celkovém počtu

2.3.3 Funkce analytiky pohledávek

Analýzy pohledávek jsou realizovány v rámci těchto skupin:

- Analýzy ekonomických **ukazatelů pohledávek** podle vybraných dimenzí, tj. hodnocení jejich počtu, objemu, struktury.
- Analýzy pohledávek podle jejich **splatnosti**.
- Analýzy pohledávek podle **platebních podmínek**.
- Analýzy pohledávek **vzhledem k zákazníkům** a jejich skupinám.
- Analýzy **urgencí** pohledávek.
- Analýzy **časového vývoje** pohledávek.
- Hodnocení **faktorů** ovlivňujících objem pohledávek, jejich splatnosti a způsoby úhrady.

2.4 Řešení deskriptivní analytiky v rámci finančního řízení



Analytické otázky:

Finanční analytika:

- Poskytují současné reporty pravdivé a **včasné informace vzhledem k potřebám finančního řízení**?
- Kdo a v jakých termínech vykonává **hodnocení finančních výsledků** firmy?
- Do jaké míry je třeba respektovat **mezinárodní standardy** – IFRS, US GAAP a další?
- Jak operativně a s jakými problémy jsou modifikovány finanční aplikace vzhledem **ke změnám státní legislativy**?
- Jsou **o finančním stavu firmy** pravidelně informováni oprávnění pracovníci?
- Jak řešit rozvoj finančního řízení **v souladu se strategickými záměry** firmy?
- Jak efektivním finančním řízením **podporovat výkonnost firmy** (v obchodě, nákupu apod.)?
- Zjišťují a vyhodnocují se **ekonomické a mimoekonomické efekty** finančních operací? Kde jsou cesty jejich zvyšování?
- Jak řešit **úvěrové zatížení** retailové firmy?

Analýtika závazků:

- Existuje pravidelný **systém reportingu závazků**, měsíčně, kvartálně, ročně, jsou stanovena **pravidla pro reportování** závazků?
- Jsou pravidelně analyzovány významné **odchyly**, resp. anomálie v objemu závazků?
- Jak správně nastavit **analytická pravidla** ve vztahu k ukazatelům nákupu pro generování varovných zpráv (**alertů**)?


Analýtika pohledávek:

- Jak se **vyhodnocují pohledávky** k zákazníkům vzhledem k jejich významu a vazbám?
- Jak se sledují **pohledávky po splatnosti** a jaké jsou přístupy k jejich řešení?
- Promítá se úroveň a objem pohledávek **do nastavení úvěrových limitů** vzhledem k zákazníkům?

	▪ Jsou automaticky navrhována opatření pro řešení pohledávek, zejména těch významných a po splatnosti? ▪ Jsou pravidelně analyzovány významné odchyly, resp. anomálie v objemu pohledávek?
	Datové zdroje: ▪ ERP – finanční moduly tvoří obvykle základní součást ERP, s nejvyšším využitím a poskytují obvykle kompletní ekonomické informace finanční analýzy. Součástí ERP jsou u některých produktů i moduly finanční analýzy. ▪ eByznys (eShop, eProcurement) – poskytují ekonomická data o prodeji z provozu eShopů, případně data dokumentů, především faktur elektronicky předávaných retailové firmě od dodavatelů na bázi eProcurementu. ▪ POS – ekonomické informace o realizovaných prodeji na pokladnách, informace o platbách zákazníků. ▪ ECM – informace z finančních dokumentů (interních i externích) získávané např. na bázi jejich parsování.
	Poznámky k řešení: ▪ ERP jako zdroj dat pro analytiku vždy nestačí na specifické potřeby retailové firmy. Pak se využívají speciální finanční aplikace pro ty části finančního řízení, které ERP nepokrývá, nebo realizují speciální požadavky na finanční analytiku. ▪ ERP podporuje vysokou úroveň integrace celého systému, což právě u finančních modulů je velmi podstatné, finanční úlohy jsou věcně provázány na většinu úloh ostatních oblastí řízení, což se následně promítá do řešení úloh analytiky (nákupu, prodeje, majetku a dalších) s respektováním kontextu celé retailové firmy. ▪ V rámci finanční analýzy a zpracování výsledných analytických dokumentů musí zajištěno, že se realizují podle platných standardů a legislativy. Musí se také podle potřeb realizovat finanční analýzy a výkaznictví podle mezinárodních standardů (IFRS, US GAAP atd.).

2.5 Prediktivní finanční analytika

Celkové schéma prediktivní analytiky ve finančním řízení dokumentuje Obrázek 2-5:



Obrázek 2-5: Prediktivní analytika ve finančním řízení

2.5.1 Cílové proměnné ve finančním řízení

- Hospodářský výsledek.
- Obrat.
- Objem nákladů firmy.
- Cash Flow.
- MVA (Market Value Added), EVA (Economic Value Added)..
- EBITDA (Earnings Before Interest, Taxes, Depreciation and Amortization).

2.5.2 Funkce prediktivní analytiky a plánování ve finančním řízení

Prediktivní analytika ve finančním řízení firmy poskytuje podklady pro přípravu finančních prognóz a finančních plánů různých typů a zaměření a finančních operací. K těm patří zejména:

- Predikce hodnot **hospodářského výsledku**:
 - Prediktory: počty zákazníků, objem prodeje za jednotlivé druhy zboží, objem prodeje služeb.
- Predikce **objemu nákladů** firmy:
 - Prediktory: objem investic do rozvoje prodejen, počet pracovníků na prodejnách.
- Predikce **solventnosti firmy**, tj. schopnosti firmy splácet své krátkodobé a dlouhodobé závazky v době jejich splatnosti:
 - Prediktory: disponibilní cash flow.
- Predikce **rentability**, tj. ziskovosti firmy, která měří efektivnost, s níž využívá kapitál, tj. podíl zisku k vloženému kapitálu.
 - Prediktory: disponibilní cash flow.

- Predikce **cash flow**:
 - Prediktory: počty zákazníků, objem prodejů za jednotlivé druhy zboží, objem prodejů služeb.
- Predikce hodnot **MVA** (Market Value Added), **EVA** (Economic Value Added), **EBITDA** (Earnings Before Interest, Taxes, Depreciation and Amortization):
 - Prediktory: objem prodejů za jednotlivé druhy zboží, objem prodejů služeb.
- Plánování **externích zdrojů** financování, úvěrování atd.

2.6 Řešení plánování prediktivní analytiky v rámci finančního řízení

	Analytické otázky: ▪ Jak probíhá finanční plánování (např. podle útvarů), a jak se realizuje příprava rozpočtu firmy? ▪ Jsou automaticky realizovány vazby mezi jednotlivými částmi plánu? Jsou automaticky podporovány všechny změny všech částí plánu se vzájemnými vazbami? ▪ Je k dispozici porovnání plánu a skutečností včetně trendů a výhledu podle potřeby? ▪ Je automaticky podpořen rozpad finančního plánu na rozpočty útvarů? ▪ Zahrnuje plán cash flow veškeré informace z finančního plánu a je obrazem skutečností? ▪ Jak zajistit kvalitní přípravu specialistů plánovačů vzhledem k charakteru a potřebám firmy a současně vzhledem k vybraným softwarovým nástrojům pro plánovací úlohy? ▪ Jak co nejpřesněji a včas zjišťovat budoucí předpokládané potřeby finančních zdrojů? ▪ Jak aplikovat metody a možnosti prediktivní analytiky v rámci finančního plánování?
	Poznámky k řešení: ▪ Plán cash flow obvykle zahrnuje veškeré informace z finančního plánu a likvidita firmy může být na základě dostupné analytiky pravidelně hodnocena a přijímána příslušná opatření. ▪ Úspěšnost prediktivní analytiky ve finančním řízení může být výrazně ovlivněna zejména následujícími aspekty: ○ nedostatkem potřebných dat v nezbytném objemu a s historií pro vyvinutí úspěšných prediktivních modelů, ○ častým problémem je nedostatečná kvalita dat – redundance dat, duplicity, věcné chyby v datech, absence unifikovaných dat a další, ○ je nezbytné počítat i s tím, že realizace prediktivní analytiky je časově náročná s předpokládaným nasazením nejen specialistů pro modely a metody prediktivní analytiky, ale i doménové specialisty orientované zejména na finanční plánování a prognózování v retailové firmě. ▪ Machine Learning – představuje modely, které se různými způsoby učí z historických finančních dat, v nichž hledají významné vztahy a proměnné vztahující se k cílové proměnné (proměnným), kterou je třeba predikovat.

- Příklady uplatnění machine learning **a vybraných funkcí a metod** pro prediktivní finanční analytiku:
 - **Regresní analýzy** – se uplatňují pro predikce uvedených cílových proměnných (hospodářského výsledku, objemu nákladů apod.) podle uvedených prediktorů.
 - **Klasifikace** – závazků, podle objemu významu, splatnosti apod.
 - **Clustering** – pohledávek podle významu zákazníků.
 - **Profilování** – finančních společností vzhledem k možnostem financování a úvěrování retailové firmy.


3. Personální a mzdová analytika



Účelem personální a mzdové analytiky je poskytovat vedoucím pracovníkům kvalitní **analytické** podklady pro řešení požadavků na personální kapacity a jejich struktury, kvalifikační programy a mzdové zajištění.

3.1 Deskriptivní personální analytika

Souhrnný pohled na součásti deskriptivní personální analytiky prezentuje Obrázek 3-1:



Obrázek 3-1: Deskriptivní personální analytika

3.1.1 Dimenze personální analytiky

	Základní dimenze:
	Čas – dimenze určující např. dobu vzniku pracovního poměru, resp. jeho ukončení, doby realizovaných pracovních výkonů. Slouží pro sledování vývoje personálních kapacit v čase, analýzy nedostatku personálních kapacit podle období apod.
	Regiony – struktura států a regionů pro analýzy regionálního rozdělení disponibilních i potřebných personálních kapacit vzhledem k umístění poboček nebo prodejen firmy.
	Lidské zdroje a mzdy:
	Zaměstnanci – pro analýzy časových kapacit zaměstnanců, pro analýzy reálného využití zaměstnanců, analýzy objemu odpracované doby atd.
	Profesní struktura – pro analýzy počtů a časového fondu zaměstnanců podle jednotlivých profesí.
	Kvalifikační struktura – pro analýzy potřeby a stavu počtů pracovníků a jejich charakteristik vzhledem k dosažené kvalifikaci.
	Věková struktura – pro analýzy počtů pracovníků a jejich charakteristik vzhledem k věku, pro určení potřeby nových pracovníků.
	Vzdělávání – pro analýzy a určení rekvalifikací pracovníků podle poskytovatelů.
	Podniková organizace:
	Podnikové procesy – pro analýzy objemu práce spojené s jednotlivými procesy vzhledem k zaměstnancům, pro analýzy časové a nákladové náročnosti procesů v retailové firmě.
	Činnosti – představují jednotlivé vybrané dílčí činnosti uskutečňované v rámci obchodních a dalších aktivit firmy, které jsou základem pro analýzy pracnosti a nároků na pracovníky.
	Podnikové útvary – pro analýzy potřebného a reálného personálního vybavení jednotlivých útvarů, pro specifikaci problémů spojených s nedostatkem zaměstnanců v útvarech retailové firmy.
	Externí partneři:
	Poskytovatelé školicích a dalších služeb – pro analýzy zajištění a realizace rekvalifikačních programů v řízení v řízení ekonomiky, obchodu i IT.

3.1.2 Metriky personální analytiky

Analytika pro řízení personálních zdrojů je založena **na těchto hlavních metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.3.2):

- **Počty pracovníků** – fyzické počty pracovníků firmy, tj. nepřepočítané podle úvazků.
- **Pracovní fond v člověkodnech** – přepočítaný objem pracovní doby pracovníků firmy.
- **Počet obchodních, zejména prodejních transakcí na 1 pracovníka.**
- **Lidský kapitál a návratnost investice** – vyjádření celkového zisku či ztráty vůči investici do lidského kapitálu, a to obvykle v procentech či finančním vyjádření.
- **Náklady na nábor pracovníků** – na získávání a přijímání nových pracovníků vyjadřující efektivitu náborové činnosti.
- **Efektivita náborových zdrojů** – přepočítané vyjádření účinnosti vybraných náborových zdrojů.
- **Fluktuace zaměstnanců** – měření změn ve stavu zaměstnanců.

- **Objem kursů a kvalifikačních programů** – objem plánovaných i absolvovaných školení v člověkodnech.
- **Náklady na kursy a kvalifikační programy** jsou náklady na jednotlivé vzdělávací programy, kursy a odborná školení.


3.1.3 Funkce personální analytiky

Personální analýzy firmy představují tuto funkcionalitu:

- Analýzy **souhrnných ukazatelů** personálního řízení a personálního rozvoje.
- Analýzy **počtů a struktury pracovníků**, pracovního fondu v člověkodnech, podle kvalifikační struktury, profesního zařazení, věkové struktury.
- Hodnocení **pracovních nákladů**, podle útvarů, jednotlivých pracovníků.
- Analýzy **produktivity pracovníků**, např. na bázi realizovaného objemu prodeje.
- Analýzy **návratnosti investice** do nových i stávajících zaměstnanců.
- Analýzy **nákladů na nábor** zaměstnanců podle náborových zdrojů.
- Analýzy **fluktuace zaměstnanců**, jejich příčin a identifikace problémů.
- Analýzy **ukazatelů kvalifikačního rozvoje** podle potřebné a reálné kvalifikační struktury zaměstnanců.
- Analýzy struktury a objemu připravovaných a realizovaných **kursů a programů**, podle útvarů, zaměstnanců, poskytovatelů školicích služeb.
- Analýzy **nákladů na kursy** a kvalifikační programy podle poskytovatelů školicích služeb.
- Analýzy **časového vývoje personálních zdrojů**, analýzy výkyvů v personální zajištění firmy v čase.
- Analýzy **faktorů** ovlivňujících rozvoj personálu, kvalifikačních struktur v čase, analýzy rozvoje pracovního fondu v čase apod.

3.2 Deskriptivní mzdová analytika

Souhrnný pohled na součásti deskriptivní mzdové analytiky prezentuje Obrázek 3-2:



Obrázek 3-2: Deskriptivní mzdová analytika

3.2.1 Dimenze mzdové analytiky

	Základní dimenze:
	Čas – dimenze určující dobu realizovaných pracovních výkonů, doby nároků na mzdy, pro analýzy vývoje mzdového zatížení firmy apod.
	Regiony – struktura států a regionů kde se realizují pracovní výkony vzhledem ke mzdám, u velkých společností i pro porovnávání požadavků na mzdy mezi státy, případně regiony.
	Lidské zdroje a mzdy:
	Zaměstnanci – analýzy časových kapacit zaměstnanců, analýzy objemu odpracované doby atd.
	Profesní struktura – pro analýzy mezd podle jednotlivých profesí.
	Kvalifikační struktura – analýzy potřeby a stavu počtů pracovníků a jejich charakteristik vzhledem k dosažené kvalifikaci.
	Věková struktura – analýzy počtů pracovníků a jejich charakteristik vzhledem k věku, určení potřeby nových pracovníků.
	Mzdové složky – pro analýzy mezd a platů podle jejich jednotlivých součástí.
	Podniková organizace:
	Podnikové procesy – pro analýzy objemu práce spojené s jednotlivými procesy vzhledem k zaměstnancům, analýzy mzdové náročnosti procesů v retailové firmě.
	Činnosti – pro analýzy mzdových nákladů a pracovních na potřebné úrovni detailu.

	Podnikové útvary – pro analýzy mzdového zatížení jednotlivých útvarů, resp. poboček, prodejen apod..
--	---

3.2.2 Metriky mzdové analytiky

Analytika práce a mezd je založena např. **na těchto metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.3.3):

- Celkový **objem plánovaných nebo vyplacených mezd**.
- **Prémie** – za pracovní výsledky, které jsou kvantifikovatelné (např. za úsporu nákladů).
- **Odměny** – na základě hodnocení zaměstnanců.
- **Účasti na výsledku firmy, bonusy** – podíly zaměstnanců na celkovém výsledku firmy.
- **Pracovní náklady přesčasů** = mzdové náklady na přesčasy / celkové tržby.
- **Průměrná hodinová sazba** = pracovní náklady / počet odpracovaných hodin.
- **Příjem za zaměstnance** = příjmy / celkový počet zaměstnanců.

3.2.3 Funkce mzdové analytiky

Analýzy pro řízení práce a mezd firmy představují tuto funkcionalitu:

- Analýzy **souhrnných ekonomických ukazatelů mezd** podle vybraných dimenzí a jejich potřebných kombinací.
- Analýzy objemu a struktury **mezd podle útvarů, případně podnikových procesů**.
- Analýzy objemu mezd **podle profesních, kvalifikačních a věkových struktur**.
- Analýzy objemu **prémii, odměn, bonusů**.
- Analýzy mezd podle **mzdových složek**.
- Analýzy **návratnosti investic** do nových zaměstnanců.
- Analýzy **nákladů na nábor** nových zaměstnanců.
- Analýza **fluktuace** zaměstnanců z pohledu mzdového zatížení.
- Analýzy **časového vývoje mezd**.
- Analýzy **faktorů** ovlivňujících mzdové náklady v čase, hodnocení sezónních vlivů apod.

3.3 Řešení deskriptivní analytiky v personálním řízení


	Analytické otázky: Personální analytika: ▪ Jsou analyzovány a odsouhlaseny cíle pro vybrané profese v návaznosti na cíle firmy zaměřené na všechny složky hodnocení? Dochází k pravidelné aktualizaci personálních cílů? ▪ Existuje analytický systém měření výkonnosti pro vybrané profese včetně systému odměňování vázaného na výkonnost? ▪ Zvyšují se analytické odbornosti a schopnosti zaměstnanců komunikovat a spolupracovat a zvyšuje se jejich motivace? ▪ Zajišťuje se příprava pracovníků v oblasti kvalitní komunikace se zákazníky? ▪ Jak zajistit trvalý přehled vedení firmy o kapacitách na pracovním trhu? ▪ Jak analyzovat a následně omezit fluktuaci pracovníků? ▪ Jak analyzovat, plánovat a realizovat kvalifikační rozvoj pracovníků?
---	---

	- Jak dosáhnout potřebné znalostní úrovně pracovníků pro efektivní využití IT včetně využití analytických nástrojů? - Jak dosáhnout konsensu mezi pracovníky personálního řízení na navrženém obsahu a strukturách personálních analýz? Mzdová analytika: - Je pravidelně analyzován, dokumentován a zaveden benefitní program pro zaměstnance s ohledem na zařazení podle funkcí a s možností výběru? Má motivační charakter? - Jak analyzovat a plánovat nárůst mezd ve vztahu k podnikovým výsledkům a produktivitě práce? - Jak řešit identifikaci dat, tj. jednotlivých položek PAM a jejich vazeb tak, aby poskytovala snadnou a rychlou orientaci pracovníků firmy v mzdových analýzách?
	Datové zdroje: ERP (případně specializované personální nebo mzdové aplikace) – kompletní personální informace a informace pro výpočty mezd. POS – počet transakcí pro sledování výkonnosti pracovníků na pokladnách s vazbou na odměňování. Současně poskytuje podklady pro plánování pracovníků podle zatížení prodejen ve špičkách. Sociální sítě – poskytují data pro analytiku zaměřenou na pracovní trh a dostupnost pracovních zdrojů, zejména specialistů pro potřeby retailové firmy.
	Poznámky k řešení: - S ohledem na legislativu se zejména v případě mzdové analytiky využívají vedle ERP jako zdroj speciální mzdové aplikace a jejich data. - Moduly personálního řízení v rámci ERP zajišťují celý systém reportingu, přičemž reporty jsou zvláště náročné na určení dostupnosti podle kompetencí vedoucích pracovníků. - Na základě analytiky ERP i mimo něj mohou být zaměstnanci informováni aktuálně a bezprostředně o dění ve firmě, tyto informace a analýzy se umisťují na intranet, resp. speciální HR-portál. - Funkcionalita personálních modulů ERP může být zdrojem pro průzkum spokojenosti zaměstnanců. Na druhé straně podporuje projednávání stížností a nespokojenosti zaměstnanců, co se týká jejich problémů.

3.4 Prediktivní personální analytika

	Účelem prediktivní analytiky je na základě současných a historických faktů predikovat očekávaný vývoj potřeb a možností zajištění personálních zdrojů ve firmě a zvyšovat pravděpodobnost výběru správných lidí na správná místa, zvyšovat efektivitu získávání nových lidí a efektivitu jejich kvalifikační přípravy.
---	--

Celkové schéma prediktivní analytiky v personálním řízení dokumentuje Obrázek 3-3:



Obrázek 3-3: Prediktivní analytika v personálním řízení

3.4.1 Cílové proměnné v personálním řízení

Náměty na specifikaci cílových proměnných v oblasti personálního řízení obsahuje další přehled:

- Počet otevřených pracovních pozic ve firmě.
- Počet nových pracovníků podle útvarů, pozic a úrovní řízení.
- Pracovní fond v člověkodnech.
- Utilizace pracovníků, tedy vytížení jednotlivých pracovníků.
- Objem kursů a kvalifikačních programů.
- Náklady na kursy a kvalifikační programy.
- Hodnocení spokojenosti manažerů s pracovníky podle útvarů, pracovníků.

3.4.2 Funkce prediktivní analytiky a plánování v personálním řízení

V oblasti personálního plánování prediktivní analytika zahrnuje např. tyto **funkce**:

- **Plánování utilizace pracovní síly**, řízení kompetencí a řízení změn v personálních strukturách s dopady na změny organizace.
 - Prediktory: počty pracovníků, počty pracovních pozic.
- Predikce **potřeby nových pracovních pozic**:


- Prediktory: objem prodejů nebo služeb, počet zákazníků, počet a velikost dislokovaných prodejen.
- Predikce **potřeby nových pracovníků** podle pracovních pozic:
 - Prediktory: objem prodejů nebo služeb.
- Predikce **předpokládaných nákladů** na získávání, uplatňování a udržování lidského kapitálu:
 - Prediktory: počty pracovníků, počet a velikost dislokovaných prodejen.
- Predikce **objemu pracovního fondu**:
 - Prediktory: počty pracovních pozic, objem prodejů nebo služeb, počet zákazníků.
- Predikce **potřeby kvalifikačních programů**:
 - Prediktory: počty pracovníků, nabídka kurzů a kvalifikačních programů.
- Predikce **nákladů na kurzy** a kvalifikační programy:
 - Prediktory: počty pracovníků, počty pracovních pozic, ceny poskytovatelů kurzů.
- **Očekávaný vývoj** nabídky na pracovním trhu podle dále upřesňovaných prediktorů z oblasti demografie.
- **Klasifikace pracovníků do tříd**, např. „profesních skupin“ podle „útvárů, profesních charakteristik“ apod.

Poznámka:

- Podle (Fitz-Enz, Mattox, 2014) se uplatnění prediktivní analytiky v personálním řízení projevuje v celkovém zvýšení výkonu firmy, někdy až o 4 %.

3.5 Prediktivní mzdová analytika

Celkové schéma prediktivní analytiky v řízení práce a mezd dokumentuje Obrázek 3-4:



Obrázek 3-4: Prediktivní analytika v řízení práce a mezd

3.5.1 Cílové proměnné v řízení práce a mezd

- Celkový objem plánovaných nebo vyplacených mezd.
- Utilizace pracovníků.
- Pracovní fond v člověkodnech.
- Pracovní náklady přesčasů.
- Objem nákladů na certifikáty.
- Objem prémie a odměn.

3.5.2 Funkce prediktivní analytiky a plánování v řízení práce a mezd

- Predikce **objemu mezd**.
 - Prediktory: mzdové složky, počet pracovníků.
- Predikce **prémie a odměn**:
 - Prediktory: počet pracovníků, objem prodeje nebo služeb.
- Predikce **nákladů na mzdy** vzhledem k přesčasům.
 - Prediktory: objem přesčasů, počet pracovníků.
- Predikce **utilizace pracovníků**.
 - Prediktory: počet pracovníků, objem prodeje nebo služeb.
- Predikce **nákladů na získané certifikáty**.
 - Prediktory: počty certifikátů, počet pracovníků.

3.6 Řešení prediktivní analytiky v personálním řízení



Analytické otázky:

- Jak zvýšit **úspěšnost a výkonnost byznysu** díky vysoké kvalitě úloh mzdového plánování?
- Jak co nejpřesněji a **včas zjišťovat budoucí předpokládané mzdové požadavky**?
- Jak mzdové plány pro **různé časové horizonty**, s respektováním personálních, ekonomických a dalších vlivů?
- Jak identifikovat **hlavní problémy firmy** vzhledem k úrovni a kvalitě plánování mezd?
- Jak zajistit **kvalitní přípravu specialistů plánovačů** vzhledem k charakteru a potřebám firmy a současně vzhledem k vybraným softwarovým nástrojům pro plánovací úlohy a prediktivní analytiku?
- Jak správně a racionálně aplikovat **plánovací metodiky firmy** do řešení mzdového plánování?



Poznámky k řešení:


- Problémem při uplatňování plánování a analytiky může být respektování platné **personální** a zejména **mzdové legislativy**, které se navíc poměrně často mění.
- Příklady uplatnění machine learning **a vybraných funkcí a metod** pro prediktivní personální analytiku:
 - **Regresní analýzy** – slouží pro predikce cílových proměnných, např. pro plánování časového fondu, nákladů na mzdy, a to ve vztahu k uvedeným prediktorům. Např. „počet nových pracovníků“ podle „počtů volných pracovních pozic“
 - **Klasifikace** – segmentace rekvalifikačních a školicích programů podle obsahu, způsobu realizace a ukončení programu, které mohou sloužit přesnější plánování programů podle struktur pracovníků (profesní, kvalifikační apod.).
 - **Klasifikace kvalifikačních tříd** – posouzení nároků na znalosti a zkušenosti u každé kvalifikační třídy.
 - **Klasifikace prémie a odměn** – podle dopadů na objem mezd.
 - **Clustering** – klastry poskytovatelů školicích služeb podle typu školení, kapacitních možností, způsobu školení a konzultací,
 - **Profilování** – specifikace klíčových charakteristik jednotlivých pracovníků a jejich skupin z pohledu nároků na mzdy a odměny.

4. Analytika v marketingu



4.1 Deskriptivní analytika v marketingu

Souhrnný pohled na součásti deskriptivní analytiky marketingu prezentuje Obrázek 4-1:



Obrázek 4-1: Deskriptivní analytika v marketingu

4.1.1 Dimenze analytiky v marketingu

	Základní dimenze:
	Čas – dimenze určující dobu marketingových aktivit , pro analýzy vývoje trhu, konkurence, určování a analýzy času marketingových kampaní atd.
	Regiony – struktura států a regionů kde se realizují marketingové aktivity pro analýzy teritoriálního rozdělení trhu, pro analýzy odezvy na marketingové kampaně podle regionů apod.
	Externí partneři:
	Dodavatelé – pro analýzy marketingových aktivit vzhledem ke zboží a službám podle jednotlivých dodavatelů.
	Zákazníci firmy – pro přípravu a analýzy marketingových aktivit podle strukturalizace zákazníků, jejich významu, jejich velikosti apod.
	Poskytovatelé školicích, logistických a dalších služeb – pro analýzy marketingových aktivit vzhledem ke zboží a službám podle jednotlivých poskytovatelů služeb.
	Konkurence – pro analýzy konkurentů retailové firmy, které je účelné sledovat z pohledu poskytovaných zboží a služeb zákazníkům a získávaných konkurenčních výhod.
	Podniková organizace:
	Podnikové procesy – pro analýzy marketingových aktivit, kampaní, promo akcí, jejich časové a finanční náročnosti.
	Podnikové útvary – pro analýzy podílu (pracnosti, nákladů) jednotlivých útvarů, resp. poboček, prodejen na marketingových aktivitách retailové firmy.
	Obchodní dimenze:
	Obchodní kanály – pro analýzy vlivu různých obchodních kanálů na ekonomické i obchodní výsledky firmy.
	Obchodní segmenty – pro hodnocení úspěšnosti obchodních aktivit na jednotlivých obchodních segmentech.
	Obchodní zástupci, agenti – pro hodnocení zástupců z pohledu jejich podílů na marketingových aktivitách firmy.
	Zboží – pro přípravu a analýzy výsledků marketingových akcí podle struktury a typů nabízeného a prodáváného zboží.
	Služby – pro přípravu a analýzy výsledků marketingových akcí podle struktury a typů poskytovaných a prodáváných služeb.

4.1.2 Metriky analytiky v marketingu

Analytika v marketingu je založena např. **na těchto metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.2.2):

- **Pozice firmy na trhu** – podíl firmy na daném segmentu, resp. segmentech trhu v %.
- **Procento respondentů** kampaně, kteří uskutečnili nákup.
- **Zvýšení prodeje díky promo akci v %** ((Promotion Uplift) = (Objem prodeje v průběhu promo akce – Běžný objem prodeje) / Běžný objem prodeje * 100.
- **Efektivnost různých interakčních kanálů** na základě celkového počtu interakcí a průměrného skóre spokojenosti.
- **Procento interakcí**, které jsou úspěšně vyřešené.

- **Procento interakcí, které zahrnují opakované interakce.**
- **Procento zákazníků zařazených do věrnostního programu.**
- **Náklady na získání nového zákazníka** prostřednictvím marketingových kampaní, (CAC, Customer Aquisition Cost) = $\text{Celkové náklady marketingu} / \text{Počet nových zákazníků}$.
- **Počet analyzovaných konkurentů** – počet konkurenčních firem, které jsou předmětem např. srovnávacích analýz, sledování jejich nabídky služeb apod.
- **Úspěšnost marketingové kampaně** – je stanovena jako poměr počtu zákazníků, kterým jsou prodány nové služby, děleno počtem všech oslovených zákazníků v kampani.
- **Marketingové náklady na objednávku** – podíl celkových marketingových výdajů na celkovém počtu objednávek ukazuje náročnost investic do marketingu.
- **Podíl marketingu na celkových tržbách v %** = $(\text{celkové marketingové výdaje} / \text{celkové tržby}) * 100$.

4.1.3 Funkce analytiky v marketingu

Analytika marketingu představuje tuto funkcionalitu:

- Analýzy **souhrnných ukazatelů marketingu** v retailové firmě podle zvolených dimenzí a jejich kombinací.
- Analýzy **pozice firmy na trhu** podle obchodních segmentů, regionů, zboží služeb apod.
- Analýzy **počtů a struktury zákazníků** firmy a jejich změn.
- Analýzy **konkurentů** podle regionů, zboží a nabízených služeb.
- Hodnocení **úspěšnosti marketingových kampaní** podle změn v objemech prodeje zboží a služeb.
- Analýzy **marketingových nákladů** podle jednotlivých kampaní, podle útvarů firmy, podle obchodních segmentů.
- Analýzy **podílu marketingu** na celkových tržbách,
- Analýzy **prodejních marží**, tržního podílu.
- Analýzy výsledků, resp. úspěšnosti **slevových akcí**.
- Analýzy **časového vývoje** marketingových aktivit a jejich výsledků.
- Hodnocení **faktorů ovlivňujících marketingové** aktivity hodnocení promo akcí, sezónních faktorů apod.

4.2 Řešení deskriptivní analytiky marketingu




Analytické otázky:

- Jsou pro analýzu trhu zmapovány a analyzovány **potřebné interní a zejména externí informační zdroje**?
- Je zmapován **potenciál trhu**?
- Je **zmapována konkurence** (konkrétní data o cenách, podíl na trhu, kvalitě, vztazích)?
- Zjišťují a vyhodnocují se **ekonomické a mimoekonomické efekty** marketingových akcí? Kde jsou cesty jejich zvyšování?
- Jak efektivními analýzami v marketingu **podporovat výkonnost firmy** (v nákupu, obchodě apod.)?
- Jak kvalitně vyhodnocovat **výsledky marketingových průzkumů** podle potřeb řízení obchodu firmy, jak sledovat jejich návratnost?

	▪ Jak efektivní jsou různé promo akce? ▪ Jak kvalitně a kompletně lze vyhodnocovat konkurenci v daných segmentech trhu?
	Datové zdroje: ▪ ERP – obsahuje základní informace o realizovaném obchodu, zejména výsledcích prodeje na prodejních vstupujících do marketingové analytiky. ▪ CRM a sociální CRM – pro analytiku poskytuje podle možností detailní informace o zákaznících, o jejich požadavcích a potřebách. ▪ SRM – zajišťuje a analyzuje informace o dodavatelích, jejich profilech, slouží pro nákupní marketing. ▪ Competitive Intelligence – poskytuje komplexní informace o konkurenci. ▪ eByznys (eShop) – kompletní informace o průběhu obchodů a na eShopech pro analytiku jejich úspěšnosti, případně problémů v rámci marketingu. ▪ Sociální sítě – informace ve vztahu k hodnocení vlastní firmy a rovněž konkurence na internetu.
	Poznámky k řešení: ▪ Komplexní informace o potenciálních i realizovaných obchodních aktivitách v rámci CRM vytvářejí základ pro analýzy obchodní výkonnosti a tím i možnost sledovat obchodní aktivity a jejich efektivitu atd. ▪ CRM, Competitive Intelligence a sociální sítě umožňují systematické sledování a hodnocení konkurence podle různě zvolených kritérií (sortiment, nabídka doprovodných služeb, cenová úroveň apod.). ▪ Data získávaná ze zákaznických karet nebo aplikací jsou významným zdrojem pro formulování zákaznických profilů, a tedy přesnější zacílení i dalších marketingových aktivit.

4.3 Prediktivní analytika v marketingu

Celkové schéma prediktivní analytiky v řízení marketingu dokumentuje Obrázek 4-2:



Obrázek 4-2: Prediktivní analytika v marketingu

4.3.1 Cílové proměnné v marketingu

Náměty na specifikaci vybraných cílových proměnných v oblasti řízení marketingu obsahuje další přehled:

- Pozice firmy na trhu vyjadřuje podíl firmy na daném segmentu, resp. segmentech trhu v %.
- Počet promo akcí.
- Úspěšnost marketingové kampaně.
- Marketingové náklady na objednávku.
- Podíl marketingu na celkových tržbách.
- Objem nákladů na analýzy trhu a konkurence.
- Zvýšení tržeb za zboží a služby za období.

4.3.2 Funkce prediktivní analytiky a plánování v marketingu

- Predikce **tržní pozice firmy** podle segmentů trhu a prodejních možností:
 - Prediktory: počty a rozsah marketingových kampaní, počet objednávek podle druhů zboží, počet pracovníků, počty prodejen.
- Plánování a zaměření **marketingových kampaní**:
 - Prediktory: počty a rozsah marketingových kampaní, počet pracovníků, počty prodejen.
- Predikce **úspěšnost** marketingové kampaně:

- Prediktory: počty zákazníků ve skupinách, náklady marketingových kampaní.
- Plánování počtů a obsahu **promo akcí**:
 - Prediktory: počet pracovníků, počty prodejen.
- Plánování **marketingového mixu**, tj. plánování v oblasti cenové, distribuční, komunikační:
 - Prediktory: počty prodejen, počty oslovených zákazníků podle skupin.
- Predikce **poptávky na trhu**:
 - Prediktory: počet objednávek podle druhů zboží.
- Plánování **marketingového rozpočtu**:
 - Prediktory: náklady marketingových kampaní.
- Plánování **nákladů na analýzy** trhu a konkurence:
 - Prediktory: počet pracovníků, počty prodejen.
- Predikce **zvýšení tržeb** v důsledku marketingových aktivit:
 - Prediktory: počty a rozsah marketingových kampaní,
- Predikce **obchodních příležitostí**:
 - Prediktory: počty a rozsah marketingových kampaní, počty prodejen, náklady marketingových kampaní.

4.4 Řešení prediktivní analytiky a plánování v marketingu

	Analytické otázky: ▪ Daří se racionálně plánovat jednotlivé marketingové akce a promo akce, vyhodnocuje se jejich finální úspěšnost? ▪ Vychází příprava a plánování marketingových akcí z analýzy zákazníků a jejich segmentů? ▪ Hodnotí se pravidelně stav poptávky na trhu a jak se zjišťuje? ▪ Má každá marketingová akce plánované cíle a metriky? ▪ Jsou marketingové akce realizovány v souladu s marketingovými plány? ▪ Odpovídá plánování marketingového mixu reálným možnostem retailové firmy? ▪ Je schvalován rozpočet na naplánované akce a komunikaci? ▪ Zjišťuje se zvýšení tržeb za zboží a služby, které lze spojit s realizovanými marketingovými kampaněmi? ▪ Jsou náklady na marketing a marketingové kampaně přiměřené získávaným efektům? ▪ Disponuje firma dostatkem specialistů na marketing nebo pro to využívá externí poskytovatele? ▪ Jak zajistit propojení různých typů plánů, zejména naturální plánování marketingových akcí na finanční vyjádření plánů?
	Poznámky k řešení: ▪ Prediktivní analytika je v oblasti marketingu většinou založena na komplexních hodnoceních zákazníků, jejich očekávání, možných odchodů od firmy apod. ▪ Na stále větším významu nabývají predikce a prognózování předpokládaného vývoje objemu a struktury prodeje.


- Prediktivní modely pro marketing směřují stále více na **efektivnější cílení marketingových kampaní** a snížení nákladů na jejich realizaci.
- Příklad uplatnění machine learning **a vybraných funkcí a metod** pro prediktivní analytiku v marketingu:
 - **Regresní analýzy** – predikce zákaznické poptávky na základě dat prodeje z minulých období.
 - **Regresní analýzy** – na základě historie a vzorů nákupů modelování kampaní pro podporu budoucích prodejů.
 - **Rozhodovací stromy** – pro segmentaci zákazníků podle věku, způsobu a objemu nákupů, teritorií a dalších pro účely zacílení marketingových kampaní.

5. Analytika vztahů k zákazníkům



5.1 Deskriptivní analytika vztahů k zákazníkům

Souhrnný pohled na součásti deskriptivní analytiky vztahů k zákazníkům prezentuje Obrázek 5-1:



Obrázek 5-1: Deskriptivní analytika vztahů k zákazníkům

5.1.1 Dimenze analytiky vztahů k zákazníkům

	Základní dimenze:
	Čas – dimenze určující dobu aktivit ve vztahu k zákazníkům a jejich časového vývoje, pro analýzy vývoje počtu a struktur zákazníků v čase.
	Regiony – struktura států a regionů pro analýzy teritoriálního, resp. demografického rozdělení zákazníků z hlediska počtů i struktury.
	Externí partneři:
	Zákaznické firmy – pro analýzy struktury zákazníků firmy např. podle významu zákazníků, jejich velikosti apod.
	Podniková organizace:
	Podnikové procesy – pro analýzy řešení postupů při komunikaci a kooperaci se zákazníky.
	Podnikové útvary – pro analýzy úspěšnosti útvarů, např. při posilování loajality zákazníků, trvalých vazeb na konkrétní prodejny nebo prodejnu.
	Obchodní dimenze:
	Zboží – pro analýzy struktury a typů nabízeného a prodáváného zboží z pohledu potřeb a požadavků zákazníků.
	Služby – pro analýzy struktury a typů poskytovaných a prodáváných služeb z pohledu zájmu zákazníků o různé služby.
	Servisní činnosti – pro analýzy servisních činností realizovaných u zákazníků vzhledem k jejich zájmu o tyto servisní činnosti.
	Reklamáce – pro analýzy reklamací zákazníků na dodané produkty a služby podle druhů reklamací, skupin zákazníků, nebo částky reklamovaného zboží, či služby.
	Posouzení reklamace – pro analýzy výsledků reklamací, např. přijatá, odmítnutá, v posuzování apod.

5.1.2 Metriky analytiky vztahů k zákazníkům

V rámci analytiky vztahů k zákazníkům se využívají zejména **tyto metriky**:

- **Počet zákazníků firmy** zahrnuje všechny zákazníky firmy.
 - **Počet nových zákazníků** (akvizice).
 - **Počet aktivních zákazníků**.
 - **Procento ztracených zákazníků, kteří přestali nakupovat**.
- **Celkový objem zaznamenaných interakcí se zákazníkem**.
- **Hodnota zákazníka v životním cyklu (CLTV, Customer Lifetime Value)** = (Průměrná hodnota nákupu * Frekvence nákupů * Životnos) – Náklady na nového zákazníka.
- **Konverzní poměr (Conversion Rate)** = (Počet prodejů / Počet návštěvníků eShopu) * 100.
- **Call centra – časové metriky**, do časových metrik spojených s provozem call centra patří zejména čas strávený hovorem se zákazníkem, čas nezbytný po ukončení rozhovoru a další.
- **Průměrný čas rozhovoru** využívá se pro určení celkové pracovní zátěže call centra a plánování kapacit lidských zdrojů.
- **Vyřízení operátora** je procento času operátora, kdy je zaneprázdněný hovorem nebo nezbytnými po hovoru činnostmi porovnaný s celkovým dostupným časem.

- **Náklady na volání** jsou klíčovým ukazatelem výkonu pro většinu operací call centra.
- **Úspěšnost call centra** je míra úspěšných telefonátů. Počet úspěšně přijatých telefonů na celkový počet telefonátů.
- **Počty zákaznických reklamací** podle jejich typu, obsahu, posouzení, obchodního agenta.
- **Náklady na reklamace** celkově a průměrné náklady na reklamaci.
- **Počet dní reakce** firmy na reklamaci, od podání reklamace.
- **Počty reklamací podle úrovně obtížnosti.**

5.1.3 Funkce analytiky vztahů k zákazníkům

Analýzy vztahů k zákazníkům představují tuto funkcionalitu:

- Analýzy **počtů zákazníků**, počtů nových zákazníků, počtů ztracených zákazníků podle regionů, podle prodejen apod.
- Analýzy **počtů interakcí** se zákazníkem podle obchodních kanálů, podle regionů.
- Analýzy **ukazatelů call center** jejich časových metrik.
- Analýzy **nákladů call centra** a jeho úspěšnosti.
- Analýzy počtů a objemu **zákaznických reklamací**.
- Analýzy **nákladů na zákaznické reklamace**.
- Analýzy objemu reklamací **podle nároků na jejich vyřízení**,


5.2 Řešení deskriptivní analytiky vztahů k zákazníkům

	Analytické otázky: ▪ Jak posuzovat vzory přístupu zákazníků k nákupům – náhodné versus podle průzkumu nabídky? ▪ Jaké kategorie zboží procházejí, případně nakupují zákazníci dohromady? ▪ Jaké jsou podstatné indikátory naznačující odchod zákazníka („churn“) od obchodníka? ▪ Jak kvalitně a systematicky využívat funkce call center? ▪ Které segmenty zákazníků nejlépe reagují na různé promo akce?
	Datové zdroje: ▪ CRM – obsahuje obvykle zákaznickou databázi na bázi věrnostních a dalších programů a podklady pro analýzy zákaznických potřeb. Z komunikace se zákazníkem vyplývají často i jeho preference, pokud jde o obchodní kanály. ▪ POS – poskytuje podklady pro aktualizace věrnostních programů, zejména na základě použitých zákaznických karet. ▪ eByznys (eShop) – informace o navštívených stránkách, realizovaných prodejních transakcích, případně poznámky od zákazníků. ▪ Sociální sítě – hodnocení firmy ze zákaznických komunit.
	Poznámky k řešení: ▪ Pro zákaznickou loajalitu je podstatné správné personální nebo automatické (s chatboty) vybavení call center.

- Je otázkou, zda pro analytiku v oblasti vztahů k zákazníkům využívat standardní **analytické nástroje** nebo **analytiku integrovanou v CRM**.

5.3 Prediktivní analytika řízení vztahů k zákazníkům

Celkové schéma prediktivní analytiky v řízení vztahů k zákazníkům dokumentuje Obrázek 5-2:



Obrázek 5-2: Prediktivní analytika v řízení vztahů k zákazníkům

5.3.1 Cílové proměnné v řízení vztahů k zákazníkům

- Počty nových zákazníků.
- Počty operátorů na call centrech.
- Náklady na call centra.
- Objem servisních činností nabízených zákazníkům.
- Počty zákazníků zařazených do věrnostních programů.

5.3.2 Funkce prediktivní analytiky a plánování v řízení vztahů k zákazníkům

- Predikce **počtů zákazníků**.

- Prediktory: počty prodejen, počty pracovníků na prodejnách, objem prodejů za jednotlivé druhy zboží, objem prodejů služeb.
- Predikce **počtů nových zákazníků**.
 - Prediktory: počty a rozsah marketingových kampaní.
- Predikce **potřeby personálu na call centrech**.
 - Prediktory: počty a struktura nabízených druhů zboží a služeb.
- Predikce **potřeby pracovníků pro servisní činnosti**.
 - Prediktory: počty a struktura nabízených druhů zboží a služeb.
- Predikce **rozvoje věrnostních programů**
 - Prediktory: počty a rozsah marketingových kampaní.

5.4 Řešení prediktivní analytiky a plánování řízení vztahů k zákazníkům

	Analytické otázky: ▪ Daří se udržovat stabilní počet stálých zákazníků? ▪ Do jaké míry jsou zákazníci spokojeni s nabízenými službami a zbožím? ▪ Využívá firma pro kontakty se zákazníky funkcionalitu CRM a zejména call center? ▪ Je personální vybavení call centra odpovídající současným potřebám retailové firmy? ▪ Daří se snižovat podíl ztracených zákazníků? ▪ Jsou dostatečně kapacitně zajištěny servisní činnosti pro zákazníky? ▪ Využívá se věrnostních programů?
	Poznámky k řešení: ▪ Personalizovaný marketing tvoří (Mitchel, 2025): ○ orchestrace komunikačních kanálů (email, SMS, sociální média, direct mail), ○ personalizace obsahu (email obsahující doporučené produkty, prodejní akce apod.), ○ personalizace nabídky (prodejní kupóny, dárky apod.), ○ časová optimalizace (machine learning modely predikující nejvhodnější časy pro zaslání nabídek zákazníkovi). ▪ RFM (Recency, Frequency, Monetary) analýza řeší kvantifikaci zákazníka na těchto attributech: ○ R: Recency – kdy naposledy zákazník nakupoval. ○ F: Frequency – jak často zákazník nakupuje. ○ M: Monetary – kolik zákazník utrací. ▪ Využití RFM analýzy je založeno na tom, že zákazníkovi se pro každý atribut přiřadí určitý počet bodů, obvykle 1 – 5. Na základě toho se vytvoří matice zákazníků RFM o 125 kombinacích. Podle hodnot se pak zákazníci dělí do segmentů jako „Šampioni“, „Rizikovi“, „Loajální“ apod. ▪ Prediktivní analytika má být zaměřena na vytváření dlouhodobých a úspěšných vztahů se zákazníky, zvyšování jejich tzv. loajality.


- Průběžná analytika zákaznických požadavků a chování, evidence a **hodnocení současných obchodních vztahů** podstatně zvyšuje výkonnost a celkovou obchodní úspěšnost firmy.
- Příklady uplatnění machine learning **a vybraných funkcí a metod** pro prediktivní analytiku v řízení vztahů k zákazníkům:
 - **Rozhodovací stromy** – pro specifikaci komunikačních aktivit (call center) se zákazníky a přípravy podkladů pro marketingové kampaně.
 - **Segmentace zákazníků** umožňuje zefektivnění komunikace se zákazníky, lepší plánování sortimentu zboží a promo akcí a realizuje se na těchto principech (Mitchel, 2025):
 - demografická segmentace zákazníků podle věku pohlaví, výše příjmů, rodinného stavu, možností bydlení,
 - geografická segmentace podle regionu, klimatické zóny působení ve městě nebo na venkově,
 - behaviorální segmentace podle nakupovaných produktů, četnosti nákupů, velikosti nákupů, návštěv eShopů, jejich využití pro nákupy,
 - psychografická segmentace podle životního stylu, hodnot, nastavených priorit,
 - případně dalších.

6. Analytika v řízení nákupů



6.1 Deskriptivní analytika nákupů

Souhrnný pohled na součásti deskriptivní analytiky nákupů prezentuje Obrázek 6-1:



Obrázek 6-1: Deskriptivní analytika nákupů

6.1.1 Dimenze analytiky nákupů

	Základní dimenze:
	Čas – dimenze určující dobu požadovaných a realizovaných nákupů zboží, pro sledování vývoje objemu nákupů v čase i ve vztahu k jednotlivým dodavatelům.
	Regiony – struktura států a regionů kde se realizují nákupní operace pro sledování úspěšnosti nebo ekonomické efektivnosti nákupů v rozlišení podle regionů.
	Externí partneři:
	Dodavatelé – pro analýzy dodavatelů zboží a služeb, režijního materiálu podle jejich kvality, sortimentu, cenové úrovně.
	Poskytovatelé logistických služeb – pro analýzy portfolia služeb, dostupnosti, kvality.
	Podniková organizace:
	Podnikové procesy – pro analýzy objemu nákladů a pracnosti spojeného s jednotlivými nákupními procesy.
	Podnikové útvary – pro analýzy pracovního zatížení jednotlivých útvarů, resp. poboček, prodejen apod. ve vztahu k dodavatelům a službám logistiky.
	Obchodní dimenze:
	Platební podmínky – pro analýzy objemu nákupů podle dohodnutých platebních podmínek vzhledem k dodavatelům.
	Dodací podmínky – pro analýzy objemu nákupů podle dohodnutých dodacích podmínek vzhledem k dodavatelům.
	Dokumenty – pro analýzy počtů zpracovávaných obchodních dokumentů realizovaných ve vztahu k řízení nákupů, pro posuzování výkonnosti útvarů.
	Zboží – pro přípravu a analýzy výsledků a efektivnosti nákupních operací podle struktury dodávaného zboží.
	Služby – pro přípravu a analýzy výsledků a efektivnosti nákupních operací podle struktury dodávaných služeb.
	Reklamáce – pro analýzy reklamací k dodavatelům na dodané produkty a služby.
	Posouzení reklamace – pro analýzy výsledků řešení reklamací – přijatá, odmítnutá, v posuzování apod.

6.1.2 Metriky analytiky nákupů

Analytika nákupů je založena např. **na těchto metrikách:**

- **Počet objednávek** – na dodavatele zboží a služeb s určením požadovaného objemu položek zboží, resp. rozsahu služeb, dodacích termínů apod. S tím souvisí:
 - **Průměrná výše**, resp. objem objednávky ve finančním vyjádření.
 - **Počet zpracovaných a odeslaných objednávek.**
 - **Počet dosud nevyřízených objednávek.**
- **Ekonomická výše objednávky (EOQ, Economic Order Quantity)** – představuje počet jednotek zboží na objednávce při nejnižších nákladech pro obchodníka. Vychází z předpokladu stabilní úrovně poptávky a stabilních dodacích dob dodávek zboží. Počítá se na základě tohoto vzorce:

$$EOQ = \sqrt{\frac{2(\text{Roční využití položek zboží})(\text{Náklady na objednávku})}{(\text{Roční náklady na dodávku na jednotku zboží})}}$$

Příklad (Bragg, 2024, upraveno): Firma prodávající papír ho dodává v objemu 1000 palet ročně. Náklady na jednu objednávku jsou 15 USD. Náklady na dodávku jedné palety představují 5 USD ročně.

$$EOQ = \sqrt{\frac{2(1000)(15)}{(5)}} = 77$$

Další metriky jsou vymezeny detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.2.4:

- **Objem nákupů za stanovený čas** – celkový objem nákupů zboží a služeb podle sortimentu, dodavatelů a regionů a podíly jednotlivých sortimentních položek, dodavatelů a regionů a v časovém vývoji.
- **Náklady na zajištění nákupu zboží a služeb** – objem nákladů na nákup podle nákladových položek, zodpovědností a činností.
- **Počet a profily dodavatelů** – počet aktuálně využívaných, potenciálních i v minulosti využívaných dodavatelů firmou. Sledují se rovněž:
 - Průměrný čas dodávky, případně maximální časy dodávek.
 - Spolehlivost dodavatele, počet reklamací na zajištění dodávek.
 - Frekvence objednávek.
 - Náklady na dodávku.
- **Počet dokumentů** zpracovávaných v souvislosti s nákupem (dodací listy, faktury apod.)
- **Dodací lhůta nákupů** – doba, která uplyne od předání objednávky odběratelem až po okamžik dostupnosti (pohotovosti) zboží
- **Počet reklamací a objem reklamovaného zboží** – počet reklamací (přijatých, odmítnutých, realizovaných) podle sortimentních položek, typů reklamací atd.

6.1.3 Funkce analytiky nákupů

Analýzy nákupních aktivit retailové firmy představují tuto funkcionalitu:

- Analýzy **souhrnných ekonomických ukazatelů nákupu** podle vybraných dimenzí.
- Analýzy **ekonomické úspěšnosti a efektivnosti** realizovaných nákupů zboží i služeb.
- Analýzy **nákladů na nákup**, sledování nákladovosti nákupů, analýzy a kontrola smluv, plnění termínů, jakosti apod.
- Analýzy počtu, **objemu a vývoje nákupních transakcí**.
- Analýza počtů vytvořených, odeslaných a dosud nevyřízených **objednávek**.
- Optimalizace **velikosti objednávek** a dodávek zboží podle EOQ.
- Hodnocení **dodacích lhůt** nakupovaných produktů a služeb.
- Analýzy a hodnocení **počtu a objemu reklamací** k dodavatelům.
- Analýzy **počtu různých dodavatelů**, jejich obměny a hodnocení a porovnání jejich kvality.
- Vyhodnocení **úspěšnosti či neúspěšnosti** podaných **reklamací** k dodavatelům.
- Analýzy **kvality, resp. nekvality** nakupovaných zboží a služeb.
- Analýzy **časového vývoje nákupů**.
- Analýzy **faktorů** ovlivňujících nákupní aktivity, hodnocení sezónních vlivů, zpracování indexů, kumulativních hodnot v čase apod.


- Analýzy **v rámci nákupního marketingu**, analýzy nabídky trhu, dodavatelských možností, analýzy stavu dodávek.

6.2 Řešení deskriptivní analytiky nákupu

	Analytické otázky: ▪ Jak nastavit a racionálně realizovat analytické funkce nákupního marketingu, tj. analýzy průzkumů na nákupním trhu, možností dopravy a logistiky? ▪ Existuje evidence stávajících i potenciálních dodavatelů v takovém rozsahu, aby bylo možné vyhodnocovat spolehlivost a kvalitu dodávek? ▪ Provádí se systematicky vyhodnocování dodavatelů (dodací spolehlivost, cena, dodací pohotovost, kvalita dodávek a výkonů)? ▪ Jak dosahovat zkracování doby a časové náročnosti na přípravu nákupních analýz?
	Datové zdroje: ▪ ERP – nákupní moduly jsou zcela standardní součástí ERP pro analytiku nabízejí obvykle veškerý potřebný objem dat. ▪ SCM – poskytuje informace o aktuálním průběhu logistických řetězců a pro jejich analytiku. ▪ SRM – poskytuje komplexní informace o dodavatelích jako vstupy pro analytiku v rámci nákupního marketingu. ▪ eByznys (eProcurement) – poskytuje data z nákupních dokumentů předávaných dodavateli na bázi elektronické výměny dat.
	Poznámky k řešení: ▪ ERP a SRM podporují evidenci stávajících i potenciálních dodavatelů v takovém rozsahu, aby bylo možné analyzovat spolehlivost a kvalitu dodávek. Umožňuje provádět systematické vyhodnocování dodavatelů, tj. dodací spolehlivost, cenovou úroveň, dodací pohotovost, kvalitu dodávek a výkonů. ▪ Nákupní analytika v rámci ERP obsahuje kritéria pro vyhodnocení nákupní zakázky a hodnocení její ekonomiky.

6.3 Prediktivní nákupní analytika

Celkové schéma prediktivní analytiky v řízení nákupů dokumentuje Obrázek 6-2:



Obrázek 6-2: Prediktivní analytika v řízení nákupů

6.3.1 Cílové proměnné v řízení nákupů

- Objem nákupů za stanovený čas.
- Objem nákladů na zajištění nákupu zboží.
- Objem nákladů na externě poskytované služby.
- Počty pracovníků zajišťujících nákupní operace.
- Počet dodavatelů, počet aktuálně využívaných, potenciálních i v minulosti využívaných dodavatelů firmou.
- Dodací lhůta nákupů vyjadřuje dobu, která uplyne od předání objednávky firmou až po okamžik dostupnosti (pohotovosti) zboží.

6.3.2 Funkce prediktivní analytiky a plánování v řízení nákupů

Prediktivní analytika v řízení nákupů podporuje prognózování a plánování nákupů zboží a služeb pro potřeby firmy. V oblasti plánování nákupů má zejména připravovat podklady pro tyto operace:

- Predikce pro **plánování nákupů**.
 - Prediktory: objem prodejů za jednotlivé druhy zboží.
- Predikce **potřeby zboží** na dané období.
 - Prediktory: objem prodejů za jednotlivé druhy zboží.
- Predikce **nákladů na zboží** pro sestavení nákupního rozpočtu.


- Prediktory: počty zbožívých položek, rozsah a dislokace skladových kapacit.
- Predikce pro **operativní plánování nákupu**, které se realizuje ve vazbě na plánování prodeje.
 - Prediktory: objem prodejů za jednotlivé druhy zboží, počty zbožívých položek, rozsah a dislokace skladových kapacit.
- Predikce potřeby **externě nakupovaných služeb**:
 - Prediktory: počty a struktura externě zajišťovaných služeb, počty prodejen.
- Plánování potřeby **personálního zajištění** pro řízení nákupů:
 - Prediktory: disponibilní pracovní kapacity, počty prodejen, objem prodejů za jednotlivé druhy zboží.
- Predikce **počtů dodavatelů** a jejich struktury
 - Prediktory: počty zbožívých položek, počty prodejen, objem prodejů za jednotlivé druhy zboží.

6.4 Řešení prediktivní analytiky a plánování nákupů

	Analytické otázky: ▪ Jak lze co nejpřesněji a včas zjišťovat budoucí předpokládané potřeby zboží a služeb? ▪ Jak systematicky sledovat a regulovat stav zásob a zabezpečit jejich co nejefektivnější využití? ▪ Vyhodnocuje se pravidelně ekonomická a kvalitativní úspěšnost nákupů? ▪ Realizuje se ve firmě nákupní marketing? ▪ Vyhodnocuje se kvalita dodavatelů? ▪ Jak zajistit dostupnost informací o stavu a předpokládaném vývoji nákupního trhu? ▪ Jak efektivně provázat plánování nákupů na operativní plánování nákupů s provozem prodejen? ▪ Jak připravovat a realizovat plány nákupů pro různé časové horizonty vzhledem k situaci na trhu?
	Poznámky k řešení: ▪ Klíčovým vstupem pro plánování a prediktivní analytiku nákupů jsou predikce a odhady zákaznické poptávky na trhu, resp. výsledky prediktivní analytiky poptávky, tedy konkrétně predikce poptávky ovlivňuje plánování zásob, výběr dodavatelů nebo cash flow. ▪ Příklady uplatnění machine learning a vybraných funkcí a metod pro prediktivní analytiku v řízení nákupů: ○ Regresní analýzy pro predikce cílových proměnných jako objemu nákupů za období, objem nákladů určených na nákupy a další podle uvedených prediktorů. ○ Klasifikace dodavatelů – jejich rozřazení do stejnorodých tříd podle definovaných charakteristik (velikost, význam, cenová úroveň apod.), kde cílem je například identifikace rizikových dodavatelů nebo strategických partnerů. ○ Klasifikace nakupovaných zboží – podle standardních parametrů (druh, šarže, cena apod.). ○ Klasifikace nakupovaných služeb.


- **Clustering** – klastry dodavatelů podle dodávaného zboží, podle poskytovaných služeb, spolehlivosti, objemu dodávek v čase, kde cílem může být segmentace pro vyjednávání, nebo detekce anomálií v dodávkách.
- **Profilování** – profily dodavatelů s přiřazením všech klíčových charakteristik např. na bázi funkcí nákupního marketingu nebo aplikací SRM.

7. Skladová analytika



7.1 Deskriptivní skladová analytika

Souhrnný pohled na součásti deskriptivní skladové analytiky prezentuje Obrázek 7-1:



Obrázek 7-1: Deskriptivní skladová analytika

7.1.1 Dimenze skladové analytiky

	Základní dimenze:
	Čas – dimenze určující dobu přijetí zásob na sklad, dobu vyskladnění, pro sledování stavů zásob v čase, hodnocení vývoje disponibilních skladovacích kapacit apod.
	Regiony – struktura států a regionů pro analýzy rozmístění skladovacích kapacit hodnocení vzdáleností mezi sklady a pobočkami nebo prodejnami.
	Dimenze skladového hospodářství:
	Sklady – pro analýzy disponibilních skladovacích kapacit, např. s respektováním struktury vlastních případně pronajatých skladů pro zboží.
	Skladová místa – pro analýzy stavu, kapacity a vytížení skladovacích míst , členěných podle jejich typů.
	Skladové technologie – pro analýzy vybavenosti skladů a reálného využití skladovacích technologií.
	Obchodní dimenze:
	Dokumenty – pro analýzy počtů a struktur dokumentů realizovaných ve vztahu k řízení, skladů, případně dopravy na sklad.
	Zboží – pro přípravu a analýzy výkonu skladových operací podle struktury zboží, pro analýzy stavů zásob podle druhů zboží, pro analýzy rizika vyprodání zásob.
	Externí partneři:
	Poskytovatelé logistických služeb – pro analýzy portfolia poskytovaných služeb, jejich dostupnosti vzhledem k lokalitě skladů.

7.1.2 Metriky skladové analytiky

Analytika ekonomiky skladů je založena **na těchto hlavních metrikách** (dále v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.2.5.):

- **Stav zásob zboží** – objem zásob zboží v naturálních i peněžních jednotkách. S tím souvisí:
 - Průměrná zásoba – ukazatel, který udává průměrný počet měrných jednotek zásoby zboží.
 - Okamžitá zásoba.
 - Bezpečnostní zásoba.
 - Úbytek zásob.
 - Objem odepsaných zásob, např. vzhledem k expiraci.
- **Náklady na zásoby (držení zásoby)** – obsahují pouze ty složky nákladů, které se mění v závislosti na změně velikosti zásob a které jsou rozhodnutím o výši objednávky ovlivněny.
- **Bod pro doplnění zásob (ROP, Reorder Point)** = $(\text{průměrná denní potřeba zboží} \cdot \text{časový nárok dodání}) + \text{bezpečnostní zásoba}$. Pokud je stávající zásoba menší nebo rovna ROP, je nutné doplnění zásob.
- **Zisková marže na jednu korunu investovanou do položky zásob** – udává, jak je náročné firmě vydělat zisk na konkrétní položce zásob.
- **Dopravní náklady zásob** – dopravní sazba násobená průměrným stavem zásob.

- **Časová norma zásob** – ukazatel, který udává počet dní, během kterých vydrží průměrná zásoba zboží.
- **Rychlost obrátu zásob** – ukazatel, který udává počet obrátek průměrné zásoby zboží.
- **Obrátka zásob** – uvádí, kolikrát jedna položka zásob je nahrazená v průběhu roku (období).
- **Průměrný čas na vyprodání zásob.**
- **Poměr zásob k prodeji** = *průměrný počet všech jednotek v zásobách / počet prodaných jednotek.*
- **Inventurní rozdíly** = *skutečná hodnota zjištěná inventurou – evidenční hodnota.*

7.1.3 Funkce skladové analytiky

Analýzy skladů a skladových zásob firmy jsou realizovány v následujících skupinách:

- Analýzy **souhrnných ukazatelů řízení skladů.**
- Analýzy **stavů zásob** zboží podle jeho sortimentu expirace, analýzy průměrných zásob podle zboží apod.
- ABC analýzy pro **prioritizaci zásob.**
- Analýzy **nákladů na zásoby**, nebo držení zásoby, analýzy nákladů na dopravu do skladů.
- Analýzy počtů **zpracovávaných dokumentů** – dodacích listů, příjemek, výdejek atd.
- Analýzy počtů **skladových transakcí**, analýzy objemu transakcí v čase.
- Analýzy počtů **reklamací** a objemů reklamovaného zboží za dodavateli.
- Analýzy **v rámci inventur**, např. hodnocení inventurních rozdílů.
- Analýzy **časových norem zásob**, analýzy rychlosti obrátu zásob a obrátky zásob.
- Analýzy **časového vývoje zásob na skladech**,
- Analýzy **faktorů** ovlivňujících stavy zásob, hodnocení sezónních vlivů, zpracování indexů, kumulativních hodnot v čase apod.

7.2 Řešení deskriptivní analytiky skladů a skladových zásob




Analytické otázky:

- Vyhodnocuje se **průběh řízení jednotlivých dodávek** a na základě výsledků se realizují úpravy v plánu nákupů?
- Jak nastavit optimální **termíny pro objednávky** různých druhů zboží?
- Analyzuje se **nákladová náročnost** provozu a rozvoje skladů ve vztahu k požadavkům firmy?
- Jak lze minimalizovat **riziko vyprodání zásob** při neúměrně vysokých zásobách?
- Jak realizovat začlenění analýz skladových zásob **do byznys modelu a provozního modelu** firmy?
- Jak řešit **sezónnost** ve vazbě k úrovni zásob?
- Jaké existují aktuální **ekonomické a organizační problémy** spojené s řízením skladů a skladových zásob?
- Jak se realizuje analytická příprava **oceňování a přeceňování** skladových zásob?
- Co je obsahem a jak se provádí analytika v souvislosti **inventurami skladů**?

	Datové zdroje: ▪ ERP – moduly skladového řízení poskytují kompletní informace o skladových kapacitách, objemech zásob a pohybech na skladech. ▪ POS – zajišťují průběžné informace o prodeích a související aktualizace o pohybech zásob, snižování rizika přebytečných nebo chybějících zásob na skladech. ▪ WMS – zvyšuje kvalitu procesů plánování a organizování a současně efektivitu a flexibilitu při procesech vykládky, příjmu a vstupní kontroly, uskladnění zboží, vyskladnění a výstupní kontroly, kompletace a balení, expedice a dalších. ▪ SCM – informace o časech dodávek a jejich synchronizaci. ▪ eByznys (eProcurement, VMI) – poskytují informace vyplývající z nákupních dokumentů předávaných mezi dodavateli a retailovou firmou na bázi elektronické výměny dat. VMI (<i>Vendor Managed Inventory</i>) umožňuje dodavateli průběžně sledovat stav zásob svého zboží u obchodníka a podle toho je automaticky doplňovat.
	Poznámky k řešení: ▪ ERP podporuje detailní evidenci skladových položek zboží (pro naplnění dimenze zboží) a pohybů zásob na skladech s časovými značkami pro potřeby analytiky. ▪ Moduly ERP pro řízení skladů umožňují poskytovat data pro efektivní analytiku vytížení skladových kapacit v případě centrálních i detašovaných skladů. S tím souvisí i možnost vytváření virtuálních skladů, resp. logických skladů nad částmi fyzických skladů ▪ Předpokladem úspěchu je kvalitně nastavit systém označování skladových míst pro analytiku vytížení skladů a efektivní zaskladňování. ▪ Musí být nastavena pravidla a disponibilní data pro analytiku nakládání a likvidace obalů. ▪ Skladové moduly musí být svojí funkcionalitou provázány na analytiku zaměřenou na disponibilní skladové technologie a realizovaná příslušná rozhraní (zatladače atd.). ▪ WMS umožňuje s využitím přenosných počítačů, snímačů čárových kódů, RFID či bezdrátové sítě sběr dat do centrální databáze, komunikaci s uživateli, či prezentaci výsledků ve formě analytických reportů, což vede ke snížení nákladů na zásoby a sklady a míru chybovosti.

7.3 Prediktivní analytika v řízení skladů

Celkové schéma prediktivní analytiky v řízení skladů dokumentuje Obrázek 7-2:



Obrázek 7-2: Prediktivní analytika v řízení skladů

7.3.1 Cílové proměnné v řízení skladů

- Stavy skladových zásob podle zboží.
- Náklady na zásoby.
- Rychlost obrátu zásob.
- Obrátka zásob.
- Průměrný čas na vyprodání zásob.
- Objem skladovacích kapacit.
- Počty pracovníků pro zajištění skladových operací.

7.3.2 Funkce prediktivní analytiky a plánování v řízení skladů

- Predikce stavů zásob zboží podle jeho sortimentu a expirace.
 - Prediktory: normy zásob, struktura a počty nabízených druhů zboží.
- Predikce nákladů na zásoby.
 - Prediktory: počty prodejen, struktura a počty nabízených druhů zboží, počet dislokovaných skladů.
- Predikce potřeby pracovníků pro zajištění skladů.
 - Prediktory: disponibilní pracovní kapacity, počty prodejen.
- Predikce potřeby nových skladových kapacit.

- Prediktory: počty prodejen, struktura a počty nabízených druhů zboží, počet dislokovaných skladů.
- Plánování inventur.
 - Prediktory: počty prodejen, struktura a počty nabízených druhů zboží.

7.4 Řešení prediktivní analytiky a plánování skladů

	Analytické otázky: ▪ Jak se sledují a plánují disponibilní skladové kapacity? ▪ Je provoz skladů dostatečně personálně vybaven, jak se plánují personální kapacity pro sklady? ▪ Jak se plánují stavy zásob vzhledem k riziku vyprodání a na druhé straně k nákladům na zbytečně vysoké zásoby? ▪ Využívá se pro plánování zásob funkcionalita plánovacích nástrojů? ▪ Jak se řeší kooperace skladů s dodavateli na plánování dodávek a efektivní přejímce zboží?
	Poznámky k řešení: ▪ Plánování a predikce skladů vychází z klíčových vstupů, a to z predikce poptávky a odhadů objemu prodejů. ▪ Klíčovou otázkou je vyrovnání vztahu mezi nadměrnými zásobami („<i>overs-tock</i>“), které zbytečně váží kapitál, zvyšují náklady na držení zásob a rizika zastarání, případně expirace a na druhé straně nedostatečnými („<i>vyprodanými</i>“) zásobami („<i>stockouts</i>“), které naopak vedou k frustraci zákazníků a omezování tržeb. ▪ Plánování výše zásob vychází z průběžné aktualizace jejich stavu, kde předpokladem je integrace s aplikacemi a technologiemi POS, WMS a aplikacemi dodavatelů (Mitchel, 2025). ▪ Plánování a doplňování zásob může být vázáno na úzkou kooperaci s dodavateli na bázi systémů VMI (<i>Vendor Managed Inventory</i>) a na operativní elektronické výměně dat EDI a obdobných technologiích. ▪ Příklady uplatnění machine learning a vybraných funkcí a metod pro prediktivní analytiku v řízení skladů: ○ Regresní analýzy pro predikce skladových cílových proměnných jako stavů zásob, nákladů na zásoby zboží podle uvedených prediktorů. ○ Klasifikace skladů a skladových míst podle kapacity, místa, specifických skladových technologií. ○ Clustering – klastry skladových zásob podle druhů zboží, podle expirace, objemových charakteristik. ○ Modely založené na časových řadách zajišťují predikce požadovaného doplňování zásob na základě analýz historických dat, hodnocení trendů na trhu, sezónnosti, cyklickém chování zákazníků i na základě analýz náhodných jevů na trhu. Využívané modely jsou (Mitchel, 2025): ➤ ARIMA (<i>AutoRegresive Integrated Moving Average</i>), ➤ SARIMA (<i>Seasonal ARIMA</i>). ○ Modely založené na principech rozhodovacích stromů, které řeší nelineární vazby, kalendářní charakteristiky (všední dny, svátky), externí

vstupy (počasí, promo akce a další). Patří sem např. modely (Mitchel, 2025):

- *Random Forests*,
- *Gradient Boosting (XGBoost, LightGBM)*.


8. Analytika prodeje



Účelem analytiky prodeje je podporovat kvalitní řízení a dosahování příznivých ekonomických výsledků ve všech parametrech řízení prodeje a související spokojenosti zákazníků..

8.1 Deskriptivní analytika prodeje

Souhrnný pohled na součásti deskriptivní analytiky prodeje prezentuje Obrázek 8-1:



Obrázek 8-1: Deskriptivní analytika prodeje

8.1.1 Dimenze analytiky prodeje

	Základní dimenze:
	Čas – dimenze určující dobu prodeje, resp. prodejních aktivit, pro analýzy vývoje objemů prodeje v čase, pro sledování anomálií prodejů zboží a služeb v čase apod.
	Regiony – struktura států a regionů kde se realizují prodeje zboží a poskytovaných služeb, pro hodnocení úspěšnosti prodeje z teritoriálního hlediska, pro sledování nároků na servisní aktivity apod.
	Obchodní dimenze:
	Platební podmínky – pro analýzy objemu prodejů podle dohodnutých platebních podmínek vzhledem k velkým zákazníkům.
	Dodací podmínky – pro analýzy objemu prodejů podle dohodnutých dodacích podmínek.
	Dokumenty – pro analýzy počtů zpracovávaných prodejních dokumentů realizovaných ve vztahu k řízení prodejů.
	Obchodní kanály – pro analýzy úspěšnosti prodeje podle využívaných obchodních kanálů.
	Obchodní zástupci, agenti – pro analýzy výkonu a úspěšnosti obchodních zástupců v realizaci prodeje.
	Zboží – pro přípravu a analýzy výsledků a efektivnosti prodeje podle sortimentu nabízeného a prodáváného zboží.
	Služby – pro přípravu a analýzy výsledků a efektivnosti prodeje podle sortimentu poskytovaných a prodáváných služeb.
	Servisní činnosti – pro analýzy poskytovaných servisních činností realizované u zákazníků, podle regionů a skupin zákazníků.
	Reklamáce – pro analýzy reklamací zákazníků na prodávané produkty a služby.
	Posouzení reklamace – pro analýzy výsledků řešení reklamací – přijatá, odmítnutá, v posuzování apod.
	Podniková organizace:
	Podnikové procesy – pro analýzy procesů spojených s prodejem zboží a služeb, pro hodnocení zejména servisních procesů firmy.
	Podnikové útvary – pro analýzy jejich výkonů v oblasti prodeje, v oblasti zajišťování servisních činností apod.
	Ekonomické dimenze:
	Měny – pro analýzy tržeb podle struktury měn, pokud jsou pro danou firmu významné.
	Nákladové druhy – pro analýzy nákladů na prodejní aktivity firmy podle jednotlivých nákladových druhů (zboží, mzdy apod.).
	Externí partneři:
	Zákazníci firmy – pro analýzy struktury skupin zákazníků firmy z pohledu poskytovaných produktů i služeb.

8.1.2 Metriky analytiky prodeje

Analytika **ekonomiky prodeje** je založena **na těchto hlavních metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.2.3.1):

- **Tržby z prodeje zboží a služeb** – tržby podle prodejen, sortimentních položek, regionů, prodejců a podíly jednotlivých položek na celkových tržbách. S tím souvisí:
 - **Tržby na čtvereční metr prodejny.**
 - **Průměrná hodnota obchodní transakce** (ATV, Average Transaction Value) = $\text{Celkové příjmy} / \text{Počet obchodních transakcí}$.
- **Tržní podíl** – podíl obrátu firmy na celkovém tržním obrátu vztahený k relevantnímu trhu.
- **Náklady prodeje zboží a služeb** – náklady na prodej podle nákladových druhů, prodejních činností, zboží, služeb a zodpovědnosti.
- **Prodejní marže** – marže podle sortimentních položek, porovnání plánované a skutečně dosažené marže.
- **Průměrná míra slev.**
- **Sezónnost prodeje v %** = $(\text{Průměrný objem prodeje za dané období} / \text{Celkový průměrný objem prodeje}) * 100$.

8.1.3 Metriky výkonnosti prodeje

Analytika **výkonnosti prodeje** je založena **na těchto hlavních metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.2.3.2):

- **Počet servisních činností a jejich objem** v čase a v tis. Kč podle sortimentních položek, servisních techniků, regionů, zákazníků.
- **Počet a objem reklamací v tis. Kč** přijatých, odmítnutých, realizovaných podle sortimentních položek, typů reklamací, prodejen a prodejců.

8.1.4 Metriky prodeje prostřednictvím eShopu

Analytika prodeje **prostřednictvím eShopu** je založena **na těchto hlavních metrikách**:

- **Počet návštěvníků eShopu**, počet stránek, doba návštěv, podíl návštěv bez objednávky a další.
- **Počet prodaných produktů přes eShop** je celkový součet prodaných kusů jednotlivých produktů (kategorií produktů).
- **Zisk na produkt (v eShopu)** je rozdíl prodejní ceny a nákladů na konkrétní produkt vynásobený počtem prodaných produktů a udává celkový zisk dosažený na jednotlivých produktech.
- **Průměrná hodnota objednávky v eShopu** = $\text{celkové tržby} / \text{počet objednávek}$. Je to klíčová metrika pro řízení eShopu, která udává podíl celkových tržeb na počtu všech objednávek, je vhodná pro sledování účinnosti marketingových akcí a dává podklady pro nastavení systému objednávek.
- Počet **položek** na objednávku v eShopu = $\text{počet nakoupených položek (produktů)} / \text{počet objednávek}$. Je to počet položek objednaných při jednom nákupu a reprezentuje úspěšnost nastavení portfolia produktů, marketingu a webového rozhraní.
- **Průměrný čas potřebný na odbavení objednávky.**
- **Produktivita zaměstnanců na základě odbavených objednávek.**

8.1.5 Funkce analytiky prodeje

Analýzy prodejních aktivit firmy jsou členěny na tyto hlavní skupiny funkcí:

- Analýzy **souhrnných ekonomických metrik** prodeje podle vybraných dimenzí.
- Analýzy **tržeb** z prodeje zboží a služeb podle skupin zboží a služeb, podle skupin zákazníků, podle regionů, podle používaných druhů měn, případně podle platebních podmínek u větších zákazníků.

- Analýzy **nákladů** na prodej zboží a služeb podle nákladových druhů, podle dodavatelů, podle obchodních jednotek, prodejen, podle teritorií apod.
- Analýzy **prodejních marží**, tržního podílu, dodacích lhůt.
- Analýzy počtu a objemu **servisních činností** spojených s prodejem zboží podle typů servisních činností, podle zboží, podle zodpovědných útvarů, podle procesů servisu.
- Analýzy počtu a objemu **reklamací**, podle skupin zákazníků, podle regionů, podle výsledků řešení zákaznických reklamací.
- Analýzy **výkonnosti prodeje**, tj. počtu **zpracovávaných dokumentů** – poptávek, nabídek, smluv atd. a počtu a objemu obchodních transakcí prodeje.
- Analýzy **počtu zákazníků** a hodnocení jejich významu v pořadí podle realizovaných služeb, nakupovaného sortimentu apod.
- Analýzy struktury a počtů **obchodních zástupců**.
- Analýzy **obchodních poboček, prodejen** a jejich obchodní úspěšnosti apod.
- Analýzy **prodejních aktivit na eShopu**, např. hodnocení počtu prodaných produktů přes eShop, např. náhradních dílů, sledování zisků na produkt v eShopu, analýzy počtu a struktury položek na objednávk.
- Analýzy a hodnocení **tržeb na jednu návštěvu eShopu**, sledování délky návštěv webových stránek eShopu.
- **Analýzy časového vývoje objemu a struktury prodejů** podle obchodních jednotek, prodejen, podle zboží a služeb, podle teritorií apod.
- Analýzy **faktorů** ovlivňujících úroveň prodejů, hodnocení sezónních vlivů, zpracování indexů, kumulativních hodnot v čase apod.


8.2 Řešení deskriptivní analytiky prodeje

	Analytické otázky: ▪ Do jaké míry je nákladová náročnost obchodních a prodejních aktivit přiměřená požadavkům firmy? ▪ Jak se řeší vazby analytiky prodeje na marketing, sklady, nákup? ▪ Jaké obchodní kanály se využívají v oblasti prodeje nových zboží a služeb, jak se různé kanály analyzují? ▪ Jak efektivně zákazníci využívají prostory prodejen, jak efektivně se v prodejních pohybuji? ▪ Jak dosáhnout požadované flexibility prodejních analýz vzhledem k momentálním potřebám manažerů a specialistů v řízení prodeje? ▪ Provádí se systematicky vyhodnocování zákazníků? ▪ Jak je efektivní vystavování zboží na prodejních?
	Datové zdroje: ▪ ERP – poskytuje v modulech prodeje veškeré základní informace o nabízeném sortimentu zboží a služeb a obchodní a ekonomické informace o realizovaném prodeji. ▪ POS (obdobně samoobslužné pokladny, Scan & Go) – zajišťují průběžné monitorování výkonu prodeje, poskytují informace v reálném čase, jaká zboží a kde se prodávají. Umožňuje online identifikovat úspěšnost druhů zboží v prodeji. Zahrnují např. tyto údaje:

	○ SKU (<i>Stock Keeping Unit</i>), jedinečný identifikační kód, kdy prodejce vytváří své vlastní SKU, ○ kategorie zboží, ○ cena, ○ id prodejní transakce, čas a datum, ○ způsob platby, ○ id. prodejny, id. pokladny, ○ data zákazníka, v případě použití zákaznické aplikace nebo karty. ▪ CRM – obchodníci získávají a sdílejí detailní informace o zákaznících, o jejich požadavcích a potřebách, informace o obchodních příležitostech. Na základě těchto informací je možné realizovat kvalitní analytiku a uplatnit individuální přístup k jednotlivým zákazníkům. ▪ eByznys (eShop) – data pro analýzy uskutečněných prodejů prostřednictvím eShopu, data pro základní analýzy provozu eShopu (počty návštěv, doba návštěv apod.). ▪ IoT – data snímaná senzory a shromažďovaná prostřednictvím IoT pro analýzy provozu prodejny, analýzy pohybů zákazníků po prodejně, optimalizace umístění zboží na prodejně, využívání „chytrých regálů“ snižujících riziko nedostatku daného zboží v regálu a snížení prodejů a další.
	Poznámky k řešení: ▪ V souvislosti s analytikou pro řízení prodeje doplníme 2 videa: ○ Video: řízení prodeje s využitím funkcionality CRM [Dynamics 365, CRM] ○ Video: řízení prodeje, služby pro zákazníky [Dynamics 365, prodej] ▪ ERP systémy zahrnují silnou podporu mobilních technologií, která posilují operativnost pracovníků prodeje při realizaci prodeje a poskytují další potřebná data pro analytiku. ▪ K jednotlivým nabízeným a poskytovaným službám existuje informační podpora zákazníků dostupná na firemním portálu většinou integrovaným s ERP. V některých případech prodejní moduly podporují i konfigurování požadovaných zboží a služeb zákazníkem přímo na portále. ▪ Komplexní informace o potenciálních i realizovaných obchodních aktivitách vytvářejí základ pro analýzy prodejní výkonnosti a tím její zvyšování, umožňují vytvářet prognózy prodeje, sledovat obchodní aktivity a jejich efektivitu atd. ▪ V některých případech lze uplatnit i metody řízení výkonnosti prodeje (<i>SPM, Sales Performance Management</i>). SPM představuje komplex zejména analytických a plánovacích kapacit a úloh, které společně zahrnují funkcionalitu pro přípravu a optimalizaci prodejních plánů, alokování prodejních aktivit podle teritorií, nastavování prodejních kvót, optimalizaci provizních pravidel a programů.

8.3 Prediktivní prodejní analytika

Celkové schéma prediktivní analytiky v řízení prodeje dokumentuje Obrázek 2-5:



Obrázek 8-2: Prediktivní analytika v řízení prodeje

8.3.1 Cílové proměnné v řízení prodeje

- Počet zákazníků firmy zahrnuje všechny zákazníky firmy.
- Tržby z prodeje zboží a služeb a podíly jednotlivých položek na celkových tržbách.
- Náklady prodeje zboží a služeb.
- Prodejní marže podle sortimentních položek.
- Počet servisních činností a jejich objem.
- Počty pracovníků pro zajištění prodeje.
- Počet prodaných produktů přes eShop.

8.3.2 Funkce prediktivní analytiky a plánování v řízení prodeje

- Predikce **počtů zákazníků** a současně odhady možných **ztracených zákazníků**.
 - Prediktory: objem tržeb podle zákazníků na základě např. POS.
- Predikce **vývoje prodeje**, kde se zohledňují zkušenosti se specifickým chováním zákazníků.
 - Prediktory: počet obyvatel v regionech, počet druhů zboží podle skupin, struktura poskytovaných služeb zákazníkům.
- **Predikce nákladů na prodej** zboží a služeb.
 - Prediktory: objemy prodeje zboží, objemy poskytovaných služeb zákazníkům.
- **Operativní plánování prodeje** na určená časová období.

- Prediktory: počet druhů zboží podle skupin, struktura poskytovaných služeb zákazníkům.
- Predikce **potřeby pracovní síly pro** prodejní aktivity:
 - Prediktory: disponibilní pracovní kapacity, objem prodeje.
- Predikce **uplatňování slev** na zboží a služby.
 - Prediktory: Používaná míra slev, jednotkové ceny poskytovaných služeb.
- Predikce **objemů prodeje na eShopu**.
 - Prediktory: počet druhů zboží podle skupin.

8.4 Řešení prediktivní analytiky a plánování prodeje

	Analytické otázky: ▪ Jak racionálně plánovat pracovní kapacity na zajištění prodeje? ▪ Jak zajistit dostupnost informací o stavu a předpokládaném vývoji trhu? ▪ Jak průběžně analyzovat odchyly od vytvořeného plánu prodeje? ▪ Jak nastavit různé možnosti alokace plánovaných hodnot prodejů na útvary, resp. prodejny? ▪ Jak efektivně plánovat slevové akce při minimalizaci rizik? ▪ Jak racionálně plánovat objemy prodeje na eShopu?
	Poznámky k řešení: ▪ Podstatnou součástí v analytice prodeje je cenová analytika a predikce cen a cenového vývoje (kapitola 10). ▪ Analytika ztráty zákazníka („churn“) se váže na situace, kdy zákazník přestal po určitou dobu u obchodníka nakupovat. ▪ A/B testování umístění zboží – je porovnání dvou variant umístění zboží na prodejně a jejich vyhodnocení. ▪ Příklady uplatnění machine learning a vybraných funkcí a metod pro prediktivní analytiku v řízení prodeje: ○ Regresní analýzy (lineární i vícenásobná regrese) pro predikce objemu tržeb zboží, nákladů na prodej a další cílové proměnné podle výše uvedených prediktorů. ○ Clustering: klastry zákazníků retailové firmy podle typu nakupovaného zboží, věrnostního programu, prodejny apod. ○ Klasifikace zákazníků – jejich rozřazení do stejnorodých tříd a odhad pravděpodobnosti správnosti takového zařazení pro každého zákazníka. ○ Klasifikace prodávaných zboží – obvykle podle kategorií nebo katalogu zboží. ○ Klasifikace poskytovaných služeb – posouzení správnosti klasifikace uvedením pravděpodobnosti správného členění. ○ Identifikace anomálií („anomaly detection“), např. pro identifikace mimořádných prodejů nebo podvodů. ○ Profilování – specifikace klíčových charakteristik zákazníků z pohledu přístupů k zajištění a řízení prodeje.


- **Rozhodovací stromy** a segmentace zákazníků jsou základem pro analýzy zákazníků vzhledem k riziku odchodu („churn“).
- **Neuronové sítě** – pro komplexnější a náročnější úlohy predikce, např. pro plánování slev na zboží a služby.

9. Analytika logistiky



9.1 Deskriptivní analytika logistiky

Souhrnný pohled na součásti deskriptivní analytiky logistiky prezentuje Obrázek 9-1:



Obrázek 9-1: Deskriptivní analytika logistiky

9.1.1 Dimenze analytiky logistiky

	Základní dimenze:
	Čas – dimenze určující dobu požadavků na logistiku, pro analýzy vývoje požadavků na logistické a zejména dopravní služby v čase, pro sledování výrazných výkyvů objemu požadavků v čase.
	Regiony – struktura států a regionů, kde se realizují logistické, zejména dopravní služby, pro analýzy výkonu logistických služeb vzhledem k vzdálenostem a regionálního rozložení obchodních jednotek, skladů apod.
	Podniková organizace:
	Podnikové procesy – pro analýzy objemu nákladů a pracnosti vzhledem k logistickým procesům firmy.
	Činnosti – pro analýzy nákladů a pracnosti vzhledem k jednotlivým, případně jen vybraným činnostem v rámci logistiky.
	Podnikové útvary – pro analýzy podílu (zejména pracnosti) jednotlivých útvarů, resp. prodejen na aktivitách zajišťujících logistiku retailové firmy.
	Externí partneři:
	Dodavatelé – pro analýzy dodavatelů podílejících se na logistických procesech v rámci retailové firmy.
	Poskytovatelé logistických služeb – pro analýzy nákladů a objemu práce podle specializovaných poskytovatelů logistických služeb.
	Dimenze logistiky:
	Dopravní prostředky – pro analýzy vlastních dopravních prostředků firmy zejména k hodnocení disponibilních dopravních kapacit a nákladů na logistiku.
	PHM – pro hodnocení spotřeby PHM pro logistické procesy, pro analýzy vlastních zásob PHM a možností jejich zajištění.

9.1.2 Metriky analytiky logistiky

Analytika pro řízení logistiky je založena **na těchto hlavních metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.2.6):


- **Náklady na logistiku** = náklady na řízení a systém logistiky + náklady na zásoby + náklady na skladování + náklady na dopravu + náklady na manipulaci.
- **Náklady na dopravu** – jsou náklady na dopravu podle jednotlivých přepravních a dopravních zakázek + pojistné.
- **Průměrné náklady na kilometr.**
- **Výkon dopravy** – vyjádřený v tunokilometrech.
- **Spolehlivost dopravce** – sleduje, zda vybraný dodavatel dopraví dodávku včas, v kvalitě a v požadovaném množství v poměru k celkovému množství všech jeho dodávek.
- **Včasné naskladnění** – počítá se podle dopravce, slouží jako podklad pro hodnocení efektivity dopravce.
- **Podíl využití nákladního auta** – počítá se jako podíl váhy nakládaného zboží na celkové kapacitě.
- **Celkový počet realizovaných požadavků na logistiku** za stanovené období.
- **Průměrný čas doručení zboží. Procento včasných doručení.**

- **Hodnocení spokojenosti zákazníků s dopravou.**


9.1.3 Funkce analytiky logistiky

Analýzy logistických potřeb a jejich zajištění ve firmě představují tuto funkcionalitu:

- Analýzy **souhrnných ukazatelů** na zajištění logistiky firmy.
- Analýzy **nákladů na dopravu** podle poskytovatelů dopravy, regionů apod. (Obrázek 9-2).
- Analýzy **výkonu dopravy** v tunokilometrech podle útvarů a poskytovatelů dopravy.
- Analýzy **spolehlivosti dopravců**, zejména včasného naskladnění.
- Analýzy **poruch a jejich příčin** v logistickém řetězci.
- Analýzy **využití nákladních aut** vzhledem k jejich kapacitám.
- Analýzy **objemu a nákladů** na dopravu podle typů dopravy (Obrázek 9-3).
- Analýzy **počtu požadavků na logistiku**, objemu realizovaných výsledků logistiky.
- Analýzy počtu a **objemu reklamací** ve vztahu k externím dopravcům podle dopravců, podle typů reklamací, podle výsledků jejich řešení.
- Analýzy **časového vývoje logistických operací** podle definovaných období.
- Analýzy **faktorů** ovlivňujících aktivity logistiky, hodnocení sezónních vlivů, regionální vlivy, úroveň poptávky po zboží apod.



Obrázek 9-2: Příklad 1: Analytika nákladů na dopravu podle poskytovatelů dopravy (Zdroj: Houdek, 2024)



Obrázek 9-3: Příklad 2: Analytika objemu a nákladů na dopravu podle typů dopravy (Zdroj: Houdek, 2024)

9.2 Řešení deskriptivní analytiky v řízení logistiky


	Analytické otázky: - Do jaké míry se analyzuje nákladová náročnost realizovaných logistických aktivit ve vztahu k požadavkům firmy? - Zjišťují a analyzují se ekonomické a mimoekonomické efekty dopravních operací? Kde jsou cesty jejich zvyšování? - Analyzuje se průběžně spotřeba PHM? - Jak optimalizovat dopravní cesty? - Jak racionalizovat vnitropodnikovou dopravu?
	Datové zdroje: ERP – automatizují chod logistiky firmy, nabízejí současně i základní funkcionality dopravy. SCM – v rámci celého dodavatelského řetězce umožňuje lépe optimalizovat a koordinovat jednotlivé zakázky, optimalizovat dopravní cesty mezi subjekty v řetězci a současně poskytovat komplexní data pro analytiku řetězce. Spediční aplikace – spediční dopravní systémy mají podstatné efekty v oblasti dopravy a zásilkovství. Poskytují pro analytiku data, která se každých pár minut aktualizují, ve kterých je u přeprav uvedena jejich hmotnost, rozměry a datum požadované realizace a u nabídek vozů jejich rozměry, nosnost, typ vozu a datum. eByznys (eProcurement) – zkvalitňuje a urychluje zásobovací procesy retailové firmy na základě elektronické výměny dat, u velkých firem vytváří pro analytiku obrovské datové zdroje.

**Poznámky k řešení:**

- ERP často v této oblasti pokrývá část funkcionality, takže **specializované aplikace** je doplňují, ale předpokládá to je kvalifikovaně vybrat.
- V souvislosti s ERP je nutné nastavit hodnocení efektivnosti **zajišťování logistiky vlastním prostředky, nebo externími poskytovateli** a vytvářet podklady pro příslušná rozhodnutí.
- V logistických modulech musí být zahrnuto i **sledování průběhu** jednotlivých zakázek a hodnocení jejich efektivnosti ve vazbě na externí poskytovatele logistických služeb.
- Úzkým propojením různých firem na bázi SCM a informačních technologií **se posiluje váha celého takového komplexu** při získávání zakázek a při výběrových řízeních.
- Díky propojení různých firem v dodavatelském řetězci a řízení zakázek v celém jeho rámci je možné podstatně **pružněji a rychleji reagovat na požadavky** zákazníků včetně kvantitativních nebo sortimentních změn v zakázkách.
- **Dosažení potřebných parametrů řešení v rámci SCM**, zejména jeho analytiky zejména v čase dodávek, pružnosti, spolehlivosti a kvality souvisejících služeb přináší redukci nákladů na řízení řetězců, na skladování zboží, manipulaci a dopravu zboží.
- Předpokladem kvalitního řešení SCM je **shoda na standardech a technologiích** pro zajištění komunikace mezi jednotlivými subjekty.
- Pro eProcurement musí být nastavena **shoda mezi retailovou firmou a dodavateli** o komunikačních standardech a způsobu komunikace.

9.3 Prediktivní analytika v logistice

Celkové schéma prediktivní analytiky ve finančním řízení dokumentuje Obrázek 9-4:



Obrázek 9-4: Prediktivní analytika v logistice

9.3.1 Cílové proměnné v řízení logistiky

- Objem aktivit spojených s logistikou.
- Náklady na logistiku jsou náklady na zajištění celého procesu logistiky ve firmě.
- Náklady na dopravu.
- Výkon dopravy vyjádřený v tunokilometrech.
- Podíl využití nákladního auta se počítá jako podíl váhy nakládaného zboží na celkové kapacitě.

9.3.2 Funkce prediktivní analytiky a plánování logistiky

Prediktivní analytika v řízení logistiky firmy má podporovat následující aktivity:

- Predikce **aktivit logistiky** podle různých hledisek pro různé časové horizonty.
 - Prediktory: počty požadavků na logistiku.
- Predikce **nákladů** na logistiku.
 - Prediktory: počty požadavků na logistiku.
- Predikce potřeby **externích poskytovatelů** logistických služeb.
 - Prediktory: počet externích poskytovatelů logistiky podle typů.
- Predikce rozvoje **vlastního vozového parku**.
 - Prediktory: počty vlastních dopravních prostředků, počty využívaných dopravních prostředků.

9.4 Řešení prediktivní analytiky v řízení logistiky

	Analytické otázky: ▪ Jak zvýšit úspěšnost a výkonnost logistiky díky kvalitnímu plánování dopravních cest? ▪ Jak zajistit dostupnost informací o stavu a předpokládaném vývoji trhu poskytovatelů dopravy? Jak racionálně plánovat a vybírat kvalitní dopravce? ▪ Jak co nejpřesněji a včas zjišťovat budoucí předpokládané potřeby logistiky? ▪ Jak respektovat dislokaci firmy a realizovat konsolidaci plánů logistiky vzhledem k různým obchodním jednotkám a útvarům? ▪ Jak správně nastavit zodpovědnosti a kompetence za přípravu plánů logistiky?
	Poznámky k řešení: ▪ Prediktivní analytika v logistice směřuje zejména ke zvýšení spolehlivosti logistických řetězců, snižování časových nároků jednotlivých dodávek, vytváření konkurenčních výhod. ▪ Otázkou pro plánování logistiky je posuzování disponibilních vlastních a externích dopravních kapacit a další prostředků pro zajištění logistiky. ▪ Zásadní předpoklad řešení prediktivní analytiky je zde definování metrik výkonnosti poskytovatelů, k nimž patří (Mitchel, 2025): ○ Včasné dodávky, (<i>OTD, On Time Delivery</i>), – procento dodávek uskutečněných ve stanovených termínech. ○ Splnění množství (<i>Fill Rate</i>) – podíl objednaného množství, které dodavatel dodal již v první dodávce. ○ Splnění kvality (<i>Quality Rate</i>) – procento dodávek, které splnily stanovené parametry kvality. ○ Variabilita časů dodávek (<i>Lead Time Variability</i>) – určuje spolehlivost dodavatele. ○ Diference nákladů (<i>Cost Variance</i>) – rozdíly mezi dohodnutými a skutečnými náklady, díky příplatkům, penále apod. ▪ Příklady uplatnění machine learning a vybraných funkcí a metod pro prediktivní analytiku v řízení logistiky: ○ Regresní analýzy (lineární i vícenásobná regrese) pro predikce potřeby objemu logistických zejména dopravních služeb, predikce variability a spolehlivosti časů dodávek, predikce nákladů, predikce potřeby externích poskytovatelů. ○ Klasifikace vlastních a nakupovaných logistických služeb. ○ Klasifikace rizikových dodavatelů a dodávek. ○ Klasifikace vlastních dopravních prostředků podle druhů, kapacity, výrobce apod. ○ Clustering: klastry poskytovatelů logistických služeb podle cenové úrovně, dodacích podmínek, platebních podmínek, objemu poskytovaných služeb v čase, spolehlivosti služeb. ○ Profilování specifikace komplexních charakteristik poskytovatelů logistických služeb z pohledu přístupů k zajištění a řízení požadavků na logistiku, resp. dopravu.


- **Optimalizace dopravních cest** (VRP, *Vehicle Routing Problem*) zahrnuje (Mitchel, 2025, upraveno):
 - Kapacitní optimalizaci vzhledem ke kapacitám dopravních prostředků.
 - Časovou optimalizaci, kdy dodávky se musí realizovat v určitých časových úsecích.
 - Optimalizaci míst nakládky a vykládky.

10. Cenová analytika



10.1 Deskriptivní cenová analytika

Souhrnný pohled na součásti deskriptivní cenové analytiky prezentuje Obrázek 10-1:



Obrázek 10-1: Deskriptivní cenová analytika

10.1.1 Dimenze cenové analytiky

	Základní dimenze:
	Čas – dimenze určující dobu platnosti ceníků zboží a služeb, pro analýzy cenového vývoje na trhu i v rámci retailové firmy.
	Regiony – struktura států a regionů pro případné sledování cenových rozdílů zboží a služeb mezi státy, případně regiony.
	Externí partneři:
	Dodavatelé – pro analýzy cenové úrovně zboží a služeb podle jednotlivých dodavatelů a pro tvorbu nákladových cen.
	Zákazníci firmy – pro přípravu a analýzy cen podle jednotlivých zákazníků, resp. skupin zákazníků.
	Konkurence – pro analýzy konkurentů retailové firmy jejich nastavené cenové úrovně, pro přípravu ceníků vzhledem ke konkurenceschopnosti firmy.
	Obchodní dimenze:
	Obchodní kanály – pro analýzy vlivů různých obchodních kanálů na tvorbu cen.
	Obchodní segmenty – pro hodnocení charakteru a rozvoje různých obchodních segmentů na tvorbu ceny.
	Zboží – pro analýzy cenotvorby vzhledem k různým druhům zboží.
	Služby – pro analýzy cenotvorby vzhledem k různým druhům služeb.

10.1.2 Metriky cenové analytiky

Analytika pro řízení cen a cenové politiky je založena **na těchto hlavních metrikách:**

- Úroveň **zákaznické poptávky** vzhledem k vlastní nabídce.
- **Náklady prodeje** podle skupin zboží a služeb.
- Nastavené **nákladové ceny** podle zboží a služeb.
- Nastavené ceny zboží a služeb **podle cenové hladiny konkurence**.
- **Průměrná marže**.
- **Cenová elasticita vzhledem k poptávce**.
- **Průměrná míra slev**.

10.1.3 Funkce cenové analytiky


- **Analýzy nákladů** na zboží a služby, jako základ pro stanovení nákladových cen.
- Analýza **cen konkurence** podle tržních segmentů a příprava ceníků s respektováním konkurence.
- Analýza cenotvorby **pro prostředí eShopu**, na základě posouzení cenové úrovně ostatních eShopů.
- Analytická podpora **dynamické tvorby cen**.
- Analýzy **časového vývoje** cen podle zboží, služeb, regionů.
- Analýzy **podstatných faktorů** ovlivňujících tvorbu cen, vývoje poptávky a nabídky v obchodních segmentech, vlivy různých obchodních kanálů apod.

10.2 Řešení deskriptivní cenové analytiky

	Analytické otázky: ▪ Jsou stanovovány adekvátní ceny pro segmenty trhu, resp. skupiny zákazníků? ▪ Jaká jsou k dispozici vstupní data pro analytiku cen? ▪ Jak řešit cenovou analytiku vzhledem k otázce, které typy cen budou pro danou retailovou firmu prioritní? ▪ Jak realizovat analytiku cen pro zboží na eShopech? ▪ Jak se bude promítat cenová analytika do přípravy ceníků? ▪ Jak často se musí cenová analytika realizovat a kdo bude za ní zodpovědný? ▪ Jaké jsou třeba analytické funkce vzhledem k nastavování slev.
	Datové zdroje: ▪ ERP – obsahuje standardní a komplexní data o zboží, službách a jejich cenících. ▪ CRM – umožňuje pro analytiku cen systematické sledování a hodnocení cenové nabídky na trhu a sledování cenové úrovně konkurence. ▪ SRM – poskytuje pro analytiku cen profily dodavatelů a cenové parametry dodávaného zboží, případně služeb.
	Poznámky k řešení: ▪ Předpokladem úspěšnosti CRM je nastavení prostředí, kdy pracovníci z marketingu i obchodu jsou připravení a ochotní sdílet informace o cenách na trhu partnerů i konkurentů a poskytují je pro cenovou analytiku. ▪ SRM poskytuje potřebná data pro systematické analýzy dodavatelů, jejich cenovou úroveň s provázáním na ostatní parametry, jako dodací spolehlivost, kvalita dodávek a další.

10.3 Prediktivní cenová analytika

Celkové schéma prediktivní analytiky v řízení cen a v cenotvorbě dokumentuje Obrázek 10-2:



Obrázek 10-2: Prediktivní analytika v řízení cen

10.3.1 Cílové proměnné v řízení cen

- Objem nákladů na prodej zboží a služeb.
- Objem zákaznické poptávky.
- Ceny zboží a služeb.
- Marže k cenám zboží a služeb.

10.3.2 Funkce prediktivní analytiky a plánování cen

- Predikce **nákladů** na prodej zboží a služeb:
 - Prediktory: objemy prodeje zboží, objemy poskytovaných služeb zákazníkům.
- Predikce **zákaznické poptávky**:
 - Prediktory: sortiment nabízených zboží, struktura poskytovaných služeb, stav konkurence.
- Predikce **cen** za zboží a služby.
 - Prediktory: jednotkové ceny poskytovaných služeb, používaná míra slev.

10.4 Řešení prediktivní analytiky a plánování cen

	Analytické otázky: ▪ Jak racionálně plánovat úroveň cen vzhledem k zákaznické poptávce? ▪ Jak plánovat ceny podle informací o stavu a předpokládaném vývoji trhu? ▪ Jak plánovat nákladově založené ceny? ▪ Jak racionálně řešit slevové akce vzhledem k úrovni cen? ▪ Jak racionálně plánovat ceny na zboží na eShopu?
	Poznámky k řešení: ▪ Součástí řešení je analýza cenové sensitivity, tedy vnímání cenových pohybů zákazníci, založené např. na informacích z POS. ▪ Analytika cen je základem i pro dynamickou tvorbu cen, ale v řadě případů se dynamická tvorba cen příliš nedoporučuje s ohledem na negativní reakce zákazníků. ▪ Změny cen je ale nezbytné zodpovědně včas promítat do plánovaných a publikovaných ceníků, právě s ohledem na důvěru zákazníků a jejich rychlou a spolehlivou orientaci. ▪ Predikce cenové elasticity poptávky (PED, Price Elasticity of Demand) – sleduje procentuální změnu poptávky po zboží na základě jednoho procenta změny v ceně (Mitchel, 2025). Je založena na následující kalkulaci: ○ $PED = \% \Delta Q / \% \Delta P$, kde (Q je množství, P je cena). ○ Elastická poptávka, kde $PED > 1$, množství poptávaného zboží odpovídá více než proporcionálně na změnu ceny, zákazníci jsou cenově sensitivní. ○ Neelastická poptávka, kde $PED < 1$, množství poptávaného zboží odpovídá neproportionálně na změnu ceny, zákazníci jsou méně cenově sensitivní. ▪ Analýza indexu cenové pozice (PPI, Price Position Index) je založena na následující kalkulaci (Mitchel, 2025): ○ $PPI = (Cena\ retailové\ firmy / Medián\ konkurenčních\ cen) * 100\ %$. ○ Z kalkulace logicky vyplývá, pokud je PPI menší než 100 %, je firma levnější než konkurence, v opačném případě dražší. ▪ Příklad uplatnění machine learning a vybraných funkcí a metod pro prediktivní analytiku v řízení cen: ○ Machine Learning – zajišťuje, že ceny na základě předdefinovaných pravidel budou v reálném čase, resp. blízko reálnému času odpovídat následujícím aktuálním faktorům (Mitchel, 2025): ➤ úroveň poptávky, ➤ úroveň konkurence, ➤ charakteristika zákazníků, ➤ komplex externích faktorů (sezóna, počasí apod.), ➤ další faktory.

- **„Reinforcement Learning“** představuje algoritmy určující ceny na bázi permanentního hodnocení zpětných vazeb z trhu a založené na vyrovnavání krátkodobých efektů tržeb a dlouhodobé spokojenosti zákazníků.


11. Analytika majetku, investic, údržby a zajištění energiemi



Účelem analytiky majetku, investic, údržby a zajištění energiemi je zejména poskytovat pracovníkům v daných oblastech řízení kvalitní **analytické podklady** pro rozhodování o stavu majetku, nárocích na údržbu a na přípravu nových investičních akcí, pro uplatnění optimálních odpisových modelů a zajištění retailové firmy energiemi.

11.1 Deskriptivní analytika majetku

Souhrnný pohled na součásti deskriptivní analytiky majetku prezentuje Obrázek 11-1:



Obrázek 11-1: Deskriptivní analytika majetku

11.1.1 Dimenze analytiky majetku

	Základní dimenze:
	Čas – dimenze sloužící pro analýzy vývoje objemu a struktury majetku firmy podle jednotlivých druhů.
	Regiony – struktura států a regionů pro analýzy rozmístění majetku a např. hodnocení jeho využití, nároků na obnovu apod.
	Dimenze majetku:
	Majetek – pro analýzy majetku firmy podle jednotlivých druhů. V kombinaci s dimenzí stavu majetku slouží pro sledování využití majetku, plánování oprav, náhrady apod.
	Úroveň stavu majetku – pro analýzy kvalitativního a technického stavu jednotlivých druhů majetku.
	Podniková organizace:
	Podnikové útvary – pro analýzy zodpovědnosti za majetek a správy majetku podle útvarů retailové firmy.
	Ekonomické dimenze:
	Nákladové druhy – pro analýzy nákladů na pořízení a správu majetku podle druhů (materiál, odpisy apod.).

11.1.2 Metriky analytiky majetku

Analytika pro řízení majetku je založena **na těchto hlavních metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.3.2 a 4.3.3):

- **Celkový objem majetku firmy** – podle druhů majetku a technických parametrů, vyjádřený v měrných jednotkách a Kč.
- **Náklady na pořízení a správu majetku.**
- **Objem nájemného.**
- **Objem nájemného vzhledem k obratu.**
- **Objem odpisů** majetku podle odpisových kategorií.
- **Úroveň využití** majetku je určovaná obvykle expertním odhadem.
- **Pozemky** – rozsah pozemků v daných jednotkách (čtvereční metry, kilometry, hektary).
- **Budovy** – využitelná plocha budov ve čtverečních metrech.
- **Zařízení** – počet jednotlivých druhů zařízení.
- **Dopravní prostředky** – počet dopravních prostředků podle typů.

11.1.3 Funkce analytiky majetku


Analýzy majetku firmy představují např. tuto funkcionalitu:

- Analýzy **souhrnných ukazatelů majetku retailové firmy.**
- Analýzy **objemu majetku firmy** v naturálním i finančním vyjádření.
- Analýzy objemu **odpisů** majetku a jejich vlivu na potřebu obnovy jednotlivých druhů majetku.
- Analýzy úrovně **využití majetku** a další.

- Analýzy **ukazatelů dlouhodobého hmotného majetku** zahrnuje analýzy rozsahu pozemků, objemu majetku v budovách, dopravních prostředcích, v inventáři.
- Analýzy **ukazatelů dlouhodobého nehmotného majetku**, pokud jsou významné, zahrnující patenty, licence, autorská práva.

11.2 Deskriptivní analytika investic a údržby

Souhrnný pohled na součásti deskriptivní analytiky investic a údržby prezentuje Obrázek 11-2:



Obrázek 11-2: Deskriptivní analytika investic a údržby

11.2.1 Dimenze analytiky investic a údržby

	Základní dimenze:
	Čas – dimenze sloužící pro sledování vývoje požadavků na investice, doby jejich realizace, časové charakteristiky úvěrů, časové charakteristiky údržbových aktivit apod.
	Regiony – struktura států a regionů, kde se realizují jednotlivé investice, pro analýzy investičních aktivit a jednotlivých akcí údržby.
	Dimenze investic a údržby:
	Majetek – pro analýzy majetku firmy podle jednotlivých druhů a jejich stavu vzhledem k nezbytným nebo plánovaným investicím.
	Úroveň stavu majetku – pro analýzy kvalitativního a technického stavu jednotlivých druhů majetku vzhledem k potřebě nových investic.
	Druhy investic – pro analýzy objemu a významu investic podle druhů, pro analýzy plánovaných, aktuálně realizovaných nebo již uskutečněných investic firmy.

	Druhy údržby – pro analýzy objemu, pracnosti a nákladů na plánované a realizované aktivity údržby.
	Externí partneři:
	Dodavatelé – pro analýzy investic a údržby z pohledu externích dodavatelů, kteří se na nich podílejí.
	Poskytovatelé služeb – pro analýzy investic z pohledu poskytovatelů služeb spojených s investicemi i s aktivitami údržby.

11.2.2 Metriky analytiky investic a údržby

Zahrnuje metriky **základní metriky i metriky** ve vztahu k **metodám sledování návratnosti investic** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.3.4):

- **Objem investic** ve finančním vyjádření.
- **Objem oprav a údržby** – objem plánovaných a realizovaných oprav a údržby vyjádřený v Kč a normohodinách.
- **Výnosnost investice, resp. ROI – Return on Investment** – poměr zisku (přebytku výnosů nad cenou investice) a finančním objemem investice.
- **Čistá současná hodnota, resp. NPV – Net Present Value** – diskontované budoucí peněžní toky k současnému období.
- **Ukazatel doby splacení investice (PM – Payback Method)** – slouží k odhadu časového intervalu, po jehož uplynutí je investice splacena kumulovaným ročním tokem peněz (cash flow).


11.2.3 Funkce analytiky investic a údržby

Analytika v oblasti řízení investic a údržby představuje tyto skupiny funkcí:

- Analýzy **souhrnných ukazatelů** investic a údržby.
- Analýzy **objemu investic, objemu oprav** a údržby v pracnosti a nákladech.
- Analýzy **návratnosti investic** založených na rentabilitě investic (ROI), čisté současné hodnotě investice (NPV), době splacení investice.
- Analýzy **časového vývoje** investic a objemu údržby.
- Analýzy škály **faktorů**, které ovlivňují přípravu a realizace investičních akcí a akcí údržby.

11.3 Deskriptivní analytika energií

Souhrnný pohled na součásti deskriptivní analytiky v řízení energií prezentuje Obrázek 11-3:



Obrázek 11-3: Deskriptivní analytika v řízení energií

11.3.1 Dimenze analytiky energií

	Základní dimenze:
	Čas – dimenze sloužící pro vývoj potřeby a spotřeby energií podle jejich druhů.
	Regiony – pro analýzy energetické náročnosti firmy podle regionálního rozdělení, pro sledování ekonomické efektivity zajištění energiemi vzhledem k regionům.
	Dimenze majetku, investic a energií:
	Druhy energií – pro analýzy potřeby a spotřeby energií podle jejich druhů a pro hodnocení energetické náročnosti objektů.
	Měřidla – pro analýzy instalovaných měřidel v rozlišení podle druhů energií.
	Dodavatelé energií – pro analýzy poskytovatelů energií, jejich služeb a cenové úrovně.
	Podniková organizace:
	Podnikové útvary – pro analýzy energetické potřeby a spotřeby za jednotlivé útvary, prodejny.
	Dimenze majetku:
	Majetek – pro analýzy jednotlivých druhů majetku podle jejich energetické náročnosti.

11.3.2 Metriky analytiky energií


Analytika pro řízení energií je založena **na těchto hlavních metrikách** (detailněji v publikaci [\[Oblasti a komponenty\]](#), v podkapitole 4.4):

- **Objem spotřeby elektrické energie** – sleduje a analyzuje spotřebu elektrické energie v MWh.
- **Objem spotřeby plynu** – sleduje a analyzuje spotřebu zemního plynu ve firmě v GJ, resp. MWh.
- **Objem spotřeby nafty** – sleduje a analyzuje spotřebu nafty ve firmě v litrech.
- **Objem spotřeby vody** – sleduje a analyzuje spotřebu vody ve firmě v m³.
- **Objem spotřeby tepla** – sleduje spotřebu tepla v prostorách firmy, prodejnách a podle regionů včetně sezónních výkyvů.
- **Náklady na energie podle druhů** – sleduje náklady na spotřebu energií podle druhů v tisících Kč.
- **Počty měřidel** – zahrnují počty instalovaných měřidel pro různé druhy energií.
- **Objem vlastní výroby elektrické energie** – sleduje vlastní výrobu el. energie v MWh, např. při využití vlastní elektrárny, fotovoltaické zdroje apod.

11.3.3 Funkce analytiky energií

Analýzy potřeby a spotřeby energií zahrnuje tyto **funkce**:

- Analýzy **souhrnných ekonomických ukazatelů** řízení energií.
- Analýzy **objemu spotřeby** energií podle druhů, objemu spotřeby tepla.
- Analýzy **počtů měřidel** a jejich umístění.
- Analýzy **plánované potřeby** energií.
- Analýzy **objemu vlastní výroby** energií.
- Analýzy **časového** vývoje potřeby a spotřeby energií.
- **Hodnocení faktorů** ovlivňujících nároky na energie, hodnocení sezónních vlivů, dodavatelů, umístění prodejen, jejich technického vybavení apod.



Obrázek 11-4: Příklad 1: Analytika měřidel energií (Zdroj: Hájek, 2024)

11.4 Řešení deskriptivní analytiky v řízení majetku, investic, údržby a energií



Analytické otázky:

Analýzy majetku:

- Jak zvýšit **úspěšnost a výkonnost** byznysu díky vysoké kvalitě analýz pro řízení majetku?
- Jak dosáhnout **konsensu mezi pracovníky** řízení majetku na navrženém obsahu a strukturách analýz?
- Jak dosahovat **zkracování doby a časové náročnosti** na přípravu analýz majetku?
- Jak racionálně vymezit **očekávané efekty** analýz pro řízení majetku?
- Které **reporty** řízení majetku a s jakým obsahem budou adekvátní jednotlivým úrovním a pozicím řízení?
- Jak správně nastavit **analytická pravidla** ve vztahu k ukazatelům majetku pro generování varovných zpráv (**alertů**)?

Analýzy investic a údržby:

- Je k dispozici **identifikace** udržovaného nebo opravovaného zařízení?
- Je možné v každém okamžiku zjistit **aktuální stav jednotlivých zařízení**?
- Existuje ke každému zařízení kompletní a **aktuální technická dokumentace** v papírové i digitální podobě přístupná oprávněným pracovníkům?
- Existuje ke každému zařízení kompletní a **aktuální provozní dokumentace** v digitální podobě přístupná oprávněným pracovníkům?
- Existuje komplexní, integrovaná **evidence o disponibilních zdrojích** pro realizaci údržby, a to v různých časových horizontech?
- Analyzuje se realizace údržby, zda je plně **v souladu s definovanými pravidly** (technologickými postupy, bezpečností práce)?

Analýzy potřeby a spotřeby energií:

- Jak zajistit kvalitní evidenci **měřičů spotřeby** energií?
- Jak racionálně analyzovat a vybírat mezi **dodavateli** energií?
- Existuje **evidence stávajících i potenciálních dodavatelů energií** v takovém rozsahu, aby bylo možné vyhodnocovat jejich spolehlivost a kvalitu?
- Jsou **analýzy dodavatelů a dodávek** prováděny systematicky podle předem stanovených kritérií? Jsou dostupné oprávněným uživatelům?
- Jak analyzovat **efektivitu jednotlivých spotřebičů** energií?



Datové zdroje:

- **ERP** – moduly řízení majetku poskytují obvykle **funkcionalitu** pro evidenci majetku, pro správu majetku a řízení investic a údržby a pro reporting majetku.
- ERP nabízí často i adekvátní **dokumentaci investic** a aktualizovaný seznam požadovaných dokladů pro uvedení investice do provozu a následné zařazení do evidence majetku.
- ERP zahrnuje evidenci a **identifikaci udržovaných nebo opravovaných zařízení**.




Poznámky k řešení:

- Pokud ERP nepostihuje požadavky retailové firmy je na trhu k dispozici **řada produktů pro řízení majetku („asset management“)**, které se aplikují v případech dalších potřeb na funkce v dané oblasti a ty musí být kvalifikovaně vybrány.
- Pro údržbu musí řešení zajistit komplexní, integrovanou evidenci **o disponibilních zdrojích pro realizaci údržby**, a to v různých časových horizontech.
- ERP v řízení majetku zefektivňuje **procesy** spojené s řešením a hodnocením požadavků na energie různého druhu a případná řešení problémů ve vztahu s dodavateli. ERP poskytují obvykle základní funkce, ale spíše se využívají **specializované aplikace**.

11.5 Prediktivní analytika investic, údržby

Celkové schéma prediktivní analytiky v řízení investic a údržby dokumentuje Obrázek 11-5:



Obrázek 11-5: Prediktivní analytika v řízení investic a údržby

11.5.1 Cílové proměnné a prediktory

Náměty na specifikaci cílových proměnných v oblasti řízení investic a údržby obsahuje další přehled:


- Objem investic.
- Objem oprav a údržby.
- Počty pracovníků pro realizaci investic a údržbu.

11.5.2 Funkce prediktivní analytiky a plánování v řízení investic a údržby

- Predikce investičních záměrů, příprava investičního plánu.
 - Prediktory: objem požadavků na investice podle útvarů.
- Predikce nákladů na nové investice.
 - Prediktory: objem požadavků na investice podle útvarů, cenová úroveň dodavatelů investic.
- Predikce nákladů na údržbu a opravy.
 - Prediktory: cenová úroveň dodavatelů oprav a údržby, objem požadavků na opravy a údržbu.
- Predikce počtu pracovníků pro nové investice.
 - Prediktory: disponibilní pracovní fond, rozsah investic.
- Predikce počtu pracovníků pro zajištění údržby.
 - Prediktory: disponibilní pracovní fond, počet a časový rozsah akcí údržby..

11.6 Prediktivní analytika v plánování potřeby energií

Celkové schéma prediktivní analytiky v plánování potřeby energií dokumentuje Obrázek 11-6:



Obrázek 11-6: Prediktivní analytika v plánování potřeby energií

11.6.1 Cílové proměnné v řízení energií

- Objem potřeby elektrické energie.
- Objem potřeby zemního plynu.
- Objem potřeby nafty v litrech.
- Objem potřeby tepla.
- Náklady na energie podle druhů v měně.
- Objem vlastní výroby el. energie.

11.6.2 Funkce prediktivní analytiky a plánování v řízení energií

- Predikce potřeby *požadavků na energie* podle druhů.
 - Prediktory: objem nových investic, počty energeticky náročných zařízení, prostorová kapacita budov.
- Predikce vlastní výroby energií.
 - Prediktory: kapacita zařízení pro výrobu energie.
- Predikce nákladů na energie podle druhů.
 - Prediktory: objem nových investic, počty energeticky náročných zařízení, prostorová kapacita budov.

11.7 Řešení prediktivní analytiky v plánování investic, údržby a energií



Analytické otázky:

Plánování investic:

- Existuje **dlouhodobý reálný plán investičních akcí** pro firmu schválený dozorčí radou?
- Existuje **roční plán** investic pro firmu? Existuje možnost **operativní změny** ročního plánu?
- Jak realizovat kvalitní přípravu **investičních záměrů** a průběh jejich posuzování a schvalování?
- Jsou stanovena **pravidla** pro zpracování investičního záměru?
- Dochází k pravidelné **aktualizaci plánu investic** na základě výsledků marketingových průzkumů (zvýšení odbytu a zlevnění produktů a služeb), legislativních požadavků a zajištění bezpečnosti dodávek apod.?
- Jsou ke všem investicím zpracovávány **termínové plány** a jsou pravidelně kontrolovány ve vazbě na finanční plány?

Plánování údržby:

- Existuje odsouhlasený **roční plán proaktivní údržby** jednotlivých budov a zařízení dostupný pro oprávněné pracovníky?
- Je plán údržby **v souladu s platnou legislativou**, doporučením výrobce a provozními zkušenostmi?

	Plánování potřeby energií: ▪ Jak co nejpřesněji a včas zjišťovat budoucí předpokládané potřeby firmy v zajištění energiemi? ▪ Jaké jsou hlavní problémy firmy vzhledem k potřebě zajištění energiemi, a to obchodní, ekonomické i provozní? ▪ Jak nastavit různé možnosti alokace plánovaných hodnot na útvary?
	Poznámky k řešení: ▪ Příklad řešení prediktivní analytiky v řízení energií je obsahem přílohy 2. Příklad je zaměřený na optimalizaci energetického zajištění chladících zařízení v retailových řetězcích vzhledem k nastavení odpovídajících teplot s minimalizací rizika zkažení uskladněného zboží. ▪ Příklady uplatnění machine learning a vybraných funkcí a metod pro prediktivní analytiku v řízení investic, údržby a energií: ○ Regresní analýzy (lineární i vícenásobná regrese) pro predikce požadavků na investice, resp. investičních záměrů, predikce potřeby údržby a nároků na opravy, požadavků na zajištění energiemi. ○ Klasifikace majetku podle jednotlivých druhů – jejich rozdělení do skupin. ○ Klasifikace majetku podle úrovně využití – obvykle vychází z provozní evidence firmy, ○ Klasifikace odpisových tříd – podle běžných standardů a legislativy. ○ Klasifikace připravovaných investic. ○ Klasifikace údržbových činností. ○ Clustering investičních akcí podle dodavatelů, rozsahu a významu investic. ○ Clustering údržby a aktivit údržby podle periodicity, rozsahu, způsobu realizace. ○ Clustering poskytovatelů energií pro retailovou firmu podle druhů energií, objemu dodávek. ○ Profilování: ➤ specifikace komplexních charakteristik dodavatelů investic, jejich kvality a poskytovaných služeb, ➤ specifikace komplexních charakteristik dodavatelů energií včetně poskytovaných služeb.


12. Analytika obchodních center



Účelem analytiky obchodních center je celkové zkvalitnění a zpřesnění řízení obchodních center na základě vyhodnocování sledovaných metrik a vytváření **analytických podkladů** pro rozhodování o rozvoji obchodního centra, změnách ve struktuře nájemců apod. (dále podle Tkáč, D., Franěk, R., 2021).

12.1 Deskriptivní analytika obchodního centra

Souhrnný pohled na součásti deskriptivní analytiky obchodního centra prezentuje Obrázek 12-1:



Obrázek 12-1: Deskriptivní analytika obchodního centra.

12.1.1 Dimenze deskriptivní analytiky obchodního centra

	Základní dimenze:
	Čas – dimenze určující např. dobu platnosti smluv s nájemci, pro analýzy vývoje obsazení obchodního centra, vývoje ekonomických výsledků z pronájmů apod.
	Regiony – pro analýzy dislokací obchodních center, pro analýzy jejich nabídky vzhledem k populaci v daném regionu.
	Podniková organizace:
	Podnikové procesy – pro analýzy komunikací a kooperací mezi managementem OC a jednotlivými nájemci.
	Podnikové útvary – pro analýzy ekonomických výsledků podle jednotlivých útvarů OC.
	Ekonomické dimenze:
	Nákladové druhy – pro detailní analýzy nákladů na provoz a na poskytované služby obchodním centrem nájemníkům.
	Účetní období – pro analýzy vývoje nákladů a výnosů obchodního centra a jejich porovnání v rámci účetních období.
	Účetní osnova – pro analýzy financí podle účtů hlavní knihy a analytického účetnictví obchodního centra.

	Obchodní dimenze:
	Platební podmínky – pro analýzy plateb nájemníků.
	Servisní činnosti – pro analýzy servisních činností poskytovaných nájemníkům.
	Dimenze majetku, investic a energií:
	Majetek – pro analýzy majetku obchodního centra podle jednotlivých druhů. V kombinaci s dimenzí stavu majetku slouží pro sledování využití majetku, plánování oprav apod.
	Úroveň stavu majetku – vyjadřuje kvalitativní a technický stav jednotlivých druhů majetku.
	Druhy investic – pro analýzy plánovaných, aktuálně realizovaných nebo již uskutečněných investic do rozvoje obchodního centra.
	Druhy energií – pro analýzy druhů energií pro hodnocení jejich spotřeby a energetické náročnosti.
	Měřidla – pro analýzy počtů měřidel v rozlišení podle druhů energií a jejich umístění.
	Dodavatelé energií – pro hodnocení poskytovatelů energií a s nimi spojených služeb a jejich cenové úrovně.
	Obchodní dimenze:
	Obchodní kanály – pro analýzy podílů různých obchodních kanálů na ekonomických i obchodních výsledcích OC.
	Obchodní segmenty – pro hodnocení úspěšnosti OC na jednotlivých obchodních segmentech.
	Služby – pro přípravu a analýzy poskytovaných služeb podle struktury a typů poskytovaných služeb nájemníkům.

12.1.2 Metriky pro deskriptivní analytiku obchodního centra.

- **Počty zákazníků OC (Footfall)** – reportují ho jednotliví nájemníci, zároveň se zaznamenává senzory u vchodů, zaznamenává se i počet aut.

Související metriky:

- **Průměrný nákup** je poměr celkového obratu a počtu transakcí a ukazuje kolik utratí zákazník při jednom nákupu.
- **Kupní síla** odkazuje na sumu peněz, kterými disponují soukromé domácnosti za jisté období.
- **Míra absorpce** je poměr mezi hrubým obratem prodejce a dostupnou koupěschopností.
- **Index kupní síly** vyjadřuje kupní sílu regionu na obyvatele v porovnání s celostátním průměrem.

- **Výnosy z pronájmů** – finanční objem výnosů z pronájmů sledovaný podle jednotlivých nájemníků.

Související metriky

- **Hrubý počáteční výnos** vypočítaný jako poměr nasmlouvaného nájmu (čistého ročního nájmu) k tržní hodnotě nájmu.
- **Čistý počáteční výnos** u nemovitostí označuje poměr hrubého příjmu očištěného od provozních nákladů ovlivňujících likviditu a hodnotou nemovitosti plus náklady nabyvatele.
- **Tržby na metr čtvereční (Produktivita prostoru)** je obrat na metr čtvereční pronajimatelné plochy.
- **Poměr nájmu plus všech ostatních poplatků k tržbám** je nejčastější používané kritérium. Existují standardní rozsahy, které se mohou označit za udržitelné pro nájemníka, hodnoty

jsou však subjektivní pro odvětví, typ nájemníka a strukturu příjmů a výdajů. Často se z něho tvoří dvanáctiměsíční klouzavý průměr.

- **Obrat za celé centrum** se může porovnávat s obratem jednotlivých nájemníků.
- **Míry růstu tržeb** jsou meziměsíční a meziroční podíly.
- **Počet nájemníků OC** zahrnuje všechny nájemníky daného obchodního centra, např. kategorizované podle velikosti, typu apod. Váží se k němu další **ekonomické charakteristiky** podle nájemníků.

Související metriky

- **Počet obchodních transakcí**, reportují ho jednotliví nájemníci.
- **Obrat nájemníků** za celé centrum.
- **Podíl obratu nájemníků** na celkovém obratu OC.
- **Míry růstu tržeb** jako meziměsíční a meziroční podíly.
- **Průměrný prodej** = $\text{Obrat} / \text{Počet transakcí}$.
- **Pronájemná plocha** se rozděluje na pronajatou a prázdnou, pronajatá se obvykle člení podle kategorií nájemníků.

Související metriky

- **Hrubá pronájemná plocha** je celkový rozsah plochy bez ohledu na její aktuální využití.
- **Obraty pronájmů** se vytvářejí jako celkové souhrny a časové porovnání, které slouží jako KPI.
- **Prodej na čtvereční metr** se počítá z obrátů a z počtů m² jednotlivých nájemníků. Vytvářejí se z něj souhrny a časová porovnání. Je to jeden z hlavních KPI.
- **Poměr nákladů na pronájem** je ukazatel, který se dá jednoznačně označit jako KPI. Počítá se z obrátů, výšky nájmu a všech poplatků jednotlivých nájemníků.

12.1.3 Funkce deskriptivní analytiky obchodního centra

- **Analýza nájemního mixu** – podle typů nájemců a technických a smluvních omezení.
- **Marketingové analýzy** – podle standardních marketingových metrik a dimenzí.
- **Analýzy správy majetku** – kontroly na bázi měsíčních a čtvrtletních reportů a jejich projednání.
- **Porovnávání nájemců mezi sebou** – porovnání klíčových ukazatelů, jako je obrat na metr čtvereční, poměr nákladů na obsazenost, návštěvnost – pokud jsou v každé obchodní jednotce instalovány senzory.
- **Porovnání kategorie nájemců** – podle sortimentní nebo velikostní kategorie se aplikuje na indikátory v předchozím bodě.
- **Analýzy vývoje obchodního centra v čase** – meziroční, dvanáctiměsíční klouzavé průměry a součty.

Obrázek 12-2 představuje plán rozmístění jednotek v rámci obchodního centra:



Obrázek 12-2: Příklad 1: Floorplan obchodního centra a základní údaje o nájemnících (Zdroj: Tkáč, D., Franěk, R., 2021).

12.2 Řešení deskriptivní analytiky obchodního centra



Analytické otázky:

- Jak dosáhnout **zvýšení výnosů** z pronajímaných prostor?
- Proč mělo obchodní centrum **v daném období nižší návštěvnost**?
- Jak lze **zvýšit počet návštěvníků** obchodního centra?
- **Který nájemce** je vhodný pro obsazení určitých prostor v obchodním centru na základě jeho polohy?
- Jak zvýšit **počet transakcí zákazníků** nakupujících v obchodním centru?
- Jak udržet návštěvníky **v obchodním centru** delší dobu?
- Jak organizovat **obchody a poskytované služby** tak, aby se maximalizoval počet transakcí a čas strávený v obchodním centru?
- Jak úspěšná je aktuální **marketingová strategie** vzhledem ke zvyšování návštěvnosti?
- **Na jak dlouho jsou smluvně zajištěné aktuální hodnoty** měsíčního nájemného pro nájemce?




Datové zdroje:

- **ERP** – poskytuje vysoký úroveň **interní integrace** řízení obchodních center a potřebných dat pro analytiku v rámci jejich různých oblastí řízení (obchodu, marketingu, majetku, personalistiky).
- **CRM** – poskytuje pro analytiku informace o nájemnících, zákaznících a obchodních aktivitách v rámci OC.

	▪ Sociální sítě – dodávají informace např. o hodnocení obchodního centra ve veřejnosti, stavu poptávky na trhu a další charakteristiky globálního charakteru pro analýzy v řízení obchodního centra.
	Poznámky k řešení: ▪ ERP zefektivňuje obchodní, resp. prodejní procesy, díky racionalizaci standardních operací. ▪ Efektivita obchodních procesů se dále zvyšuje tam, kde jsou do ERP a jeho obchodních funkcí zabudovány technologie workflow. ▪ Vedení OC je díky analytice schopné velmi rychle reagovat na požadavky zákazníků, resp. nájemců a je současně je tak schopné řešit ihned problémy spojené s poskytovanými službami, infrastrukturou apod. ▪ ERP představuje obvykle hlavní zdroj dat OC a s tím rostou nároky na kvalitu dat, která při velkých objemech, počtech obchodních transakcí může být problémem. ▪ CRM podporuje vytváření dlouhodobých a úspěšných vztahů s nájemci a zvyšování jejich loajality.

12.3 Prediktivní analytika v řízení obchodních center

Celkové schéma prediktivní analytiky v řízení obchodních center dokumentuje Obrázek 12-3:



Obrázek 12-3: Prediktivní analytika v řízení obchodních center

12.3.1 Cílové proměnné v řízení obchodních center

- Počet zákazníků obchodního centra.
- Výnosy z pronájmů obchodů.
- Počet nájemníků obchodního centra.
- Náklady na služby poskytované obchodním centrem.

12.3.2 Funkce prediktivní analytiky a plánování v řízení obchodních center

- Predikce **výnosů z pronájmů**.
 - Prediktory: rozsah pronajímatelné plochy, počet obchodníků působících v obchodním centru.
- Predikce **zájemců o pronájem plochy** v obchodním centru.
 - Prediktory: rozsah pronajímatelné plochy, počet obchodníků působících v lokalitě obchodního centra.
- Predikce **počtu návštěvníků**, resp. zákazníků v obchodním centru.
 - Prediktory: počet obyvatel v lokalitě obchodního centra, počet obchodníků, resp. nájemců v obchodním centru.
- Predikce **nákladů na služby** poskytované obchodním centrem:
 - Prediktory: počet obchodníků, resp. nájemců v obchodním centru.

12.4 Řešení prediktivní analytiky a plánování obchodních center

	Analytické otázky: ▪ Jak racionálně plánovat využitelné plochy k pronajmutí? ▪ Jak zajistit dostupnost informací o stavu a předpokládaném vývoji trhu v dané lokalitě obchodního centra? ▪ Jak plánovat a nastavit ceny za pronajímané plochy? ▪ Jak nastavit různé možnosti alokace plánovaných hodnot výnosů z pronájmů na útvary obchodního centra? ▪ Jak efektivně plánovat počty nájemníků vzhledem ke kapacitám obchodního centra? ▪ Jak plánovat komplex služeb poskytovaných nájemníkům? ▪ Jak plánovat náklady za poskytované služby?
	Poznámky k řešení: ▪ Součástí prediktivní analytiky obchodních center je predikce cen a cenového vývoje za poskytované služby nájemníkům. ▪ Analytika ztráty zákazníka („churn“) se váže na situace, kdy nájemce ztratil o umístění a služby v obchodním centru zájem. ▪ A/B testování umístění jednotlivých obchodních jednotek – znamená efektivní rozložení prodejen, resp. obchodníků v obchodním centru. ▪ Řešení uplatnění machine learning a vybraných funkcí a metod pro prediktivní analytiku v řízení obchodních center:

- **Regresní analýzy** pro predikce výnosů z pronájmů, počtů zájemců o umístění v obchodním centru, počtu zákazníků v čase podle uvedených prediktorů.
- **Clustering: rozvojových aktivit** a inovací ve vybavení obchodních centra.
- **Clustering:** klastry nájemníků obchodního centra podle typu a sortimentu zboží, požadavků na služby apod.
- **Klasifikace nájemníků** obchodního centra – jejich rozřazení do stejnorodých tříd.
- **Klasifikace poskytovaných služeb nájemníkům** obchodního centra.
- **Klasifikace poskytovaných služeb** – posouzení správnosti klasifikace uvedením pravděpodobnosti správného členění.

Závěry k oddílu B: Analytika podle oblastí řízení retailové firmy

Oddíl B byl věnován primárně **vymezení základního obsahu** deskriptivní a prediktivní analytiky retailové firmy podle vymezených oblastí řízení. Předmětem řešení **nebyly jednotlivé analytické nástroje** a jejich parametry, neboť v tomto případě se odvoláváme na jiné dostupné publikace.

Každá kapitola (a oblast řízení) obsahovala **2 podkapitoly**. První byla věnována deskriptivní analytice pro danou oblast a druhá prediktivní analytice. Ke všem bodům v rámci kapitoly je třeba zdůraznit, že **nejde o striktní pravidla**, ale o **náměty na řešení**, které analytik může nebo nemusí přijmout, ale hlavně je pak **konkretizovat** podle skutečných potřeb a podmínek dané retailové firmy. Zejména v částech prediktivní analytiky analytik musí modifikovat a **konkretizovat řešení** podle pochopení a analýzy potřeb a možností firmy v prognózování a plánování, i s využitím zmíněných metod a modelů.

V každém případě pokládáme za podstatné **znovu zdůraznit**, že **klíčovými předpoklady** úspěšných řešení deskriptivní i prediktivní analytiky je kvalitní znalost, resp. pochopení byznysu retailové firmy **na straně analytika** a na druhé straně, **na straně manažerů a specialistů retailové firmy** jejich zájem na řešení, kreativita a kvalifikovaný přístup k projektu.

C. Přílohy

1. Strojové učení (Machine Learning)



Účelem přílohy je pouze vymezit základní principy a funkce strojového učení (Machine Learning). Příloha si tak neklade nárok prezentovat tento fenomén ve větším rozsahu a detail. Pro tyto účely odkazujeme na další zdroje uvedené v následujícím přehledu:

- GÉRON, A.: Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow. O'Reilly, 2023. ISBN: 978-1-098-12597-4.
- Příklady kódů k řešení úloh: <https://github.com/ageron/handson-ml3>
- Tutoriály k publikaci: <https://homl.info/tutorials>
- Scikit-Learn: <https://scikit-learn.org> : jednoduché užití, zahrnuje implementace algoritmů, představuje efektivní vstup do ML prostředí.
- TensorFlow: <https://tensorflow.org> : zejména pro rozsáhlé neuronové sítě, distribuované zpracování modelů
- Keras: <https://keras.io> : deep learning s využitím neuronových sítí


Text přílohy je založen a upraven na publikaci (Géron, 2023), viz výše.

1.1 Principy machine learning (ML)

Machine learning je postaven na následujících principech:

- Je to **algoritmus nebo technika**, která dovoluje systému být **trénován a učit se na vzorech** ze vstupů a následně je upravovat podle zkušeností, aniž by musely být explicitně programovány.
- **Základní termíny** ML jsou:
 - trénovací sada („*training set*“): případy, které systém využívá k učení,
 - jednotlivé trénovací případy: trénovací instance („*training instance*“),
 - model: část ML systému, která se učí a vytváří predikce (např. neuronová síť),
 - přesnost („*accuracy*“): míra kvality a výkonu systému.

- **Přístup k řešení ML** dokumentuje další obrázek:



Obrázek 1-1: Přístup k řešení ML (Zdroj: Géron, 2023)

1.2 Klasifikace ML podle řízení učení

1.2.1 Řízené učení („supervised learning“)

- Tréninková sada na vstupu algoritmu **obsahuje požadované strukturované řešení** („labels“).
- **Typickou úlohou** je zde **klasifikace**, nebo např. predikování cílové ceny produktu, požadovaných vlastností produktu, a to na bázi **regrese** apod.
- Pokouší se **modelovat vztahy** a závislosti mezi cílovou predikcí, prognózou a vstupními vlastnostmi tak, že mohou predikovat výstupní hodnoty pro nová data založené na vztazích, které byly „naučeny“ na předchozích datových sadách. Spoléhají se zde na **experty**, kteří fungují jako učitelé k naplnění trénovacích dat, která pomáhají modelu získávat správné odpovědi.

1.2.2 Neřízené učení („unsupervised learning“)

- Učí se **z prostých, jasných příkladů** bez připojených odpovědí, kde algoritmu je ponechána možnost určit, které datové vzory využije.
- Systém **nevyužívá přítomnost učitele**.
- **Typickými úlohami jsou**:
 - **clustering**, resp. hierarchický clustering, který **dělí jednotlivé skupiny prvků na podskupiny** („hierarchical clustering“),
 - **redukce dimenzí** pro zjednodušení obsahu dat („dimensionality reduction“),
 - výběr, resp. **vyloučení určených vlastností** („feature extraction“),
 - **identifikace anomálií** („anomaly detection“),
 - **identifikace nových instancí** odlišujících se od ostatních („novelty detection“),
 - **zjišťování asociačních pravidel** („association rule learning“).

1.2.3 Semi-supervised learning

Vytváření požadovaných strukturovaných řešení („labels“) je často časově a nákladově náročné, proto se v některých případech **kombinují „labels“ a instance bez strukturovaných řešení**. Ty se označují jako „semi-supervised learning“ a jsou kombinací „supervised learning“ a „unsupervised learning“ algoritmů.

1.2.4 Self-supervised learning

Přístup, který zahrnuje **generování plně „labeled“ datového setu z plně „unlabeled“ datového setu**. Pak lze využít kompletně „supervised learning“. Tento přístup se označuje jako „self-supervised learning“.

1.2.5 Reinforcement learning

„Reinforcement learning“, resp. posilované učení se označuje jako **agent, který může vyhodnocovat prostředí, vybírat a vykonávat akce a získávat odměny nebo negativní odměny** (penalizaci). Učí se, co je nejlepší strategie, resp. politika, jak získávat odměny. Politika určuje, jakou akci má agent vybrat pro danou situaci.

1.3 Dávkové a online učení

Dané rozlišení zahrnuje situace, zda je systém schopen se postupně učit z průběžně přicházejících dat, či nikoli.

1.3.1 Dávkové učení („batch learning“)

Systém se nemůže učit průběžně, musí být trénován na základě všech dostupných dat. Současně to představuje „offline learning“, to znamená, že systém je nejprve trénován a pak jako celek jde do provozu bez možnosti dalšího trénování. Systém postupně ztrácí na hodnotě vzhledem k tomu, že zatímco se prostředí mění, systém zůstává stejný. Tento stav se označuje jako „model rot“ nebo „data drift“. Systém musí v pravidelných fázích procházet dalším trénováním, což závisí na úlohách, pro které je využíván. Musí se počítat s tím, že trénování systému na kompletním setu dat je obvykle časově i nákladově vysoce náročné.

1.3.2 Učení online („online learning“)

Systém je trénován průběžně na základě aktuálních vstupů dat. Trénování je tak výrazně časově méně náročné. Využívá se v prostředích častých a rychlých změn a při omezeném rozsahu výpočetních zdrojů. Může být rovněž využit na velkých objemech dat, které však nemusí být najednou v paměti – „out-of-core learning“.

Podstatný parametr těchto systémů je, jak rychle se může adaptovat na změněná data, a označuje se jako „learning rate“. Problém je v případě chybných dat, kdy systém reaguje velmi rychle a snižuje se jeho výkon. Je tak nutné průběžně systém monitorovat.

1.4 Učení založené na instancích nebo modelech („instance-based / model-based learning“)

Klasifikace je založená na tom, do jaké míry je systém schopen generalizovat, to znamená, jak je schopen poskytovat dobré predikce, generalizovat příklady.

1.4.1 Instance-based learning

Systém se učí na základě příkladů z paměti, které generalizuje do nových případů s využitím úrovně podobnosti a porovnává je s naučenými příklady.

1.4.2 Model-based learning

Je přístup generalizace setu příkladů a vytvoření modelu příkladů, který je následně využíván k predikci. Prvním krokem je výběr modelu a určení míry jeho výkonu. Definuje se tzv. „utility function“ (resp. „fitness function“) určující, jak je model dobrý. Na druhé straně slouží „cost function“, tj. jak je model špatný.

1.5 Faktory machine learning

Hlavní faktory ovlivňující ML představují nekvalitní modely a nekvalitní data.

1.5.1 Nedostatečné množství trénovacích dat

Obvykle je potřeba pro jednoduché problémy tisíce příkladů v datech, pro komplexní problémy (např. rozpoznávání obrazů, či hlasu) se vyžadují miliony příkladů.

1.5.2 Nerepresentativní trénovací data

Pro generalizování jsou nezbytná trénovací data, která jsou reprezentativní vzhledem k novým případům, které se mají generalizovat. Pokud se využívají nerepresentativní data, pak modely, které je pro trénování používají poskytují chybné predikce.

1.5.3 Špatná kvalita dat

Špatná kvalita dat může zahrnovat následující aspekty:

- Případy, kdy instance zahrnují hodnoty mimo obvyklé limity („outliers“).
- Některé instance neobsahují potřebné vlastnosti, parametry („features“), např. věk zákazníka.
- „Features engineering“ zahrnuje tyto kroky:
 - „Features selection“ – výběr nejpoužívanějších vlastností.
 - „Features extraction“ – kombinování existujících vlastností.
 - Vytváření nových vlastností na základě nových dat.

1.5.4 Validace a ladění modelů

Aby se zajistilo, že je naučený prediktivní model co nejpřesnější, **musí být testován pomocí skupiny dat out-of-sample, testovacích dat**, která nijak nevstoupila do vývoje a učení modelu. Ověřuje se schopnost predikce modelu na této skupině dat a **porovnává se, jak moc se odchyluje od výsledků z učících dat**. Pokud je odchylka velká, znamená to, že model není optimálně generalizován. Nabyté znalosti jsou poté aplikovány na model, který se podle nich upraví a následně opět testuje.

Z důvodu vlastnosti generalizace **nejsou prediktivní modely při predikci úspěšné na 100 %**. V každém prediktivním modelu se objevují **2 základní typy chyb** (NYCE, 2007):

- Typ I. – chybně predikovaný výskyt, ve skutečnosti není výskyt,
- Typ II. – chybně predikovaný nevýskyt, je ve skutečnosti výskyt.

Overfitting (také overlearning) přeučení modelu znamená, že model **špatně vyhodnocuje náhodný šum v datech**, určuje důležité vztahy na základě náhodných proměnných a postrádá schopnost generalizace. Úspěšnost predikce modelu na nových datech je oproti ideálnímu stavu snížena. Tento nežádoucí stav může být mimo jiné **způsobený následujícími případy**:

- špatné nastavení modelu, například příliš velký (hluboký, rozvětvený) rozhodovací strom, příliš komplexní neuronová síť,
- příliš malý vzorek učících dat,
- chyby ve vstupních proměnných, které nebyly řádně očištěny.

Underfitting (nedoučení modelu) znamená, že **učení modelu bylo chybou nastavení modelu**, nebo nedostatkem dat **zastaveno příliš brzy** a nebyly odhaleny všechny důležité vztahy. Model je příliš obecný a jednoduchý. Například nedoučený strom se skládá z příliš malého počtu pravidel a má málo listů.

Pruning (prořezávání) je jedna z metod **optimalizace modelů**. Účelem je **snížení komplexity** modelu. Například u rozhodovacích stromů představuje pruning „prořezávání“ větví modelu, za účelem snížení počtu větví a listů a tím snížení rizika overfittingu (SiegeL, 2013), u neuronových sítí zase snížení počtu neuronů a vrstev Hidden Layer (Matignon, 2005).

1.5.5 Vyhodnocení modelu

Po vytvoření prvních modelů se **výsledky těch nejúspěšnějších testují v praxi na nových datech**. Na základě predikce se **uskuteční rozhodnutí** a nastane nějaká akce. Poté se vyhodnocuje, jak moc predikce odpovídá realitě, **vyhodnocuje se úspěšnost modelu** v praxi. Ta bývá zpravidla řádově nižší než model vykazuje na učících, či testovacích datech. V některých případech může být **objektivní**

vyhodnocení problematické, protože provedená akce ovlivní chování jedince a není tak možné zjistit jeho chování, když by akce nenastala.

Příkladem může být **marketingová kampaň** telekomunikační společnosti zaměřená na odcházející klienty, kde prediktivní modely vyhodnocují pravděpodobnost odstoupení klienta od smlouvy a jeho přechodu ke konkurenci. Klienti s nejvyšším skóre jsou společností osloveni a je jim nabídnuta nějaká výhoda. V tomto případě se však nedá přesně ověřit, zdali klienti, vyhodnocení jako nejnáchylnější k odstoupení, skutečně odstoupit chtěli, tedy zdali je model vyhodnotil správně jako nejnáchylnější k odstoupení. Dá se pouze měřit, kolik lidí skutečně odstoupilo a kolik ne. Řešení tohoto problému spočívá ve **využití kontrolních skupin**, kdy se záměrně část klientů s vysokým skóre neosloví a sleduje se u nich jejich chování neovlivněné prediktivním modelem.

1.6 Využití machine learning

Hlavní oblasti uplatnění ML podle (Géron, 2023) jsou tyto:

- v problémech, kde současná řešení vyžadují obrovské množství času a ladění, resp. jsou založena na neúměrném počtu pravidel,
- při řešení velmi komplexních problémů, kde tradiční postupy neposkytují odpovídající výsledky,
- u řešení problémů v nestabilním prostředí, kde se data velmi rychle mění,
- pro řešení komplexních problémů založených na velkých objemech dat.

Využití machine learning v jednotlivých **typech analytických úloh** je následující:

- **deskriptivní analytika** – využívá obdobných metod jako data mining. Využívají metody clusteringu a asociační pravidla. Příkladem klastrů je vytváření zákaznických skupin podle nákupních zvyklostí. Příkladem asociačního pravidla může být „kdo nakupuje zboží A, obvykle nakupuje i zboží B“,
- **diagnostická analytika** – využívá machine learning pro identifikaci různých anomálií např. u detekcí podvodů nebo hledají vzory dat pro klasifikaci událostí nebo vlastností produktů, nebo pro řešení úloh regrese,
- **preskriptivní analytika** – zahrnuje i „deep learning“, což je podmnožina machine learning založená na algoritmech, které se pokouší emulovat lidské myšlení a chování při řešení komplexních problémů. Deep learning nastavuje základní parametry dat a počítač má s využitím mnoha vrstev zpracování vytvářet potřebné vzory.

1.7 Prediktivní analytika a machine learning

Pro prediktivní analytiku machine learning nabízí nové možnosti a pokročilé metody při jejím využití a dosahuje se lepších prognóz. Představuje dnes **součást všech typů analytických úloh**, deskriptivní i prediktivní analytiku. ML je **využíváno v mnoha aplikacích**, jako např. Amazon, YouTube, Netflix v souvislosti s dalším doporučováním obsahu podle předchozích preferencí a nákupů zákazníka. Např. Amazon podle předchozích nákupů doporučuje další tituly knih nebo publikací souvisejících s přechozími nakupovanými tématy. **Business intelligence** aplikace využívají machine learning algoritmy k identifikování dalších použitelných dat.

Prediktivní analytika – využívá machine learning a deskriptivní proměnné pro prediktivní modelování jako neuronové sítě, extrapolace, regresní modely, případně pro spojování několika modelů do jednoho celku. Např. u neuronových sítí lze využít data z předchozích marketingových kampaní (jako věk, příjem atd.) a určovat příležitosti a rizika spojená s novými kampaněmi.

2. Příklad: Využití IoT pro chladicí zařízení v supermarketovém řetězci

(Zdroj: Gorylová, B., 2025, upraveno.)



Účelem přílohy je dokumentovat na příkladu řízení energií v maloobchodním řetězci možnosti a principy využití machine learning dalších souvisejících metod, kde zdrojem dat jsou technologie IoT (*Internet of Things*). **Cílem řešení** bylo optimalizovat spotřebu energie chladicích zařízení s minimalizací rizika zkažení nebo ztrát zboží.

2.1 Využití IoT v maloobchodním prodeji

Dle autorů Hossain et. al. (2021) nabízí IoT odvětví maloobchodu mnoho příležitostí, zejména **v oblasti lokalizačních služeb**, které využívají bezdrátové technologie k určení polohy zákazníků, sběru relevantních informací a komunikaci s nimi. To může zahrnovat například zasílání **propagačních oznámení na mobilní telefony zákazníků**, když se nacházejí v určité části obchodu, nebo poskytování navigace v rámci větších nákupních prostor. Očekávaným přínosem je okamžité zlepšení zákaznické zkušenosti a zároveň získání informací o chování zákazníků, která mohou být následně využita **pro cílenou marketingovou kampaň**.

IoT přináší další funkční výhody včetně **dynamické cenotvorby**, **personalizovaných doporučení** nebo **sledování zásob**. Senzory poskytují informace o jejich stavu v reálném čase, tím je umožněno lépe reagovat na poptávku zákazníků a výši zásob optimalizovat. V maloobchodních systémech jsou dále užívány například **energeticky úsporné termostaty a osvětlení** (Hossain et. al., 2021).

Informace poskytované senzory v reálném čase umožňují prodejcům činit lepší provozní či finanční rozhodnutí. V článku je zmíněn provedený průzkum se závěrem, že v odvětví maloobchodu již 37 % potravinářských a obchodních společností experimentuje s IoT technologiemi nebo je již implementovalo, a dalších 58 % plánuje rozšířit jejich využití (Hossain et. al., 2021).

Využití IoT **v oblasti chlazení** se věnoval také článek „A Smart IoT System for Remote Refrigeration Monitoring“ autorů Padmaja et. al. (2021). Text navrhoval metodiku pro vytvoření chytrého IoT systému pro **vzdálené monitorování chladírenských skladů**, které bývají typicky umístěny daleko od obydlých oblastí. Vytvořeným produktem byl nízkonákladový real-time systém, který umožnil **sledovat a vyhodnocovat teplotu ve zmíněných skladech**. Proces začal sběrem dat ze senzorů a končil tvorbou dashboardů dostupných v počítači nebo mobilním telefonu. Navrhovaná architektura se skládala **ze tří vrstev**, zahrnovala „**okrajovou vrstvu**“ se senzory a mikroprocesory, „**serverovou vrstvu**“ obsahující brány a routery a „**aplikační vrstvu**“ pro cloudové služby a koncová uživatelská zařízení. Monitoring fungoval také jako **varovný systém a byl schopen spustit upozornění před skutečným poškozením potravin**. V technické řešení byl použit koncept **edge computingu**, který umožnil zpracování dat blízko místa jejich vzniku, díky čemuž dojde ke snížení nákladů na přenos dat a k vyšší efektivitě. Vysokofrekvenční data byla agregována do segmentů za účelem snížení nákladů na komunikaci mezi uzly a cloudem.

2.2 Prediktivní model

Další text je zaměřen na vývoj a **implementaci prediktivního modelu**. V daném příkladě k tomu byly použity dva populární **modely strojového učení**, **SARIMAX a XGBoost**. Modelování bylo prováděno s využitím **metody křížové validace na bázi časových řad** (*TimeSeriesSplit* z knihovny *Sklearn*), která zohledňuje časovou posloupnost dat a minimalizuje riziko úniku informací mezi trénovacími a testovacími sety. Oba algoritmy byly aplikovány na reálných datech.

2.2.1 TimeSeriesSplit

Jednou z důležitých technik v oblasti strojového učení a statistiky je **křížová validace** nebo také **cross-validace**, která **slouží k hodnocení výkonnosti modelů**. Cílem křížové validace je zajistit, aby model, který byl vyvíjen, měl dobrou schopnost přizpůsobit se dosud neznámým datům.

Zatímco tradiční metody křížové validace, jako je **k-fold**, fungují dobře na nezávislé stejně rozdělené náhodné veličiny, nemusí být vhodné pro časové řady právě kvůli jejich časové povaze. **Data časových řad přinášejí specifické výzvy, neboť pozorování jsou závislá na pořadí, ve kterém se vyskytují.** Tradiční metody křížové validace mohou vést k příliš optimistickým výsledkům modelu, protože časovou strukturu dat neberou v úvahu. V takových případech je vhodná **křížová validace pomocí TimeSeriesSplit z knihovny scikit-learn** (Pedregosa et. al., 2025), který je schopen zohlednit časovou závislost a dokáže poskytnout realističtější hodnocení výkonu. TimeSeriesSplit je rozšíření k-fold křížové validace pro data časových řad. V tradiční k-fold metodě by došlo k náhodnému promíchání dat, ovšem TimeSeriesSplit zachovává časové pořadí (KoshurAI, 2023).


TimeSeriesSplit nejprve **rozděluje datovou sadu do k bloků, každý z nich obsahuje souvislou sekvenci pozorování.** V rámci každé iterace je jeden blok určen jako testovací a ostatní bloky slouží pro trénink. Celý proces se opakuje k-krát, přičemž **testovací sada se vždy posouvá na další sekvenci pozorování.** Díky tomu se zajistí, že každý údaj je **použit jak pro trénink, tak pro testování.** Tím se zabrání úniku dat a výkon modelu může být realisticky hodnocen (KoshurAI, 2023).

2.2.2 Referenční model

Proces modelování byl zahájen použitím modelu SARIMAX (Seasonal AutoRegressive Integrated Moving Average with eXogenous regressors), který je **rozšířením klasického ARIMA modelu**, navíc umožňuje zohlednit sezónnost v časových řadách a zároveň pracovat s externími proměnnými. SARIMAX kombinuje autoregresní složku, integrovanou složku pro **zohlednění trendu a klouzavý průměr** s možností zahrnutí vysvětlujících proměnných (Melanie, 2024).

Hlavním **cílem** bylo ověřit, **zda sledované atributy mají skutečně tak silný vliv na spotřebu elektřiny v dané prodejně**, jak bylo očekáváno. Do úvodního modelu vstupovala transformovaná datová sada z pilotní prodejny v 60minutovém intervalu. Za **vysvětlovanou proměnnou** byla zvolena **spotřeba elektřiny**. Všechny ostatní atributy obsahující informaci o **naměřených teplotách** nebo o otevření dveří byly v modelu použity jako **nezávislé proměnné**. Data byla očištěna o extrémní pozorování pomocí **metody z-score**.

Model měl relativně **vysokou chybovost** ve svých predikcích. Výsledná hodnota značí, že **použitý model nemusí být vhodný** pro tuto datovou sadu a bude žádoucí vyzkoušet i alternativní variantu. Je ale nutné zmínit že data obsahují pouze vysvětlující proměnné související s chlazením a mražením. **V datové sadě chybí další klíčové atributy**, které by jistě zvýšily jeho **přesnost v predikci celkové spotřeby energie**. Výsledek predikce byl znázorněn na Obr. 2.1



Obr. 2.1 Vizualizovaná predikce modelu SARIMAX (data ze systému TANIX, Gorylová, 2025)

Při tvorbě modelu byly vyzkoušeny také **různé obměny vstupujících dat**. Ať už změna nastavení hranic, vstupujících parametrů nebo časových intervalů, vše za ponechání časové cross-validace. Ovšem ani jedno z alternativních řešení nedosáhlo uspokojivějšího výsledku.

2.2.3 XGBoost

Předchozí část byla zaměřena na vytvoření prediktivního modelu pomocí SARIMAX. Dále byla prozkoumána **pokročilejší metoda strojového učení – XGBoost (Extreme Gradient Boosting)** z knihovny XGBoost (Chen et. al., 2022).

Jedná se o **volně dostupnou knihovnu strojového učení**, která využívá gradientně boostované rozhodovací stromy – algoritmus spadající do kategorie **učení s učitelem**. Metoda, oblíbená zejména díky své rychlosti a schopnosti zpracovat objemné datové sady, je **dostupná pro různé programovací jazyky**, mezi něž patří C++, Python, R, Java nebo Scala. XGBoost byl vyvinut Tianqi Chenem na Washingtonské univerzitě. Jeho základní princip je stejný jako u ostatních metod boostingu – **model kombinuje slabé rozhodovací stromy do silného modelu prostřednictvím přidání reziduí**.

Rozhodovací stromy se používají pro klasifikační nebo regresní úlohy strojového učení. Hlavním principem je **využití struktury stromu, kde je atribut symbolizován vnitřním uzlem**, rozhodovací pravidlo větvi a výsledek je představen listovým uzlem. Rozhodovací stromy jsou ovšem náchylné k přeučení, a proto se místo nich často používají **ensemble metody**, které skládají rozhodnutí z více modelů. Mezi ensemble metody se řadí právě i **boosting**, ten postupně kombinuje více individuálních slabých stromů. Boosting využívá aditivní přístup, **každý strom je jeden po druhém trénován** tak, aby napravil chyby předchozích modelů. Po mnoha iteracích dojde **ke vzniku silného modelu**. (Kavlakoglu et. al., 2024)

Gradientně boostované rozhodovací stromy jsou typem boostovacího algoritmu, který využívá gradientní sestup. **Gradientní sestup slouží k minimalizaci ztráty neboli ke zlepšení výkonu** při trénování nových modelů. Gradientní sestup je populární **optimalizační algoritmus pro minimalizaci ztrátové funkce**. Gradientní boosting opět začíná slabým predikčním modelem. Cílem je sekvenčně vytvořit soubor stromů, aby se každý další strom věnoval chybně klasifikovaným příkladům. Algoritmus poté **počítá rezidua pro každou predikci stromu**, aby určil, jak moc se predikce odchylují od skutečnosti. Rezidua představují rozdíl mezi predikovanými a skutečnými hodnotami. Tato rezidua se následně **využívají ke skórování modelu pomocí ztrátové funkce**. U regresních úloh patří mezi užívané ztrátové funkce střední kvadratická chyba (MSE) nebo střední absolutní chyba (MAE). (Kavlakoglu et. al., 2024)

Střední absolutní chyba (Mean Absolute Error, MAE) je metrika používaná k měření průměrné velikosti absolutních chyb mezi předpovězenými hodnotami a skutečnými hodnotami. MAE **sděluje průměrnou velikost chyby bez ohledu na její směr** – zda je chyba kladná nebo záporná. MAE zpracovává absolutní chyby lineárně – změna v chybě bude mít přímý vliv na MAE. (Singh, 2022).

Ve skutečnosti však bývá často potřebná metrika, která by větší chyby trestala přísněji než ty menší. V tu chvíli je vhodné využít **střední kvadratické chyby (Mean Square Error, MSE), která vyjadřuje průměrný kvadratický rozdíl mezi skutečnými a predikovanými hodnotami**. Umocnění hodnot způsobuje, že MSE přikládá větší váhu větším chybám a stává se tím citlivější na extrémní hodnoty známé také jako *outliery* (Stewart, 2024).

Poslední z používaných metrik je odmocněná **střední kvadratická chyba (Root Mean Square Error, RMSE)**. **RMSE měří rozdíl mezi hodnotami předpovězenými modelem a skutečností**. Vypočítává se jako druhá odmocnina MSE. Zatímco MSE měří kvadratický rozdíl mezi skutečnými a predikovanými hodnotami, RMSE přidává krok odmocnění. Díky tomu je hodnota ztrátové funkce převedena zpět na stejnou jednotku jako původní měřené hodnoty (Singh, 2022).

2.2.4 Dlouhodobý datový model

Při tvorbě modelu byla **za cílovou proměnnou opět zvolena spotřeba elektřiny**. Všechny ostatní atributy nesoucí **informaci o naměřených teplotách nebo o dveřním kontaktu byly do modelu zapojeny jako nezávislé proměnné**.


Následně byl definován **for cyklus, ve kterém byla data v každé iteraci rozdělena na trénovací a testovací množiny** pomocí TimeSeriesSplit. Celkem bylo provedeno 5 iterací a v každé z nich byl model trénován na trénovací sadě a jeho výkon hodnocen na testovací sadě pomocí **čtyř metrik: koeficient determinace (R2), střední kvadratická chyba (MSE), odmocněná střední kvadratická chyba (RMSE) a střední absolutní chyba (MAE)**.

Tyto hodnoty byly ukládány do příslušných seznamů a po dokončení všech iterací byly vypočítány průměrné hodnoty těchto metrik. Tím byl poskytnut **celkový přehled o výkonu modelu**.


2.2.5 SHAP hodnoty

SHAP hodnoty (SHapley Additive exPlanations) jsou užívány *pro interpretaci výstupu modelu strojového učení*. Principem SHAP hodnot je **přiradit každému atributu důležitost**, která ukazuje jeho individuální přínos k výsledku modelu. SHAP hodnoty umožňují porozumět, jak jednotlivé proměnné ovlivňují každou predikci, **jak jsou pro model důležité ve srovnání s ostatními a jakým způsobem se prediktory navzájem ovlivňují**. (Awan, 2023)

Model byl vytvořen pomocí XGBoost() s nejlepším dosaženým nastavením, tedy **s daty ponechanými na frekvenci 15 minut a s eliminací extrémních pozorování**. Zároveň byly odstraněny proměnné s klouzavým průměrem a se zpožděnými hodnotami, které byly do datasetu zapojeny dodatečně. V dalším postupu byla použita **metoda TreeExplainer()** z knihovny shap (Lundberg, 2018), která vypočítává SHAP hodnoty z trénovacích dat a z natrénovaného modelu. **Výsledné SHAP hodnoty** byly následně vykresleny pomocí beeswarm grafu na Obr. 2.2. a sloupcového grafu Obr. 2.3.



Obr. 2.2 SHAP hodnoty pro Model 2 (data ze systému TANIX, vlastní zpracování)



Obr. 2.3 Průměrné SHAP hodnoty pro Model 2 (data ze systému TANIX, vlastní zpracování)

V **beeswarm grafu** byly na ose X znázorněny **SHAP hodnoty, které ukazují vliv dané proměnné na predikci modelu**. Kladná SHAP hodnota, umístěná směrem doprava od středu, ukazuje, že daná vlastnost má pozitivní vliv na model a zvyšuje jeho výstup. Záporná SHAP hodnota, výkon naopak snižuje.

Každý bod vykreslený na grafu představuje **jedno pozorování z datasetu**. Jeho barva reprezentuje hodnotu atributu. Pokud je bod znázorněn modře jedná se o nízké hodnoty atributu, červená barva naopak značí vysoké hodnoty. Velikost a hustota bodů v řádku ukazují, kolik vzorků má danou SHAP hodnotu pro určitou vlastnost. **Čím více bodů v určité oblasti, tím více pozorování má podobný vliv na predikci modelu.**

Mediánová teplota zařízení M8906 byla přibližně -22,2 °C. Hygienická norma stanovuje maximální povolenou teplotu -14 °C, z tohoto pohledu je zajištěno **bezpečné skladování potravin**, ovšem **naměřená teplota se jeví jako příliš nízká**. Za účelem úspory elektrické energie by bylo možné úroveň podchlazení o pár stupňů snížit blíže k teplotě -14 °C.

U M8905 lze pozorovat opačný problém, mediánová teplota byla -14 °C a průměrná pouze -12 °C, vysoce nad nastavenou hranicí maximální teploty. Nabízí se hypotéza, zda zařízení nemůže být vadné. **Velkou spotřebu elektřiny** by pravděpodobně bylo možné vysvětlit neustálou **potřebou dochlazení**.


V popředí se umístil také mrazicí box M8916 (SHAP hodnota 0,007) ze zázemí. Průměrná teplota boxu činí -16,86 °C a medián je -18,15 °C. Tyto hodnoty se pohybují příliš blízko požadované hranice -14 °C a bylo by pravděpodobně **vhodné silnější podchlazení**.

Z pohledu chladicích přístrojů se významně umístila zařízení CH8924 (SHAP hodnota 0,002) s mléčnými výrobky a CH8879 (SHAP hodnota 0,001) s mléčnými výrobky. Lednice CH8879 je součástí prodejny, její průměrná teplota je 5,08 °C a medián nepatrně nižší 4,25 °C. CH8924 je lednice naopak umístěná v zázemí, její průměrná i mediánová teplota je 2,75 °C. Obě zařízení splňují hygienickou normu s dostatečnou rezervou. U CH8924 by pravděpodobně mohlo dojít ke zvýšení nastavené teploty, u mléčných výrobků se stanovuje uskladnění na 0,5–7,5 °C. **Stávající rezerva se jeví nadbytečně vysoká a vede k vyšší spotřebě, než by bylo nutné.**

Z byznysového hlediska by bylo užitečné zjistit **dopad senzorů monitorujících počet otevřených dveří**, aby zadavatel mohl případně pozměnit strategii doplňování zboží. Nicméně tyto údaje se na seznamu **nejvlivnějších hodnot překvapivě neumístily vůbec** a na predikci spotřeby měly na této prodejně jen nepatrný vliv.


Naměřená teplota uvnitř prodejny také **nepatří mezi silné prediktory** a venkovní teplota má jen malý vliv (průměrná SHAP 0,001).

Pro tři nejvýše uvedené prediktory byly následně vykresleny dependance ploty znázorňující vztah mezi proměnnou a její SHAP hodnotou (viz Obr. 2.4, Obr. 2.5 a Obr. 2.6).



Obr. 2.4 Dependence plot pro M8906 (data ze systému TANIX, Gorylová, 2025)

Závislost mezi teplotou pro zařízení M8906 a její SHAP hodnotou vykázala skokový charakter. Pro teploty pod -20°C jsou **SHAP hodnoty mírně pozitivní až neutrální, model tedy predikoval spíše vyšší nebo stabilní spotřebu**. Při zvýšení teploty mrazáku nad přibližně -20°C dochází k prudkému poklesu SHAP hodnot a model náhle predikoval nižší spotřebu. Na základě pozorování lze vyhodnotit, že omezení úrovně podchlazení z původních -20°C by skutečně mohlo mít požadovaný vliv na snížení spotřeby. Tento efekt byl víceméně nezávislý na venkovní teplotě.




Obr. 2.5 Dependence plot pro M8905 (data ze systému TANIX, vlastní zpracování)

Na první pohled se vývoj predikce teploty mohl jevit jako opačný než u předchozího grafu, vzhledem k tomu, že s rostoucí teplotou rostly i SHAP hodnoty. U zařízení M8905 lze ale z naměřených hodnot

sledovat, že pozorování se nacházela v jiném rozsahu teplot, v tomto případě většina pozorování překročila kritickou mez $-14\text{ }^{\circ}\text{C}$. **Největší spotřeba proto nastala v případech, kdy muselo zařízení intenzivněji pracovat na ochlazení zpět na stanovenou teplotu.** Vrchol nastal přibližně kolem $0\text{ }^{\circ}\text{C}$, poté došlo ke strmému poklesu SHAP hodnot, kdy model opět predikoval nižší spotřebu – zřejmě v momentech, kdy zařízení přestalo aktivně chladit. Podle barevné škály lze usoudit, že efekt je mírně zesílen při nižších venkovních teplotách.

Stejně jako v předchozím případě, **nejnižší spotřeba nastává od $-17\text{ do }-10\text{ }^{\circ}\text{C}$** , kdy zařízení udržuje vnitřní teplotu a nemusí usilovat o větší ochlazení.



Obr. 2.6 Dependence plot pro M8916 (data ze systému TANIX, vlastní zpracování)

U třetího mrazicího zařízení, M8916, SHAP hodnoty v grafu působily nečekaně diskrétně, je to způsobeno tím, že osa y je **ve srovnání s předchozími dvěma grafy více detailní**.

Všechny SHAP hodnoty byly velmi blízko nule, vliv této proměnné byl na predikovanou spotřebu slabý. V oblasti **mezi $-15\text{ }^{\circ}\text{C}$ a $-5\text{ }^{\circ}\text{C}$ byly SHAP hodnoty víceméně konstantní a kladné**, zatímco při nižších teplotách kolísaly a klesaly do záporných hodnot. **Predikce spotřeby má opačný charakter** než u prvního dependence plotu pro M8906.

Na základě vykreslených SHAP dependence plotů lze tvrdit, že se **jednotlivá zařízení z hlediska vlivu teploty na spotřebu elektřiny nechovají jednotně**. Všechny sice vykazují **nelineární vztah mezi teplotou a predikovanou spotřebou, avšak charakter těchto závislostí se liší**. Zatímco například zařízení M8906 i M8905 vykazovala očekávané chování, tedy že k nejvyšší spotřebě bude docházet při extrémně vysokých a nízkých teplotách, mrazák M8916 se výrazně lišil od obou zařízení. Zatímco tyto dva mrazáky měly jasně vyjádřený vztah mezi teplotou a spotřebou, M8916 působilo jako zařízení s velmi stabilním nebo rigidním provozem, kde změny teploty mají jen minimální dopad na spotřebu elektřiny podle modelu.

2.3 Predikce na 24 hodin

Původní predikce se zaměřovala pouze na velmi krátký časový horizont 15 nebo 60 minut, dále bylo žádoucí ověřit, jak by si model poradil i s delším časovým horizontem. Z tohoto důvodu byla implementována predikce na 24 hodin.

V tomto přístupu byl původní **model rozšířen na vícekový (multistep) model**, který umožňuje předpovědět vývoj cílové proměnné na delší horizont – konkrétně na dalších 96 kroků, což odpovídá 24

hodinám při frekvenci 15 minut. Původní model pro porovnání předpovídal pouze jednu hodnotu dopředu.

K přípravě dat byla vytvořena funkce, která pro daný časový okamžik vzala aktuální vstupní hodnoty a k nim přiřadila 96 budoucích hodnot cílové proměnné, čímž vznikl **vícerozměrný cílový vektor**. Tyto vektory sloužily jako trénovací sada pro model, který se učil mapovat aktuální stav na budoucí vývoj. Model byl opět postaven pomocí algoritmu XGBoost, který umožnil vytvořit více paralelních modelů – **jeden pro každý krok predikce**. Přístup k tvorbě modelu zůstal v ostatních ohledech stejný.

2.4 Interpretace

Interpretace modelu prostřednictvím **SHAP hodnot** ukázala, že **klíčové faktory** ovlivňující predikci zahrnují zejména **mrazicí přístroje umístěné na prodejně**. Významný vliv má také teplota chladicích zařízení a venkovní teplota vzduchu. Překvapivě nebyl zaznamenána přínos senzorů pro otevření dveří, jejich data měla jen omezený vliv na spotřebu.

2.5 Vyhodnocení výsledků

Byly identifikovány klíčové faktory ovlivňující spotřebu elektrické energie. Z pohledu manažerského vyhodnocení analýza ukázala, že **hlavní prediktory spotřeby elektřiny byly nejčastěji teploty v jednotlivých chladicích a mrazicích zařízeních**. Ovšem v některých prodejnách byla nejsilnějším faktorem **četnost otevírání dveří**. Získané výsledky se lišily podle lokalit, proto je doporučeno k optimalizaci zavést **regionálně specifický přístup** se zaměřením na monitoring individuálních zařízení.

U mrazicích zařízení bylo zpozorováno, že k nejvyšší predikované spotřebě dochází ve dvou krajních případech. Při nadměrném podchlazení mrazicího prostoru, a naopak při prudkém zvýšení teploty, které vyžaduje opětovné ochlazení. Rozhodnutí o snížení míry pochlazení z -20 °C na -18 °C se jeví jako vhodně zvolené.

Zdroje

- AALST, WIL van der. *Process Mining Data Science v akci*. Berlín : Springer, 2016. 978-3-662-49850-7.
- AWAN, A. A.: *An Introduction to SHAP Values and Machine Learning Interpretability*. DataCamp. 2023. <https://www.datacamp.com/tutorial/introduction-to-shap-values-machine-learning-interpretability>
- BACAL, R.: *Manager's Guide to Performance Management*. New York, McGraw-Hill 2012. ISBN 978-0-07-177225-9.
- BERKA, P. 2003. *Dobývání znalostí z databází*. Praha: Academia, 2003. str. 366. ISBN 80-200-1062-9.
- BOTHE, O., KUBERA, O., BEDNÁŘ, D., POTANČOK, M., NOVOTNÝ, O.: *Managing Analytics for Success*, CRC Press, 2022. ISBN 978-1-032-20851-0.
- BRUCKNER, T. VOŘÍŠEK, J., BUCHALCEVOVÁ, A. a kolektiv: *Tvorba informačních systémů: Principy, metodiky, architektury*, Grada, 2012, ISBN 978-802477-9027.
- DOHNAL, J., POUR, J.: *IT v řízení podniku*, Praha, Professional publishing 2016. ISBN 978-80-7431-160-4.
- DRESNER, H.: *Profiles in Performance*. New York, John Wiley and Sons, 2010. ISBN: 978-0-470-40886-5.
- FIBÍROVÁ, J., ŠOLJAKOVÁ, L., WAGNER, J., PETERA, P.: *Manažerské účetnictví. Nástroje a metody*. Praha, Wolters Kluwer, 2015. ISBN: 978-80-7478-743-0.
- FITZ-ENZ J., MATTOX II J., R.: *Predictive Analytics for Human Resources*. Wiley and SAS Business Series, 2014. ISBN: 978-1-118-89367-8.
- FRIEBELOVÁ, JANA: *Rozhodovací stromy. Osobní stránka – Jana Friebeľová*. [Online] 28. 12 2006. [Citace: 10. 11 2010.] http://www2.ef.jcu.cz/~jfrieb/rmp/data/teorie_oa/STROMY.pdf.
- GORYLOVÁ, B.: *Využití IoT pro chladicí zařízení ve vybraném supermarketovém řetězci*, DP, VŠE, Praha. 2025.
- GROOVER, M., P.: *Introduction to Manufacturing Processes*. John Wiley and Sons, Inc. 2012. ISBN: 978-0-470-63228-4.
- HALAMA, J.: *Řízení datové kvality v Hadoop Ecosystem*, DP, VŠE, Praha, 2021.
- HINDLS, R., HRONOVÁ, S., NOVÁK, I.: *Analýza dat v manažerském rozhodování*. Grada, 1999. ISBN: 80-7169-255-7.
- HOLČÍK, J. & KOMENDA, M.: *Matematická biologie učebnice: e-learningová učebnice*. Masarykova univerzita. 2015. <https://portal.matematickabiologie.cz/index.php?pg=aplikovana-analyza-klinickych-a-biologickych-dat--aplikovana-analyza-preziti--nastroje-regresni-diagnostiky--rezidua-modelu>.
- HOLTSNIDER, B., JAFFE, B.D.: *IT Manager's Handbook*. Amsterdam, Elsevier 2012. ISBN 978-0-12-415949-5.
- HOSSAIN, S., CHISTY, N. M. A., & AMIN, R.: *Role of Internet of Things (IoT) in Retail Business and Enabling Smart Retailing Experiences*. *Asian Business Review*, 2021 11(2), 75–80. <https://pdfs.semanticscholar.org/b6f4/38a323e355a24f126e7ab55387402079263c.pdf>.
- HOUDEK, O., HÁJEK, M., MAREK, J. *Prezentace VŠE*, 2024.
- CHANDLER, N.: *The CPM Scenario*. Gartner BI Summit 2008.
- CHEN, T., & XGBoost developers: *XGBoost* (Verze 2.1.4) [Software]. 2022. <https://xgboost.readthedocs.io/en/stable/index.html>.
- CHRAMOSTOVÁ, V., POTANČOK, M., POUR, J.: *Byznys analytika pro manažery*, Oeconomia, Praha, 2020.
- KAVLAKOGLU, E., & RUSSI, E.: *What is XGBoost?* | IBM. IBM. 2024. <https://www.ibm.com/think/topics/xgboost>.

- KOSHURAI.: *Understanding TimeSeriesSplit Cross-Validation for Time Series Data*. Medium. 2023. <https://koshurai.medium.com/understanding-timeseriessplit-cross-validation-for-time-series-data-4c232cc4f844>.
- KRÁL, B. a kol.: *Manažerské účetnictví*. Praha, Management Press 2006. ISBN 80-7261-141-0.
- KUNSTOVÁ, R.: *Efektivní správa dokumentů*. Praha, Grada, 2009. ISBN 978-80-247-3257-2.
- LANEY, D., B.: *Infonomics*, Bibliomotion, Inc., New York, 2018. ISBN 978-1-138-09038-5.
- LUNDBERG, S.: *Welcome to the SHAP documentation—SHAP latest documentation*. (Verze v0.47.2) [Software]. 2018. <https://shap.readthedocs.io/en/latest/index.html#>.
- MELANIE.: *SARIMAX model: What is it? How can it be applied to time series?* DataScientest. 2024. <https://datascientest.com/en/sarimax-model-what-is-it-how-can-it-be-applied-to-time-series>.
- NOVOTNÝ, O., BUCHALCEVOVÁ, A., BRUCKNER, T., STANOVSKÁ, I., ŠEDIVÁ, Z., POUR, J.: *IT a anatomie firmy (Podniková analytika)*. Professional Publishing, 2023. ISBN 978-80-88260-70-7. Dostupné na <https://mbi-af.cz>.
- PADMAJA, B., VIJAYAKUMAR, CH., KRISHNA RAO PATRO, E., & SHASHIREKHA, B.: *A Smart IoT System for Remote Refrigeration Monitoring*. Research Square. 2021. <https://doi.org/10.21203/rs.3.rs-432649/v1>.
- PALADINO, B.: *Innovative Corporate Performance Management: Five Key Principles to Accelerate Results*. Indianapolis, Wiley Publishing, 2011. ISBN: 978-0-470-62773-0.
- PALVEL, S.: *Understanding Time Series Cross-validation*. Medium. 2023. <https://subashpalvel.medium.com/understanding-time-series-cross-validation-1929c543d339>.
- PARMENTER, D.: *Key Performance Indicators (KPI): Developing, Implementing, and Using Winning KPIs*.
- PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., GRISEL, O., BLONDEL, M., PRETTENHOFER, P., WEISS, R., DUBOURG, V., VANDERPLAS, J., PASSOS, A., COURNAPEAU, D., BRUCHER, M., PERROT, M., & DUCHESNAY, E.: *Scikit-learn: Machine learning in Python—Scikit-learn 1.6.1 documentation*. (Verze 1.6.1) [Software]. 2025. <https://scikit-learn.org/stable/index.html>.
- ŘEPA, V.: *Podnikové procesy*. Praha, Grada 2007.
- SCHIESSER, R.: *IT Systems Management*. New York, Prentice Hall 2010. ISBN 978-0-13-702506-0.
- SIEGEL, E.: *Predictive Analytics*. New York, John Wiley & Sons, 2016. ISBN 978-1-119-14567-7.
- SINGH, Y.: *3 Regression Metrics You Must Know: MAE, MSE, and RMSE | Proclus Academy*. Proclus Academy. 2022. <https://proclusacademy.com/blog/explainer/regression-metrics-you-must-know/>.
- SLÁNSKÝ, D.: *Data and Analytics for the 21st Century: Architecture and Governance*, Professional Publishing, 2018. ISBN 978-80-88260-16-5.
- STEWART, K.: *Mean squared error (MSE) | Definition, Formula, Interpretation, & Facts | Britannica*. Britannica. 2025. <https://www.britannica.com/science/mean-squared-error>.
- SYNEK, M. a kol.: *Manažerská ekonomika*. Praha, Grada 2011. ISBN 978-80-247-3494-1.
- SYNEK, M., KISLINGEROVÁ, E. a kol.: *Podniková ekonomika*. Praha, C H Beck 2015. ISBN 978-80-7400-274-8.
- ŠOLJAKOVÁ, L. FIBÍROVÁ, J.: *Reporting*. Praha, Grada, 2010. ISBN 978-80-247-2759-2.
- ŠVECOVÁ, L., VEBER, J.: *Produkční a provozní management*. Grada, 2021. ISBN 978-80-271-1385-9.
- TKÁČ, D., FRANĚK, R.: *Obchodní centra*. Pracovní dokument, 2021. Dostupný na <https://mbi-af.cz>.
- UČEŇ, P.: *Zvyšování výkonnosti firmy na bázi potenciálu zlepšení*. Praha, Grada 2008. ISBN: 978-80-247-2472-0.
- VIRTANEN, P., GOMMERS, R., OLIPHANT, T. E., HABERLAND, M., REDDY, T., COURNAPEAU, D., BUROVSKI, E., PETERSON, P., WECKESSER, W., BRIGHT, J., VAN DER WALT, S. J., BRETT, M., WILSON, J., MILLMAN, K. J., MAYOROV, N., NELSON, A. R. J., JONES, E., KERN, R., ... SciPy Contributors : *SciPy* (Verze 1.15.2) [Software]. 2025. <https://scipy.org/>.

VOMLELOVÁ, MARTA: Rozhodovací stromy. *Výuka – Marta Vomlelová*. [Online] 10 20, 2009. [Cited: 11 10, 2010.] <http://kti.mff.cuni.cz/~marta/slistromy.pdf>.

VOŘÍŠEK, J., POUR, J. a kol.: Management podnikové informatiky, Professional Publishing, 2012, ISBN 978-80-7431-102-4.

WASKOM, M. L.: 2023. *Seaborn* (Verze 0.13) [Software]. Waskom, M. L. 2023. *Seaborn* (Verze 0.13) [Software]. <https://seaborn.pydata.org/>. <https://seaborn.pydata.org/>.