

UNIVERZITA PARDUBICE

FAKULTA EKONOMICKO-SPRÁVNÍ

DIPLOMOVÁ PRÁCE

2025

Bc. Adéla Doubravová

Univerzita Pardubice  
Fakulta ekonomicko-správní

Analýza business dat pro marketingové účely  
Diplomová práce

Univerzita Pardubice  
Fakulta ekonomicko-správní  
Akademický rok: 2024/2025

# ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Adéla Doubravová**  
Osobní číslo: **E23037**  
Studijní program: **N0613A140041 Aplikovaná informatika – Data Science pro business**  
Téma práce: **Analýza business dat pro marketingové účely**  
Zadávající katedra: **Ústav systémového inženýrství a informatiky**

## Zásady pro vypracování

Cílem práce je identifikovat vhodné datové zdroje vybrané organizace a na základě analýzy relevantních dat navrhnout marketingovou strategii. Práce bude obsahovat vymezení souvisejících pojmů, identifikaci a popis datových zdrojů, výběr a zdůvodnění použitých metod, analýzu relevantních dat, návrh strategie a její implementaci pro praktické využití.

Osnova:

- Úvod do problematiky.
- Metodiky.
- Nástroje pro vyhodnocování účinnosti marketingové kampaně.
- Analýza vybrané organizace.

Rozsah pracovní zprávy: **cca 50 stran**  
Rozsah grafických prací:  
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

ALHLOU, Feras, Shiraz ASIF a Eric FETTMAN. *Google Analytics Breakthrough: From Zero to Business Impact*. Wiley, 2016. ISBN 978-1-119-14401-4.  
BAIG, Mirza Rahim; GOVINDAN, Gururajan a SHRIMALI, Vishwesh Ravi. *Data Science for Marketing Analytics – Second Edition: A practical guide to forming a killer marketing strategy through data analysis with Python*. 2. vydání. Packt Publishing, 2021. ISBN 978-1800560475.  
GRIGSBY, Mike. *Marketing Analytics: A Practical Guide to Improving Consumer Insights Using Data Techniques*. 3. vydání. Kogan Page, 2022. ISBN 978-1398608191.  
HEMANN, Chuck a Ken BURBARY. *Digital Marketing Analytics: Making Sense of Consumer Data in a Digital World (Que Biz-Tech)*. 2. vydání. Pearson Que Publishing, 2018. ISBN 978-0789759603.  
SEMERÁDOVÁ, Tereza et al. *Jak na digitální marketingovou strategii firmy*. Liberec: Technická univerzita v Liberci, 2021. ISBN 978-8074945649.

Vedoucí diplomové práce: **Ing. Renáta Bílková, Ph.D.**  
Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: **1. září 2024**  
Termín odevzdání diplomové práce: **30. dubna 2025**

**prof. Ing. Jan Stejskal, Ph.D.** v.r.  
děkan

L.S.

**prof. Ing. Petr Hájek, Ph.D.** v.r.  
garant studijního programu

V Pardubicích dne 1. září 2024

Prohlašuji:

Práci s názvem Analýza business dat pro marketingové účely jsem vypracovala samostatně. Veškeré literární prameny a informace, které jsem v práci využila, jsou uvedeny v seznamu použité literatury.

Byla jsem seznámena s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 30. 04. 2025

Bc. Adéla Doubravová v.r.

## **PODĚKOVÁNÍ**

Ráda bych poděkovala vedoucí své diplomové práce Ing. Renátě Bílkové, Ph.D., za odborné vedení, cenné rady, připomínky a trpělivost, kterou mi věnovala v průběhu psaní této práce.

Mé poděkování patří také celé mé rodině a blízkým za jejich podporu, pochopení a povzbuzení během celého studia, zejména v náročných obdobích. Bez jejich důvěry a motivace by cesta k dokončení této práce byla mnohem obtížnější.

## **ANOTACE**

Diplomová práce se zabývá využitím business dat v online marketingu a jejich aplikací při návrhu optimalizační marketingové strategie. Cílem práce je identifikovat a analyzovat relevantní datové zdroje vybrané organizace – dceřiné společnosti stavebního holdingu působícího v Pardubickém kraji – a na základě výsledků datové analýzy navrhnout efektivní strategii pro zlepšení marketingových aktivit.

Práce přináší praktický přínos v oblasti datově řízeného rozhodování v marketingu a představuje aplikovatelné postupy pro zefektivnění digitálních kampaní v reálném podnikovém prostředí.

## **KLÍČOVÁ SLOVA**

Business data, analýza, marketing, Power BI, Microsoft Excel

## **TITLE**

Business data analysis for marketing purposes

## **ANNOTATION**

The thesis deals with the use of business data in online marketing and its application in the design of optimization marketing strategy. The aim of the thesis is to identify and analyze relevant data sources of a selected organization – a subsidiary of a construction holding company operating in the Pardubice Region – and based on the results of data analysis to propose an effective strategy for improving marketing activities.

The work makes a practical contribution in the field of data-driven decision-making in marketing and presents applicable procedures for streamlining digital campaigns in a real business environment.

## **KEYWORDS**

Business data, analysis, marketing, Power BI, Microsoft Excel

# OBSAH

<b>1</b>	<b>ÚVOD .....</b>	<b>11</b>
<b>2</b>	<b>ÚVOD DO BUSINESS DAT A JEJICH ROLE V MARKETINGU .....</b>	<b>12</b>
2.1	DATA, ZNALOSTI A INFORMACE .....	12
2.2	DEFINICE BUSINESS DAT .....	12
2.3	VÝVOJ VYUŽÍVÁNÍ DAT V MARKETINGU .....	15
2.4	VÝZNAM VYUŽÍVÁNÍ DAT V MARKETINGU .....	15
2.5	DATOVÁ TYPOLOGIE .....	16
2.6	ANALÝZA DAT A MARKETINGOVÝ VÝZKUM .....	17
2.7	TYPY MARKETINGOVÉHO VÝZKUMU .....	18
<b>3</b>	<b>ZDROJE BUSINESS DAT PRO MARKETINGOVÉ ÚČELY .....</b>	<b>19</b>
3.1	ZÍSKÁVÁNÍ DAT .....	19
3.2	ZDROJE DAT .....	19
3.3	INTERNÍ ZDROJE BUSINESS DAT .....	19
3.4	EXTERNÍ ZDROJE BUSINESS DAT .....	22
<b>4</b>	<b>DIGITÁLNÍ MÉDIA .....</b>	<b>26</b>
4.1	PLACENÁ DIGITÁLNÍ MÉDIA .....	26
4.2	VLASTNĚNÁ DIGITÁLNÍ MÉDIA .....	28
4.3	ZÍSKANÁ MÉDIA .....	30
<b>5</b>	<b>METODY A TECHNIKY ANALÝZY BUSINESS DAT .....</b>	<b>32</b>
5.1	TRADIČNÍ PŘÍSTUP K ANALÝZE DAT .....	32
5.2	MODERNÍ METODY ANALÝZY .....	33
5.3	BUSINESS INTELIGENCE A JEJÍ ANALYTICKÉ NÁSTROJE .....	38
<b>6</b>	<b>ROLE BIG DATA V MARKETINGU .....</b>	<b>42</b>
6.1	BIG DATA .....	42
<b>7</b>	<b>PERSONALIZACE MARKETINGU NA ZÁKLADĚ DATOVÉ ANALÝZY .....</b>	<b>45</b>
7.1	PRINCIPY PERSONALIZACE OBSAHU .....	45
<b>8</b>	<b>PRAKTICKÁ ČÁST .....</b>	<b>50</b>
8.1	POROZUMĚNÍ CÍLI (BUSINESS UNDERSTANDING) .....	50
8.2	POROZUMĚNÍ DATŮM (DATA UNDERSTANDING) .....	50
8.3	PŘÍPRAVA DAT .....	51
8.4	MODELOVÁNÍ .....	53
8.5	VYHODNOCENÍ PRAKTICKÉ ČÁSTI .....	68
<b>9</b>	<b>ZÁVĚR .....</b>	<b>72</b>

## SEZNAM ILUSTRACÍ

OBRÁZEK 1 - TROJÚHELNÍK VZTAHŮ MEZI DATY, ZNALOSTMI A INFORMACEMI.....	12
OBRÁZEK 2 - CYKLUS FUNGOVÁNÍ IOT .....	25
OBRÁZEK 3 - ALGORITMUS UČENÍ BEZ UČITELE .....	34
OBRÁZEK 4 - ZPĚTNOVAZEBNÍ UČENÍ.....	35
OBRÁZEK 6 - DASHBOARD POWER BI.....	68

## SEZNAM TABULEK

TABULKA 1 -VÝKONNOSTNÍ KAMPAŇ ZÁŘÍ .....	54
TABULKA 2 - VÝKONNOSTÍ KAMPAŇ – ŘÍJEN.....	55
TABULKA 3 - VÝKONNOSTNÍ KAMPAŇ.....	56
TABULKA 4 - VÝKONNOSTNÍ KAMPAŇ PODLE FÁZE TÝDNE (ZÁŘÍ) .....	57
TABULKA 5 - VÝKONNOSTNÍ KAMPAŇ PODLE FÁZE TÝDNE (ŘÍJEN) .....	58
TABULKA 6 - VÝKONNOSTNÍ KAMPAŇ PODLE FÁZE TÝDNE .....	59
TABULKA 7 - VÝKONNOSTNÍ KAMPAŇ (PONDĚLÍ).....	60
TABULKA 8 - VÝKONNOSTNÍ KAMPAŇ (ÚTERÝ).....	61
TABULKA 9 - VÝKONNOSTNÍ KAMPAŇ (STŘEDA).....	61
TABULKA 10 - VÝKONNOSTNÍ KAMPAŇ (ČTVRTEK) .....	62
TABULKA 11 - VÝKONNOSTNÍ KAMPAŇ (PÁTEK).....	62
TABULKA 12 - VÝKONNOSTNÍ KAMPAŇ (SOBOTA) .....	63
TABULKA 13 - VÝKONNOSTNÍ KAMPAŇ (NEDĚLE).....	63
TABULKA 14 - OHODNOCENÍ METRIK BODY .....	64
TABULKA 15 - PŘEPOČET METRIKY S VÁHOU .....	64
TABULKA 16 - VYHODNOCENÍ DNŮ .....	65
TABULKA 17 - KORELACE MEZI ZOBRAZENÍMI A PROKLIKY .....	66
TABULKA 18 - KORELACE MEZI NÁKLADY A PROKLIKY .....	66
TABULKA 19 - KORELACE MEZI CPC A CTR.....	67
TABULKA 20 - KORELACE MEZI NÁKLADY A CPC .....	67

## SEZNAM ZKRATEK A ZNAČEK

BI	Business Intelligence
CPC	Cost Per Click – cena za proklik
CTR	Click-Through Rate – míra prokliku
DSP	Demand Side Platform – platforma pro nákup reklamního prostoru
GA	Google Analytics
IoT	Internet of Things – internet věcí
KPI	Key Performance Indicator – klíčový ukazatel výkonnosti
PNO	Podíl nákladů na obratu
PPC	Pay-Per-Click – platba za proklik
RFM	Recency, Frequency, Monetary – typ analýzy zákaznického chování
RTB	Real-Time Bidding – programatický nákup reklamy v reálném čase
SSP	Supply Side Platform – platforma pro nabídku reklamního prostoru
CRISP-DM	Cross Industry Standard Process for Data Mining – metodika datové analýzy

# 1 ÚVOD

V dnešní digitální éře se stává práce s daty nedílnou součástí marketingového rozhodování. Firmy mají k dispozici stále větší množství dat, která jim umožňují lépe porozumět chování zákazníků, optimalizovat kampaně a zvyšovat návratnost investic. Klíčem však není pouze samotná dostupnost dat, ale i schopnost je správně analyzovat a interpretovat v kontextu konkrétních marketingových cílů.

Tato diplomová práce si klade za cíl prozkoumat možnosti využití business dat v oblasti online marketingu, konkrétně prostřednictvím analýzy výkonnostních kampaní jedné z dceřiných společností stavebního holdingu působícího zejména v Pardubickém kraji. V rámci praktické části budou analyzována data ze dvou kampaní, které probíhaly v průběhu září a října 2024 – bannerové kampaně a kampaně zaměřené na klíčová slova v reklamní síti Sklik.

Výstupem práce bude nejen popisné a vizuální zhodnocení efektivity jednotlivých kampaní, ale také návrh optimalizační strategie, která bude vycházet z podrobné výkonnostní analýzy podle jednotlivých dnů v týdnu, typů kampaní, zařízení i dalších faktorů. Zvláštní důraz bude kladen na propojení praktické analýzy s metodologií CRISP-DM, která poskytne systematický rámec pro celý proces zpracování dat – od porozumění datům až po návrh opatření pro zlepšení.

Tato práce tak bude sloužit jako případová studie využití datové analýzy pro strategické rozhodování v online marketingu a zároveň demonstrovat možnosti nástrojů, jako je Excel či Power BI, pro interpretaci marketingových dat v praxi.

## 2 Úvod do business dat a jejich role v marketingu

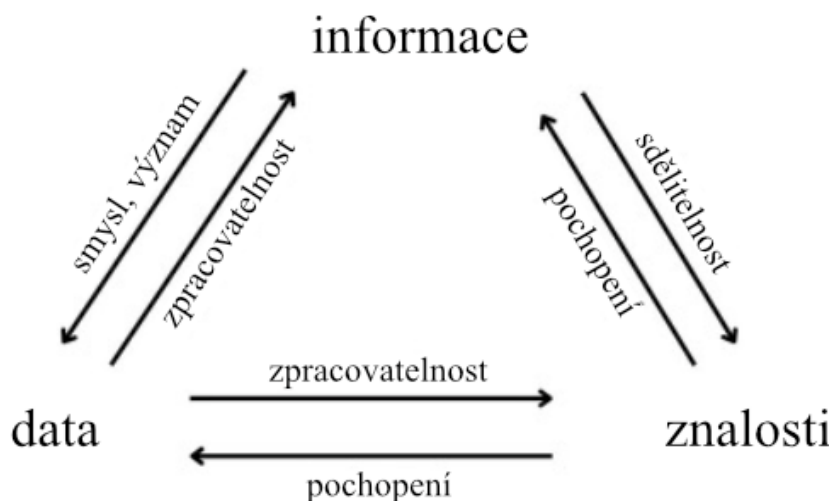
Data představují zásadní zdroj pro orientaci v chování zákazníků i výkonnosti marketingových aktivit. Jejich správná interpretace a využití umožňují firmám lépe cílit kampaně, optimalizovat náklady a činit rozhodnutí podložená fakty.

### 2.1 Data, znalosti a informace

Data hrají klíčovou roli v rámci výzkumu, protože slouží jako základ pro analýzu a interpretaci. Představují surová fakta o světě – mohou mít podobu číselných hodnot, jako je věk zákazníků či průměrná teplota, ale také obrazových dat, textů či zvukových záznamů. Samotná data však nemají hodnotu, dokud nejsou zpracována a zasazena do kontextu.

Až poté, co s daty začneme pracovat a dávat jim význam, se z nich stávají informace. Například seznam transakcí e-shopu je pouze soubor dat, ale pokud tato data začneme analyzovat a zjistíme, jaké produkty jsou nejprodávanější v určitém období, vznikne informace, která má konkrétní užitek.

Dalším krokem v procesu práce s daty je jejich přeměna na znalosti. Znalost vzniká tehdy, když aplikujeme informace do kontextu a využíváme je k rozhodování. Například pokud analýza ukáže, že určitá skupina zákazníků častěji nakupuje při slevových akcích na konkrétní produkty, firma může tuto znalost využít k optimalizaci své marketingové strategie. [1],[2]



Obrázek 1 - Trojúhelník vztahů mezi daty, znalostmi a informacemi

Zdroj: Vlastní zpracování podle Kozel (2011)

Tento proces transformace od surových dat přes informace až po znalosti je klíčový pro strategické plánování a efektivní řízení firem. Rozhodování na základě dat, neboli data-driven rozhodování, umožňuje firmám lépe pochopit potřeby zákazníků, zvyšovat efektivitu marketingových kampaní a optimalizovat provozní procesy. [6]

### 2.2 Definice business dat

Stejně tak, jak jsou data obecně důležitá v běžném životě, jsou důležitá i ve světě podnikání. Firmy se snaží získat co nejvíce informací, které se týkají společnosti a jejích činností na trhu. Shromážděná data pak využívají pro své strategické rozhodování nebo marketingové aktivity.

Definice business dat je taková, že se jedná o veškerá data, která jsou spojena s činností firmy. Zastřešují tedy veškeré údaje, které firmy sbírají ohledně svých zákazníků či svých činností na trhu.

U business dat se zaměřujeme na tři klíčová kritéria – zda jsou data strukturovaná či nestrukturovaná, zda pocházejí z interních či externích zdrojů, a na to, zda se jedná o takzvaná real-time data nebo již historická data. [1],[2]

### 2.2.1 Dělení dat podle struktury

První klíčovou charakteristikou dat je rozdělení podle struktury datového souboru. Data se dělí na strukturovaná, polostrukturovaná a nestrukturovaná. Způsob rozdělení dat je závislý na tom, jak jsou data organizována a jak s nimi může počítač pracovat.

Strukturovaná data jsou nejčastěji organizována do relačních tabulek s pevně danými sloupci a řádky, tedy mají stanovenou logickou strukturu, díky které se s nimi dá snadno pracovat. Každý sloupec obsahuje konkrétní typ dat a do řádků se ukládají jednotlivé údaje. Strukturovaná data jsou nejčastěji ve formátu textu, ale je do nich možné ukládat i obrazová a zvuková data. Jedná se například o soubory Excelu či SQL databáze. Jako zdroj strukturovaných dat lze uvést například síťová data, data z internetových obchodů, bankovníctví a podobně. [3],[4]

Nestrukturovaná data jsou opakem strukturovaných dat. Jak název napovídá, tato data nemají mezi sebou žádnou logickou strukturu, což zvyšuje náročnost práce s nimi. Nestrukturovaná data nelze zpracovávat běžnými analytickými postupy, které jsou používány na běžná data. Pro jejich zpracování se využívají pokročilejší metody analýzy dat, přičemž konkrétní metoda závisí na druhu analyzovaných dat. Například pro zpracování textu, jako je e-mailová komunikace či příspěvky na sociálních sítích, se využívají metody *přirozeného zpracování jazyka (NLP)*, pro analýzu zvuků a řeči pak *Automatic Speech Recognition*, který má za úkol převádět mluvenou řeč do písemné podoby. Pro jejich ukládání se využívají *NoSQL databáze*, které jsou specializované na ukládání neorganizovaných dat. Příklady nestrukturovaných dat můžeme nalézt v e-mailové korespondenci či textech u příspěvků na sociálních sítích, ale také v obrázcích, videích či audiozáznamech. [3],[4]

Polostrukturovaná data se nacházejí na pomezí strukturovaných a nestrukturovaných dat. Obsahují částečnou logickou strukturu, ale nejsou tak pevně svázaná jako strukturovaná data. Jsou tvořena například značkovací či stromovou strukturou. Ukládají se do *NoSQL databází* či v datových formátech jako *JSON*, *XML* či *HTML*. Jejich hlavní výhodou je flexibilita, která umožňuje práci s různými datovými strukturami. Zároveň se zvyšuje náročnost jejich zpracování a analýzy. [5]

### 2.2.2 Dělení dat podle původu

Druhou charakteristickou vlastností dat je jejich rozdělení podle původu. Data členíme na interní a externí, přičemž toto dělení je důležité zejména proto, že se s každým typem dat pracuje odlišně v rámci podnikových procesů.

## **Interní data**

Interní, nebo také soukromá data, jak už název napovídá, vycházejí z vnitřního prostředí firmy. Generují se interními procesy, systémy a interakcemi se zákazníky. Jedná se o informace, které nejsou veřejně dostupné a musí být chráněny z důvodu zachování soukromí a bezpečnosti. Patří sem například osobní údaje, jako jsou rodná čísla, finanční záznamy apod. Jako zdroj těchto dat lze označit například CRM systémy, transakční databáze, ERP systémy či webové analýzy.

Hlavní výhodou interních dat je plná kontrola nad nimi a jejich přesnost. Umožňují vzájemné kombinování dat z různých interních zdrojů a tím dosažení přesnějších a hlubších analýz. Také jsou nákladově méně náročná, protože vznikají v rámci běžné činnosti firmy. Nevýhodou je však jejich omezenost – mapují pouze činnost jedné konkrétní firmy z jejího vlastního pohledu, nikoliv celý trh. [1],[2]

## **Externí data**

Externí data, někdy označovaná jako veřejná, pocházejí z veřejně dostupných zdrojů, tedy mimo firmu. Díky nim může mít společnost širší povědomí o trhu, konkurenci a zákaznících. K jejich získání není zpravidla potřebný speciální přístup a nevyžadují přísnou ochranu.

Do externích dat patří například veřejné databáze, průzkumy trhu, sociální sítě a jiné digitální zdroje.

Výhodou externích dat je, že poskytují širší pohled na tržní prostředí. Práce s těmito daty umožňuje firmám získat konkurenční výhodu. Nevýhodou je vyšší cena, zejména při odkupu dat od třetích stran, a také riziko nižší kvality a přesnosti těchto dat. [1],[2]

### **2.2.3 Dělení podle časového hlediska**

Poslední charakteristickou vlastností, podle které se dělí business data, je časové hledisko. Podle něj rozlišujeme data historická a real-time data. Stejně jako u předchozích dělení má i toto svá specifika pro použití jednotlivých skupin dat.

#### **Historická data**

Historická data jsou údaje, které již byly uloženy v databázích a využívají se k analýzám, predikcím či plánování. Zaznamenávají minulé chování, výkonnost či trendy. V marketingu se využívají zejména pro rozbor chování zákazníků, přičemž pomáhají firmám rozdělit zákazníky do jednotlivých segmentů na základě jejich nákupních preferencí. Dále slouží například k predikci budoucích trendů a k vyhodnocování úspěšnosti marketingových kampaní.

Nevýhodou historických dat je jejich neaktuálnost, která může způsobit, že nereflektují současnou situaci na trhu.

#### **Real-time data**

Real-time data, jak už název napovídá, jsou okamžitě generovaná a zpracovávaná data. Umožňují firmám reagovat na aktuální dění v reálném čase. Díky jejich dynamické povaze dokáží zachytit aktuální chování zákazníků, například kliknutí na reklamu či nákup v internetovém obchodě.

Real-time data se v marketingu využívají zejména pro dynamickou personalizaci reklam, které se upravují na základě posledních akcí uživatelů. Dále nacházejí využití například při zpracování online transakcí v e-commerce.

Nevýhodou real-time dat je jejich vyšší technická náročnost, protože zpracování dat v reálném čase klade zvýšené nároky na technologie. Také může dojít k chybám v důsledku reakce na krátkodobé výkyvy, například v rámci prodejů. [2]

### 2.3 Vývoj využívání dat v marketingu

Marketing v posledních letech prošel značným vývojem. Marketéři se již nespolehnají pouze na domněnky, ale obracejí se na spolehlivější zdroje informací – na data. Tento přístup se souhrnně označuje jako *data-driven marketing*.

Data-driven marketing, neboli datově řízený marketing, využívá data k lepšímu pochopení chování a preferencí zákazníků a trhu. Díky tomu lze predikovat jejich potřeby, přání a budoucí chování na trhu. Marketing se obecně zaměřuje na dva hlavní cíle – uspokojení potřeb a přání zákazníků.

V rámci tradičního marketingu byly strategie založeny zejména na průzkumech, intuici a jednoduchých metrikách. Hlavními zdroji informací byly například osobní dotazníky, telefonické průzkumy nebo veřejné statistiky. Často se vycházelo z rozložení populace podle veřejných údajů nebo z vlastní zákaznické databáze.

S rozvojem internetu a elektronizací databází se marketing začal více orientovat na práci s daty. Firmy začaly získávat data pomocí CRM systémů, webové analytiky či sociálních sítí. Díky těmto zdrojům mohou marketéři přesněji vyhodnotit, co zákazníci v daný moment chtějí, a nabídnout jim odpovídající produkty či služby. [1],[6]

V současné době, kdy nastává éra umělé inteligence, firmy využívají AI a strojové učení k analýze velkých objemů dat a automatizaci marketingových procesů. Novým způsobem sběru dat jsou například *AI-driven chatboti*, kteří komunikují se zákazníky, nebo *automatizované doporučovací systémy*, které využívají například Amazon či Netflix. Díky tomu se nabízený obsah stává hyperpersonalizovaným. [7]

### 2.4 Význam využívání dat v marketingu

Jak již bylo zmíněno, data hrají klíčovou roli v rámci celého marketingu. Jsou klíčovým faktorem při vytváření úspěšné firemní strategie. Tím, že firmy využívají analýzu dat o zákaznících, mohou efektivně optimalizovat své kampaně, rozpočty a personalizovat nabídku.

*Lepší porozumění zákazníkům* je jedním z hlavních přínosů využívání dat. Mantra „Poznej svého zákazníka“ se v obchodě skloňuje již desítky let, avšak až v posledních letech se její naplnění stává realitou. Prakticky každá akce, kterou uživatel v digitálním prostředí provede, vytváří určitá data. Pomocí těchto dat se přizpůsobuje obsah sociálních sítí, vylepšují se marketingové kampaně a zjišťují se zákaznické preference.

S lepším porozuměním zákazníkům souvisí i *efektivnější propagace*. Díky analýze dat o preferencích a zálibách zákazníků mohou firmy lépe cílit své kampaně a oslovovat správné publikum ve správný čas a na správném místě.

Dalším přínosem je *optimalizace marketingových procesů*. V dnešní technologické době je čas klíčovým faktorem. Pomocí datové analytiky lze výrazně zvýšit produktivitu, efektivitu kampaní i řízení času v marketingových odděleních. [8]

## 2.5 Datová typologie

Statistická data lze rozdělit na základě různých kritérií, například podle zdroje, struktury nebo časového hlediska. Marketingová analytika se zaměřuje na data podle jejich obsahu a využití.

### 2.5.1 Demografická data

Demografická data popisují základní charakteristiky zákazníků, které slouží k segmentaci trhu. Jedná se o informace jako věk, pohlaví, vzdělání, povolání nebo rodinný stav. Využívají se k tvorbě cílených reklam, zákaznických person a k personalizaci produktové nabídky.

Demografické zacílení se používá například v rámci *Facebook Ads*, kde je možné cílit reklamy podle věku, pohlaví a bydliště uživatele. [2]

### 2.5.2 Behaviorální data

Behaviorální data se zaměřují na chování uživatelů online i offline, například na jejich zvyklosti a preference. Tato data se získávají například z historie vyhledávání, kliknutí na reklamy nebo délky návštěvy webových stránek.

V marketingu se využívají zejména pro *retargeting* reklam – například po návštěvě e-shopu se uživateli znovu zobrazí personalizovaná reklama. Tento typ dat využívá například *Amazon*, který sleduje prohlížené produkty a podle toho doporučuje další. [2]

### 2.5.3 Transakční data

Transakční data se zaměřují na nákupní chování zákazníků. Sledují například počet a hodnotu nákupů, preferované platební metody nebo frekvenci nákupů.

Marketing využívá tato data pro tvorbu věrnostních programů a segmentaci zákazníků podle jejich výdajů. Transakční data analyzují například obchodní řetězce jako *Tesco*, aby mohly nabízet personalizované slevy. [2]

### 2.5.4 Psychografická data

Psychografická data se týkají postojů, hodnot a životního stylu zákazníků, čímž firmám umožňují lépe pochopit motivaci zákazníků. Informace mohou zahrnovat osobnostní rysy, politické či náboženské preference a hodnoty.

Firmy tato data využívají pro *storytelling* a hodnotově orientovaný marketing. Příkladem je společnost *Nike*, která propaguje produkty zaměřené na aktivní životní styl. [2]

### 2.5.5 Geolokační data

Geolokační data sledují polohu zákazníků pomocí GPS nebo IP adres. Jsou klíčová pro lokální marketingové kampaně nebo offline propagaci.

Příkladem využití jsou *navigační reklamy* na *Google Maps*, které doporučují podniky v blízkosti uživatele. [2]

## 2.5.6 Sentimentová data

Sentimentová data analyzují emoce a postoje zákazníků vůči produktům nebo značkám. Získávají se například analýzou komentářů na sociálních sítích, recenzí produktů nebo zákaznických hovorů.

V marketingu slouží k real-time sledování reputace značky a zlepšování služeb na základě zpětné vazby. Sentimentovou analýzu využívá například *Tesla* při správě komunikace na sociálních sítích. [2]

## 2.6 Analýza dat a marketingový výzkum

Analýza dat a marketingový výzkum jsou dva úzce propojené koncepty, které se však liší svým zaměřením, metodologií a využitím. Proto je nutné tyto pojmy odlišovat.

### 2.6.1 Analýza dat

Analýza dat je věda o práci s nezpracovanými daty, zahrnující jejich zpracování, interpretaci a vizualizaci. Cílem je získat užitečné informace podporující rozhodování. Analýza dat nejčastěji využívá *kvantitativní přístupy*, které pracují s velkými objemy dat (*Big Data*) a s automatizací.

Příkladem cílů analýzy dat je například optimalizace nákladů na reklamu, predikce chování zákazníků na základě historických dat a podobně. [2]

### 2.6.2 Marketingový výzkum

Marketingový výzkum je systematické a objektivní sbírání nových dat, jejich analýza a interpretace. Získaná data se zaměřují na zákazníky, konkurenci a trh. Marketingový výzkum rozšířil tradiční marketing o nové metody, jako je *analýza sentimentu*, *strojové učení* či *prediktivní modelování*, které využívají nástroje datové analytiky.

Cílem marketingového výzkumu je zejména pochopení potřeb a chování zákazníků, identifikace nových příležitostí na trhu, hodnocení výkonnosti marketingových kampaní a predikce budoucích trendů. [9],[10],[11]

### Charakteristika marketingového výzkumu

Marketingový výzkum je charakteristický třemi hlavními rysy:

- **Jedinečnost** – výzkum je určen pouze pro zadavatele a zaměřen na konkrétní segment trhu
- **Vysoká vypovídací hodnota** – poskytuje hlubší a detailní informace o zkoumaném jevu
- **Aktuálnost** – data jsou získávána na základě současného stavu trhu [9],[11]

[10]

## 2.7 Typy marketingového výzkumu

Marketingový výzkum dělíme do několika kategorií podle účelu a způsobu sběru dat. Hlavní členění je:

- **Podle zdroje informací**
  - Primární výzkum
  - Sekundární výzkum
- **Podle povahy dat**
  - Kvalitativní výzkum
  - Kvantitativní výzkum
- **Podle hloubky poznání**
  - Explorativní výzkum
  - Deskriptivní výzkum
  - Kauzální výzkum [9],[12]

### 2.7.1 Primární a sekundární výzkum

*Sekundární výzkum* využívá již existující data. Je levnější, rychlejší a snadněji dostupný, ale může být zastaralý, méně spolehlivý nebo nepřesný. Mezi zdroje sekundárního výzkumu patří veřejné databáze, analýzy konkurence či nástroje jako *Google Trends*.

*Primární výzkum* se provádí tehdy, když dostupná sekundární data nestačí. Tento výzkum přináší přesná, aktuální a na míru získaná data, avšak za vyšší cenu a při větší časové náročnosti. Mezi metody primárního sběru patří dotazníky, rozhovory nebo *A/B testování*. [9],[12],[13]

### 2.7.2 Kvalitativní a kvantitativní výzkum

*Kvalitativní výzkum* zkoumá motivace, postoje a hlubší významy. Využívá textová nebo obrazová data a pracuje s malými vzorky. Výhodou je hlubší vhled, nevýhodou obtížná zobecnitelnost výsledků.

*Kvantitativní výzkum* sbírá číselná data a využívá statistické metody. Výsledky umožňují zobecnění na širší populaci, ale ztrácejí některé jemné souvislosti.

Kvalitativní výzkum odpovídá na otázku „*Proč?*“, kvantitativní na „*Kolik?*“ [9],[12],[14]

### 2.7.3 Explorativní, deskriptivní a kauzální výzkum

*Explorativní (průzkumný) výzkum* se zaměřuje na předběžné poznání problému a formulaci hypotéz. Využívá převážně sekundární zdroje.

*Deskriptivní výzkum* popisuje jevy na trhu bez snahy odhalit příčinné vztahy. Čerpá z primárních i sekundárních dat.

*Kauzální výzkum* zjišťuje příčinné vztahy mezi jevy, často pomocí experimentů nebo dotazování. [9],[12]

### 3 Zdroje business dat pro marketingové účely

Kvalitní data představují základ pro efektivní marketingové řízení. Klíčové je znát dostupné zdroje informací, ze kterých lze čerpat přehled o zákaznících, trhu i výkonnosti kampaní. Důležitou roli hraje nejen sběr a správa dat, ale i schopnost jejich smysluplného využití pro marketingová rozhodnutí.

#### 3.1 Získávání dat

Získávání dat (*data sourcing*) je systematický proces shromažďování nezpracovaných dat, která jsou klíčová pro podnikání. Tato data mohou pocházet z různých zdrojů – interních i externích. Sběr dat je prvním krokem v jakémkoliv procesu práce s daty.[15],[16],[17],[18],[19]

#### 3.2 Zdroje dat

Zdroj dat označuje místo, kde se data ukládají nebo odkud pocházejí informace týkající se produktů, zákazníků, konkurence a dalších oblastí. Data mohou být uložena v jednoduchých souborech, v databázích nebo v komplexních systémech.

Data vznikají při různých procesech a pocházejí například z:

- provozu systémů
- lidského chování (například interakce na webu)
- ručního zadávání údajů do systému
- obchodních procesů
- třetích stran

Firmy využívají tyto datové zdroje pro svou každodenní činnost i pro strategické rozhodování. [15],[16],[17],[18],[19]

#### 3.3 Interní zdroje business dat

Interní business data vznikají přímo činností firmy nebo organizace. Generují se například při prodeji, zákaznickém servisu, výrobě nebo interních procesech. Tato data se mohou vyskytovat v různých formátech, jako jsou tabulky, databáze nebo CRM systémy.

Interní data jsou pro firmy zásadní, protože:

- poskytují přehled o činnosti organizace
- umožňují analyzovat výkonnost
- slouží k optimalizaci firemních procesů
- pomáhají odhalovat slabá místa a příležitosti

Výhody interních dat spočívají především ve vysoké přesnosti a spolehlivosti, neboť pocházejí přímo z vlastních činností firmy. Další výhodou je úplná kontrola nad těmito daty, což umožňuje efektivní správu a flexibilní využití v marketingových i strategických rozhodnutích. V neposlední řadě interní data vznikají přirozeně v rámci běžné firemní činnosti, což znamená nižší finanční náklady na jejich sběr a zpracování.

Nevýhodou interních dat je jejich omezený pohled, protože popisují pouze činnost dané firmy a nezahrnují širší kontext trhu či chování konkurence. Firmy tak při spoléhání se pouze na interní data mohou ztrácet přehled o tržních změnách nebo o nových příležitostech mimo vlastní zákaznickou základnu. [9],[15],[16],[20]

Jako příklady interních zdrojů pro business data se uvádí:

- CRM systémy
- Transakční data
- Data o skladových zásobách
- Interní průzkumy a dotazníky

### 3.3.1 CRM systémy

Customer Relationship Management (CRM) představuje soubor strategií, procesů a technologií zaměřených na budování a udržování dlouhodobých vztahů se zákazníky. CRM lze chápat jak z technického pohledu, tedy jako soubor softwarových nástrojů pro řízení aktivit marketingu, obchodu a zákaznické péče, tak z manažerské perspektivy jako obchodní strategii zaměřenou na maximalizaci spokojenosti a hodnoty zákazníků. Společným jmenovatelem všech přístupů je důraz na dlouhodobé a efektivní vztahy se zákazníky.[15],[21],[22],[23]

#### Typy CRM systémů

CRM systémy se dělí na tři hlavní typy podle svého zaměření.

*Strategické CRM* se orientuje na vytvoření zákaznický orientované firemní kultury. Pomáhá identifikovat nejcennější zákazníky a přizpůsobit jim nabídku prostřednictvím segmentace trhu. Výhodou je hlubší porozumění potřebám klientů a posílení jejich loajality, nevýhodou je naopak náročnější implementace a pomalejší návratnost investic.[15],[16],[22]

*Operační CRM* usiluje o automatizaci klíčových procesů v marketingu, prodeji a zákaznických službách. Zahrnuje například automatizaci kampaní, správu obchodních příležitostí (lead management) či využití chatbotů. Přináší vyšší efektivitu a lepší zákaznickou zkušenost, avšak vyžaduje kvalitní data a důsledné zavedení napříč celou organizací. [15],[16],[22]

*Analytické CRM* se zaměřuje na sběr a analýzu dat o zákaznících. Podnikům umožňuje lépe porozumět chování zákazníků a efektivněji cílit marketingové a prodejní strategie. Klíčovou roli zde hrají techniky data miningu a prediktivní analytiky. Výzvou je potřeba kvalitních dat a vyšší náklady na implementaci. [15],[16],[22]

#### Hlavní funkce CRM systémů

CRM systémy plní zejména tři hlavní funkce: správu zákaznických dat, automatizaci procesů a integraci se systémy v rámci organizace. Centralizace dat umožňuje lepší personalizaci nabídky a efektivnější koordinaci práce napříč odděleními. Automatizace obchodních, marketingových a zákaznických procesů přispívá ke zvýšení efektivity i zákaznické spokojenosti. CRM systémy rovněž poskytují nástroje pro analýzu, reporting a integraci s ERP systémy či komunikačními platformami. [15],[16],[22]

## **Výhody a nevýhody CRM systémů**

CRM systémy umožňují firmám lépe porozumět zákazníkům, zvyšovat jejich loajalitu a efektivněji řídit interní procesy, čímž přispívají ke zvyšování ziskovosti. Výhodou je především lepší znalost zákazníků a zefektivnění interních procesů. Nevýhodou jsou naopak vyšší náklady na implementaci, nutnost práce s kvalitními daty a možný odpor zaměstnanců vůči zavádění nových technologií. [15],[16],[22],[24]

## **CRM systémy v praxi**

CRM nachází uplatnění napříč různými sektory – od e-commerce (personalizace nabídek a správa věrnostních programů), přes bankovníctví (segmentace zákazníků a prediktivní analýzy) až po zdravotnictví (správa patientských záznamů a automatizace komunikace). Firmy, které CRM systémy efektivně implementují, obvykle dosahují vyšší efektivity a lepší zákaznické zkušenosti. [15],[16],[22],[24]

### **3.3.2 Transakční data**

Transakční data představují klíčový zdroj informací pro firmy, protože zachycují všechny interakce mezi zákazníkem a organizací – od provedených plateb přes rezervace až po chování v online prostředí. Typickým znakem těchto dat je časový aspekt, který vyžaduje jejich rychlé zpracování pro zachování konkurenční výhody.

Hlavní přínos transakčních dat spočívá v identifikaci trendů v chování zákazníků a v optimalizaci marketingových i produktových strategií. Například pokud určitý produkt oslovuje specifickou demografickou skupinu, lze na ni cíleně zaměřit marketingové kampaně. Analýza transakčních dat rovněž přispívá ke zlepšení zákaznických služeb, zvýšení konverzního poměru a snížení počtu stížností.

Transakční data slouží také k hodnocení efektivity vnitřních procesů, například při rozhodování o tom, zda určité úkoly řešit interně či externě, nebo v rámci finanční analýzy, kde se sledují příjmy, výdaje a plánování rozpočtu. [25],[26],[27],[28]

Nejběžnější typy transakčních dat zahrnují údaje o objednávkách, jako jsou datum, částka a způsob platby, údaje o prodejkách včetně informací o slevách a akcích, údaje o vrácení zboží, tedy důvody reklamací a výše vrácených částek, a údaje o zákaznické podpoře, zahrnující počet stížností a rychlost řešení problémů. [26],[28]

### **Praktické využití transakčních dat**

V oblasti e-commerce se transakční data využívají ke sledování nákupních zvyklostí zákazníků, frekvence objednávek a průměrné výše útraty. V bankovníctví pomáhají identifikovat platební vzorce a řídit kreditní riziko. V sektoru cestovního ruchu umožňují transakční data personalizaci nabídek a dynamickou tvorbu cen na základě aktuální rezervační aktivity. [25],[26],[27],[28]

### 3.3.3 Zákaznické dotazování

Zákaznické dotazování patří mezi nejčastěji využívané metody sběru primárních dat v marketingovém výzkumu. Probíhá *přímým* (rozhovor) či *zprostředkovaným* (dotazník) pokládáním předem připravených otázek vybranému vzorku respondentů. Výběr konkrétní metody – osobní, telefonické, písemné nebo online – závisí na povaze výzkumu, finančních možnostech a dostupném čase.[9],[11],[29]

Dotazník je základním nástrojem pro systematický sběr dat. Při jeho tvorbě je klíčové dbát na několik aspektů: účelovou technickou stránku, která vyžaduje přesné formulace otázek, psychologickou stránku, tedy aby otázky byly snadné a příjemné k zodpovězení, a na srozumitelnost, což znamená, že instrukce musí být jasné a nevyžadující další vysvětlování.

Otázky v dotaznících mohou být různého typu. Otevřené otázky umožňují respondentům volně formulovat odpověď vlastními slovy; patří sem například volné otázky, asociační otázky nebo dokončování vět. Uzavřené otázky naopak nabízejí předem definované varianty odpovědí, a to buď ve formě dichotomických voleb (ano/ne), výběru z více možností, nebo seřazení variant podle preferencí. Polootevřené otázky pak kombinují oba přístupy – nabízejí předem připravené možnosti a zároveň umožňují doplnění vlastní odpovědi. Každý typ otázek má své výhody i nevýhody: otevřené otázky přinášejí pestřejší a hlubší odpovědi, ale jejich vyhodnocení je složitější, zatímco uzavřené otázky umožňují snadnější a rychlejší analýzu, avšak mohou omezit autenticitu odpovědí. [9],[11],[29]

Metody dotazování se liší podle formy provedení. Osobní dotazování umožňuje získat zpětnou vazbu a lépe interpretovat odpovědi, je však časově i finančně náročnější. Telefonické dotazování nabízí rychlé získání dat a nižší náklady, ale délka rozhovoru je omezená. Online dotazování je v současnosti nejrozšířenější díky nízkým nákladům a vysoké flexibilitě, je ovšem závislé na technické vybavenosti a ochotě respondentů. Písemné dotazování se dnes využívá méně kvůli nízké návratnosti, přesto se hodí pro oslovení širšího okruhu lidí v určitém segmentu. [9],[11],[29]

Výhodou dotaznickového šetření je široký dosah, možnost zachování anonymity respondentů a snadná analýza získaných dat. Nevýhodou jsou naopak nízká návratnost vyplněných dotazníků, riziko zkreslení odpovědí a vysoké nároky na kvalitní přípravu dotazníku. [9],[11],[29]

### 3.4 Externí zdroje business dat

Externí business data představují informace pocházející ze zdrojů nacházejících se mimo podnik. Jsou to tedy data, která firma nemá přímo pod svou kontrolou. Do této kategorie spadají údaje z veřejných databází, zákaznických průzkumů, sociálních sítí nebo výsledky průzkumů trhu prováděných třetími stranami. Firmy tento typ informací využívají pro analýzy trhu, konkurence, zákaznických preferencí či ekonomických trendů.

Obecně jsou externí data určena k doplnění interních dat a k rozšíření možností jejich analýzy. Často jsou veřejně dostupná nebo dostupná za úplatu či prostřednictvím obchodních partnerů. Externí data mohou firmám poskytnout přesnější předpovědi trendů a zákaznického chování. [9],[11],[16],[29],[30],[31],[32]

Externí data nacházejí uplatnění v marketingu, business intelligence a v operativním řízení organizací.

Mezi hlavní zdroje externích business dat patří:

- Veřejné databáze a vládní zdroje
- Sociální média
- Průzkumy trhů a výzkumné agentury
- Data od třetích stran
- Online analytické nástroje či vyhledávače
- Data z IoT senzorů

### 3.4.1 Veřejné databáze a vládní zdroje

Veřejné databáze a vládní zdroje představují důležitý externí zdroj dat pro firmy, které chtějí analyzovat ekonomické či nákupní trendy a lépe porozumět chování zákazníků na trhu. Tyto databáze zahrnují:

- národní vládní databáze a otevřená data
- mezinárodní a globální statistiky
- zdravotní a epidemiologická data
- finanční a tržní údaje
- geografická data

V České republice je hlavním poskytovatelem veřejných dat *Český statistický úřad*, který nabízí statistiky z ekonomické, sociální a environmentální oblasti. Dále je významným zdrojem *Ministerstvo financí*, poskytující data o státním rozpočtu a daních, a *Česká národní banka*, která zveřejňuje údaje o vývoji finančního trhu. Přístup k široké škále otevřených dat zajišťuje také portál *Otevřená data*. [33]

Na mezinárodní úrovni poskytují relevantní data například *Světová banka*, *Organizace spojených národů (OSN)*, *Mezinárodní měnový fond* a *Eurostat*, zaměřující se na ekonomické, sociální a environmentální statistiky. [33]

Zdravotní a epidemiologická data, například od *Světové zdravotnické organizace (WHO)*, slouží k analýze zdravotního stavu populace, výskytu nemocí a sledování pandemických trendů. [34]

Geografická data mají zásadní význam v oblastech, jako je marketing, logistika či environmentální analýzy. Kromě národních a mezinárodních databází je cenným zdrojem například *NASA EarthData*, která poskytuje satelitní snímky a klimatická data. [29],[30]

### 3.4.2 Sociální média

Data ze sociálních médií představují rychle rostoucí zdroj externích informací, které firmy využívají pro analýzu zákaznického chování, sledování trendů i řízení značky. Tato data pocházejí z platform, jako jsou *Facebook*, *Instagram*, *X* (dříve *Twitter*), *LinkedIn* nebo *TikTok*. [30],[35],[36]

Nejčastěji se využívají k analýze sentimentu, kdy se rozlišují pozitivní a negativní reakce na značku, ke sledování trendů pomocí populárních hashtagů nebo k analýze interakcí uživatelů

s reklamními kampaněmi. V oblasti business intelligence tato data slouží ke sledování reputace značky, konkurenční analýze a přesnému cílení reklam na základě chování a zájmů uživatelů.

Mezi používané nástroje patří například *Google Trends*, který slouží k vyhodnocování popularity klíčových slov, *Facebook Audience Insights* pro analýzu demografických a behaviorálních údajů uživatelů, nebo platformy jako *Hootsuite* a *Sprout Social* zaměřené na monitoring aktivit na sociálních sítích. Pro analýzu sentimentu s využitím umělé inteligence se používají systémy jako *Crimson Hexagon* či *IBM Watson*. [30],[35],[36],[37]

Výhodou dat ze sociálních médií je jejich rychlá dostupnost, globální dosah a nízká pořizovací cena oproti tradičním průzkumům. Na druhou stranu je však třeba počítat s rizikem nižší kvality a pravdivosti těchto dat, které mohou být ovlivněny například existencí falešných účtů nebo zkreslenými informacemi. [30],[35],[36]

### 3.4.3 Průzkumy trhů a výzkumné agentury

Průzkum trhu a data získaná od výzkumných agentur představují klíčový externí zdroj business dat. Jedná se o systematický proces shromažďování, analýzy a interpretace dat a informací o trhu. Poskytují důležité poznatky o spotřebitelském chování, trendech na trhu, konkurenčním prostředí a preferencích zákazníků. Cílem je poskytnout firmám informace, které jim pomohou při strategickém marketingovém rozhodování, a to kombinací interních a externích dat.

Mezi hlavní zdroje průzkumů trhu patří komerční výzkumné agentury, asociace a odborové organizace, veřejné a akademické zdroje a online průzkumy. Komerční výzkumné agentury, jako například společnost *Kantar*, poskytují data o spotřebitelských trendech, maloobchodním prodeji a dalších oblastech. Sběr dat pro tyto účely probíhá převážně formou dotazníkových šetření, telefonických průzkumů nebo analýz online chování.

Veřejné a akademické zdroje zahrnují veřejné databáze a výsledky výzkumů prováděných univerzitami a výzkumnými instituty, jako jsou *MIT Sloan* nebo *Harvard Business School*, které se zabývají oblastmi marketingu, ekonomiky a business analýzy.

Data získaná od výzkumných agentur prostřednictvím průzkumů trhu se následně využívají k predikci trendů, segmentaci zákazníků, testování produktů a marketingových kampaní. [9],[16],[38],[39]

### 3.4.4 Online analytické nástroje

Online analytické nástroje poskytují firmám cenné informace o chování zákazníků a o výkonnosti jejich webových stránek. Slouží ke shromažďování a analýze dat o uživatelském chování, návštěvnosti webových stránek a efektivitě marketingových kampaní.

Pro webovou analytiku se využívají zejména nástroje jako *Google Analytics*, který umožňuje měřit návštěvnost webu, sledovat konverze a analyzovat chování uživatelů. K monitorování výkonu jednotlivých marketingových kampaní se v praxi využívají nástroje jako *Google Ads* nebo *Facebook Ads Manager*, které poskytují podrobné informace o zásahu, interakcích a konverzních poměrech reklam.

Data získaná pomocí těchto nástrojů jsou klíčová pro tvorbu a optimalizaci digitálních marketingových strategií, zlepšování zákaznické zkušenosti a efektivnější plánování obchodních aktivit. [16],[29]

### 3.4.5 Data z IoT senzorů

*Internet věcí (IoT)* představuje síť propojených zařízení, vozidel a dalších objektů, které pomocí senzorů, softwaru a připojení ke cloudu sbírají a sdílejí data. Tento koncept otevírá firmám nové možnosti, jak efektivněji řídit procesy a lépe porozumět chování zákazníků.

IoT data umožňují podnikům analyzovat informace v reálném čase, což vede k personalizaci nabídek produktů a služeb a ke zlepšení zákaznické zkušenosti. Princip fungování IoT (viz. Obrázek 2 - Cyklus fungování IoT) zahrnuje čtyři kroky: sběr dat pomocí senzorů (například teplota, tlak, pohyb), přenos těchto dat do centrálního úložiště, jejich zpracování pokročilými analytickými metodami, jako je například strojové učení, a následné provedení akce na základě vyhodnocených výsledků. [16],[40],[41],[42]



Obrázek 2 - Cyklus fungování IoT

Zdroj: vlastní zpracování podle SAP [42]

Mezi běžné typy senzorů patří teplotní senzory využívané v chytrých domácnostech či meteorologii, tlakové senzory v průmyslu, pohybové senzory v bezpečnostních systémech, geolokační senzory v dopravě a dotykové senzory v mobilních zařízeních.

V marketingu se IoT data využívají k cílenému oslovení zákazníků, například na základě jejich polohy (GPS v chytrých telefonech) nebo údajů o životním stylu (z chytrých hodinek). Velký potenciál nabízí také koncept bezobslužných prodejen, jako je *Amazon Go*, kde senzory sledují pohyb zákazníků a jejich nákupy. IoT technologie rovněž umožňuje propojení zařízení s automatizovanými chatboty, kteří v reálném čase reagují na aktuální stav zařízení a pomáhají při řešení problémů.

Celkově IoT data přinášejí firmám možnost personalizace, rychlé reakce na změny a lepší rozhodování na základě aktuálních a reálných informací. [16],[40],[41],[42]

## 4 Digitální média

Od 90. let 20. století prošlo prostředí digitálních médií výraznou proměnou a nadále se dynamicky vyvíjí. V současnosti lze digitální média rozdělit do tří hlavních skupin: *placená*, *vlastněná* a *získaná média*. Toto rozdělení se souhrnně označuje jako model POEM.

Model POEM analyzuje, jaké kombinace digitálních médií jsou nejefektivnější pro získávání nových zákazníků, budování vztahů se stávajícími zákazníky a posilování pozice firmy na trhu. [43],[44]

### 4.1 Placená digitální média

Jak název napovídá, placená digitální média zahrnují všechny platformy, na kterých je za vystavení reklamy nutné zaplatit určitou částku. Jedná se o nejrozšířenější typ marketingových kanálů.

Placená média patří k nejrychlejším, nejúčinnějším a nejjednodušším metodám pro navázání kontaktu se zákazníky. Výhodou je jejich okamžitý dosah a možnost do jisté míry kontrolovat publikum, kterému se reklama zobrazí, a to díky přesnému cílení podle demografických údajů, zájmů či chování uživatelů. Výsledky kampaní jsou snadno měřitelné pomocí metrik, jako jsou *CTR (Click-Through Rate)*, *CPC (Cost Per Click)* nebo *ROAS (Return on Advertising Spend)*. [43]

Pod placená média spadají například PPC reklamy, reklamy na sociálních sítích, display reklamy, programatická reklama či sponzorovaný obsah.

Výhodou placených médií je okamžitý dosah a efekt reklamních kampaní, stejně jako možnost přesného cílení na konkrétní segment zákazníků. Správa kampaní rovněž umožňuje rychlé a efektivní měření jejich výkonnosti. Nevýhodou však zůstávají vyšší provozní náklady oproti ostatním formám digitálních médií. [43],[44],[45],[46]

#### 4.1.1 Měření úspěšnosti u placených médiích

U reklam ze skupiny digitálních placených médií se sledují zejména metriky:

- **CPC – Cost-Per-Click** – cena za jedno kliknutí na reklamní poutač
- **CTR – Click-Through Rate** – míra prokliku, počet osob, které klikly na reklamu
- **ROAS – Return on Ad Spend** – návratnost investice do reklamy
- **Konverzní poměr** – podíl osob, které po kliknutí na reklamu skutečně nakoupily

#### 4.1.2 Display reklama

Display reklama, v češtině známá také jako bannerová reklama, je grafická, obrázková či textová forma propagace tvořená reklamním proužkem. Bannery lze přirovnat k billboardům podél pozemních komunikací, jejichž hlavním cílem je zvýšit povědomí o značce.

Pro zobrazování tohoto druhu reklamy se využívá mnoho reklamních sítí, přičemž v současnosti je nejpoužívanější *Google Display Network* a reklamy zobrazované na *Facebooku*. Tyto sítě umísťují reklamy na webové stránky na základě kontextu nebo historie prohlížení uživatele, aby pravděpodobnost zaujetí reklamou byla co nejvyšší.

Display reklama se využívá zejména na webových stránkách a v mobilních aplikacích a často je součástí remarketingových kampaní. Zaměřuje se na uživatele, kteří již navštívili konkrétní web – například se jim opět zobrazí banner s produktem, který si v minulosti prohlíželi.

Klíčovými metrikami, které se u display reklamy sledují, jsou *CPM (Cost Per Mille)*, určující cenu za 1 000 zobrazení reklamy, *Viewability Rate*, udávající procento viditelnosti reklamy na stránce, a *Engagement Rate*, hodnotící míru uživatelské interakce s reklamním bannerem. [47]

### 4.1.3 PPC reklama

Pay-Per-Click (PPC) reklama je forma placené reklamy, kde se platí až za kliknutí na danou reklamu, nikoliv za její pouhé zobrazení. Cílem PPC je přivést uživatele přímo na webovou stránku firmy na základě konkrétní akce.

Princip fungování PPC reklamy spočívá v tom, že firmy definují, v jakých případech a na jakých místech se jejich reklama zobrazí. Mohou si nastavit klíčová slova, při jejichž vyhledání se jejich reklama objeví mezi placenými výsledky vyhledávačů. Po kliknutí uživatele na odkaz je účtována platba za proklik. Reklama se navíc v průběhu kampaně průběžně optimalizuje podle její výkonnosti.

Hlavní výhodou PPC reklamy je možnost cílení na uživatele, kteří aktivně vyhledávají informace spojené s nabízenými produkty či službami. Reklamu lze geograficky zaměřit pouze na určité oblasti a firmy mají plnou kontrolu nad rozpočtem i délkou trvání kampaně.

Mezi hlavní metriky sledované v rámci PPC kampaní patří *CPC (Cost-Per-Click)*, která vyjadřuje cenu za jedno kliknutí na reklamu, *CTR (Click-Through Rate)*, sledující procento uživatelů, kteří na reklamu klikli, a *Quality Score*, které hodnotí relevanci reklamy vzhledem k vyhledávaným dotazům a kvalitě vstupní stránky.

PPC reklama se využívá na mnoha platformách, mezi nejznámější patří *Google Ads*, *Facebook Ads*, *Instagram Ads*, a v českém prostředí také *Sklik od Seznamu*, který je obdobou *Google Ads*. [48],[49],[50],[51]

### 4.1.4 Programatická reklama

Programatická reklama, známá také jako *Real-Time Bidding (RTB)* reklama, využívá automatizaci k nákupu reklamního prostoru v reálném čase. RTB je založena na principu internetové dražby a poprvé vznikla v roce 2007 v USA; v České republice se začala prosazovat o pět let později.

RTB reklama funguje na základě nabídky a poptávky. Na straně nabídky se nachází majitel webové stránky, který prostřednictvím nástroje *SSP (Supply Side Platform)* nabízí reklamní prostor. Na straně poptávky je firma využívající *DSP (Demand Side Platform)*, která automatizovaně poptává a nakupuje reklamní prostor. *SSP* uvádí minimální cenu, za kterou je majitel ochoten reklamní plochu pronajmout, zatímco *DSP* nabídne maximální cenu, kterou je zadavatel ochoten zaplatit. Prostor získává ten subjekt, který nabídne nejvyšší částku. Tento proces probíhá automaticky bez nutnosti přímého vyjednávání.

Výhodou programatické reklamy je zejména možnost získat prémiové reklamní plochy, ke kterým není možné se dostat běžnými PPC kampaněmi. RTB umožňuje velmi přesné cílení i plánování reklamních aktivit a poskytuje přesná statistická data pro vyhodnocování efektivity kampaní. Nevýhodou je vyšší pořizovací cena oproti klasickým PPC reklamám. [52],[53]

## 4.2 Vlastněná digitální média

Druhým typem digitálních médií jsou vlastněná média. Jedná se o jakýkoliv kanál, který má firma plně pod svou kontrolou – spravuje ho i vlastní. Vlastněná média umožňují firmám budovat hlubší vztah se stávající klientelou a zároveň propagovat firmu a její nabídky na trhu.

Mezi hlavní představitele vlastněných médií patří například *webové stránky*, *firemní blogy*, sociální sítě jako *Instagram*, *Facebook* či *X* (dříve *Twitter*), *e-mailový marketing* nebo *kamenné prodejny*. Trendem v oblasti vlastněných médií jsou v současnosti také *podcasty*, které vydávají jednotlivé firmy.

Hlavním cílem vlastněných médií je poskytovat zákazníkům relevantní obsah a tím budovat jejich loajalitu a důvěru ke značce. Prostřednictvím vlastněných médií se firmy snaží omezit svou závislost na placených reklamních kanálech.

Výhodou vlastněných médií je především úplná kontrola nad zveřejňovaným obsahem a zároveň nižší náklady ve srovnání s placenými médii, kde je nutné hradit poplatky za propagaci. Díky vlastněným kanálům si firmy budují dlouhodobý vztah se zákazníky a posilují svou důvěryhodnost.

Nevýhodou je vyšší náročnost na tvorbu kvalitního obsahu, který je nezbytné pravidelně publikovat. Vybudování publika na vlastněných médiích trvá delší dobu než při využití placené propagace. Firmy jsou zároveň závislé na algoritmech vyhledávačů (SEO) a sociálních sítí, které ovlivňují viditelnost jejich obsahu. [43],[44],[45],[46]

### 4.2.1 Měření úspěšnosti u vlastněných médií

U reklam ze skupiny digitálních vlastněných médií se sledují zejména metriky:

- Počet návštěvníků webové stránky
- Doba, kterou návštěvník strávil na stránce
- Engagement na sociálních sítích – počet interakcí s příspěvky
- Open rate a CTR u e-mail marketingu – ukazuje funkčnost e-mailové komunikace

### 4.2.2 Firemní webové stránky

Firemní webové stránky představují jedno z nejsilnějších vlastněných médií. Mohou mít podobu prezentačních webů firmy nebo sloužit jako e-commerce platformy. Jsou klíčovým nástrojem pro reprezentaci značky, budování důvěry mezi společnostmi a jejich klienty a tvoří standardní součást komunikační strategie téměř každé firmy.

Hlavním účelem webových stránek je poskytování informací o firmě, produktech a službách, přičemž jejich součástí často bývá i firemní blog. Firemní webové stránky rovněž generují leady, tedy získávají kontaktní údaje potenciálních zákazníků.

Klíčové metriky sledované u tohoto mediálního kanálu zahrnují *počet návštěvníků webu*, *dobu, kterou návštěvníci na stránkách strávili*, *míru okamžitého opuštění webu (bounce rate)* a *konverzní poměr*, tedy podíl návštěvníků, kteří na stránce provedli požadovanou akci, například nákup v internetovém obchodě. [43],[44]

### 4.2.3 Firemní blogy

Firemní blogy jsou často integrální součástí webových stránek firmy a slouží jako nástroj obsahového marketingu. Jejich cílem je poskytovat návštěvníkům kvalitní a relevantní obsah, který se obvykle týká oboru, ve kterém firma působí. Obsah může zahrnovat odborné recenze produktů, návody na jejich používání, aktuality z odvětví nebo přehledy trendů.

Blogy zvyšují celkovou návštěvnost webu prostřednictvím SEO optimalizace. Kvalitní obsah poskytuje zákazníkům přidanou hodnotu, čímž posiluje důvěryhodnost značky a zlepšuje její pozici na trhu.

Mezi hlavní metriky sledované u firemních blogů patří počet přečtení článků, doba strávená čtením a počet sdílení článků na sociálních sítích. [43]

### 4.2.4 Sociální sítě

Po webových stránkách představují sociální sítě druhé nejvýznamnější vlastněné digitální médium. Slouží firmám k přímé komunikaci se zákazníky a umožňují budování komunity kolem značky.

Výběr konkrétní sociální sítě závisí na cílovém publiku a typu sdělení. Pro zvýšení povědomí o značce firmy často využívají *Facebook* nebo *Instagram*, zatímco pro nábor zaměstnanců a B2B marketing je vhodný *LinkedIn*. Rychlou komunikaci umožňuje síť *X* (dříve *Twitter*) a pro video marketing jsou oblíbené platformy jako *YouTube* nebo *TikTok*.

Obsah generovaný firmami na sociálních sítích odráží aktuální trendy a zaměření firmy. Publikovány jsou například edukační příspěvky, aktuality z oboru, firemní novinky či uživatelsky generovaný obsah související s využíváním produktů.

Na sociálních sítích se sledují zejména metriky zaměřené na míru zapojení komunity, například *počet interakcí u příspěvků, dosah příspěvků a nárůst počtu sledujících*. [43],[44]

### 4.2.5 E-mailový marketing

E-mailový marketing slouží firmám k cílené komunikaci se zákazníky a k budování dlouhodobých vztahů. Nejčastějšími formami jsou newslettery, obsahující pravidelné informace a novinky, a transakční e-maily, například potvrzení objednávek či zaslání faktur.

Výhodou e-mailového marketingu jsou výrazně nižší náklady oproti placené reklamě, možnost vysoké míry personalizace na základě předchozího chování uživatelů a možnost retargetingu, například při opuštění nákupního košíku.

Mezi hlavní sledované metriky v e-mailovém marketingu patří míra otevření e-mailů (open rate), míra prokliků na odkazy (CTR) a konverzní poměr.

Typickým příkladem úspěšného využití e-mailového marketingu je společnost Amazon, která rozesílá personalizované e-maily s doporučenými produkty na základě historie předchozích nákupů uživatele. [43]

### 4.3 Získaná média

Mezi získaná média patří veškeré zmínky o značce, které si firma nezaplatila ani sama nevytvořila. Jedná se o popularitu vznikající přirozenou cestou, kdy o značce mluví veřejnost. Tyto zmínky vznikají například prostřednictvím recenzí a hodnocení zákazníků, PR aktivit, word-of-mouth marketingu či sdílení na sociálních sítích.

Hlavním cílem získaných médií je zvýšení důvěryhodnosti značky prostřednictvím přirozené publicity. Pozitivní zkušenosti zákazníků přispívají k budování dobrého jména firmy, což zároveň snižuje náklady na placenou reklamu.

Získaná média vzbuzují u zákazníků vyšší důvěru než tradiční placená reklama a jejich dosažení je finančně méně náročné. Nevýhodou však je, že firma nemá kontrolu nad obsahem těchto zmínek, které mohou být jak pozitivní, tak i negativní. [43],[44],[45],[46]

#### 4.3.1 Měření úspěšnosti u získaných médií

Klíčové metriky, které se sledují u získaných médií jsou:

- Množství zmínek o značce na sociálních sítích
- Analýza sentimentu – jaký je podíl pozitivních a negativních zmínek
- Recenze a hodnocení zákazníků
- Návštěvnost webu z odkazujících zdrojů

#### 4.3.2 Recenze a hodnocení od zákazníků

Recenze a hodnocení od zákazníků tvoří klíčovou složku získaných médií. Hodnocení produktů a služeb se objevují například na *e-shopech*, v *Google Reviews*, na *Trustpilot* nebo na *portálu Heureka*.

Firmy aktivně podporují zákazníky k poskytování recenzí, například zasíláním e-mailových výzev po nákupu. Recenze slouží nejen ke zlepšování nabídky a služeb, ale jsou také cenným marketingovým nástrojem. Odpovídáním na recenze, zejména negativní, mohou firmy zmírnit jejich případný dopad.

Typickým příkladem je portál *Booking.com*, kde recenze skutečných klientů pomáhají dalším zákazníkům při rozhodování o ubytování. [43],[45],[54]

#### 4.3.3 Word-of-mouth marketing

*Word-of-mouth marketing*, známý také jako *šeptanda* nebo marketing doporučení, je forma propagace založená na ústním šíření doporučení. Lidé často více důvěřují doporučením známých než klasické reklamě, proto je tento typ marketingu velmi cenný.

Firmy dosahují efektu word-of-mouth marketingu především prostřednictvím kvalitních produktů a služeb, které zákazníci sami doporučují dále. Klíčovým nástrojem současnosti je také spolupráce s influencery, kteří svým komunitám doporučují produkty a služby na základě osobní zkušenosti. [55]

#### 4.3.4 PR a zmínky v médiích

Public relations a mediální zmínky patří k nejdůležitějším nástrojům získaných médií. PR aktivity pomáhají budovat reputaci firmy, zvyšovat povědomí o značce a posilovat důvěru veřejnosti.

Cílem PR aktivit je získat bezplatnou publicitu prostřednictvím *tiskových zpráv, článků v médiích, televizních a rozhlasových reportáží nebo podcastů*. Tyto formy publicity přispívají k pozitivnímu vnímání značky a mohou významně ovlivnit veřejné mínění.

Výhodou PR je nižší nákladovost oproti placené reklamě a dlouhodobý efekt na vnímání značky. Nevýhodou je však omezená kontrola nad obsahem zveřejněných materiálů, což může vést i k negativní publicitě.

Úspěšnost PR se měří prostřednictvím počtu zmínek v médiích, analýzy sentimentu, dosaženého dosahu a počtu přečtení jednotlivých článků. [44]

#### 4.3.5 Sdílení na sociálních sítích

Sociální sítě představují silný nástroj pro organickou propagaci značky. Zákazníci zde často dobrovolně sdílejí obsah spojený se značkou, čímž přirozeně zvyšují její dosah a viditelnost.

Firmy podporují sdílení například prostřednictvím hashtagů a zapojením se do aktuálních trendů. Tímto způsobem mohou získat virální obsah, který osloví široké publikum. Aktivní komunikace se zákazníky na sociálních sítích dále přispívá k posilování vztahů s komunitou.

Příkladem úspěšné kampaně využívající sdílení na sociálních sítích je iniciativa společnosti Starbucks, která vytvořila vánoční soutěž na Instagramu. Uživatelé sdíleli fotografie svých vánočních kelímků s hashtagem *#StarbucksRedCup*, čímž pomohli zvýšit viditelnost značky. [56],[57]

## 5 Metody a techniky analýzy business dat

Pro správné vyhodnocení dat je nezbytné zvolit vhodné analytické přístupy. Existuje široké spektrum metod, které pomáhají odhalovat souvislosti, vzorce a trendy. Výběr konkrétní techniky závisí na cíli analýzy i povaze dostupných dat, přičemž správná kombinace metod může výrazně zvýšit hodnotu získaných poznatků.

### 5.1 Tradiční přístup k analýze dat

Tradiční přístupy k analýze dat představují základní nástroje využívané v oblasti business datové analytiky již desítky let. Zahrnují popisné, deduktivní a explorační metody, které slouží k hlubšímu porozumění datům, testování hypotéz nebo objevování nových vazeb. [58],[59],[60],[61]

#### 5.1.1 Popisné metody

Popisné metody, taky označované jako deskriptivní, jsou analytické přístupy, které mají shrnout, uspořádat a jednoduše vyjádřit základní vlastnosti datových souborů. Obvykle jsou využívány v prvním kroku celkové analýzy dat, jelikož umožňují získat představu o tom, co se v souboru nachází předtím, než se provede hlubší analýza. Cílem deskriptivní statistiky je sumarizovat kategoriální a číselné údaje. Mají za cíl poskytnout základní přehled, na kterém se pak staví pro další modely a interpretace dat.

Nejpoužívanějším typem popisných statistik jsou míry středu. Jedná se například o průměrnou hodnotu, medián nebo modus. Tyto hodnoty se využívají napříč celou statistikou k definování a popisu souboru dat. Dalším využívaným typem popisné statistiky jsou míry variability. Ty mají ukázat, do jaké míry se jednotlivé hodnoty od sebe liší. Spadá sem například rozptyl, směrodatná odchylka nebo rozsah. Spadá sem také frekvenční rozdělení datového souboru, které popisuje, kolikrát se jednotlivé hodnoty zde vyskytují. Zjišťuje se pomocí výpočtu četnosti a relativní četnosti.

Pro lepší přehlednost a interpretovatelnost se data vizualizují pomocí grafických nástrojů do tabulek či grafů, např. histogramy se využívají pro vyobrazení rozložení hodnot v souboru.

V praxi se popisná statistika využívá například v oblasti marketingu, kde slouží ke shrnutí demografických údajů, v zákaznické analýze se vypočítává průměrný útrata či se v rámci kampaní vypočítává průměrné CTR. [58],[59],[62]

#### 5.1.2 Deduktivní metody

Deduktivní nebo inferenční statistické metody, je odvětví statistiky, které za pomoci různých analytických nástrojů vyvozují závěry o celkové populaci ze vzorku dat. Analýza tedy data pouze nepopisuje, ale rozhoduje, zda zjištěný výsledek má obecnou platnost či nikoliv. Jedná se o klíčový nástroj pro formulaci a ověřování hypotéz, porovnávání skupin a měření vztahů mezi poměny. Cíl deduktivní statistiky je v zobecňování celkové populace.

Klíčovou metodou v rámci inferenční analýzy je testování hypotéz, které se provádí za účelem zjištění, zda má rozdíl mezi skupinami statistický význam. To se provádí pomocí T-Testu nebo testu ANOVA. Dále se provádí regresní analýza, která má za cíl odhalit vztahy mezi jednotlivými proměnnými. V marketingu se to dá využívat na zjištění, zda má výše vynaložených nákladů na reklamu vliv na výnosy z tržeb. Výpočet korelace má měřit sílu

a směr lineárního vztahu mezi proměnnými. Například zda má vliv počet rozeslaných newsletterů na to, kolik lidí navštíví webové stránky.

Jelikož deduktivní metody pracují s pravděpodobností, tak nikdy výsledkem neřeknou, zda hypotéza platí či neplatí. Výsledkem je, s jakou pravděpodobností daná hypotéza je pravdivá či nikoliv.

V praxi se využívají například při testování kampaní, kde se využívá T-test, který porovnává konverzi u dvou verzí e-mailového newsletteru. Při marketingových výzkumech se testuje hypotéza, zda se výsledek dá zobecnit na celou populaci či se jedná pouze o výjimku. [58],[59],[63]

### 5.1.3 Explorační metody

Explorační analytické metody mají za cíl objevovat struktury, vzorce, vztahy a anomálie v datech. Na rozdíl od deduktivních metod, nepotřebují metody explorační předem stanovenou hypotézu, kterou by pomocí analýzy ověřovali. Kombinují se v ní kvantitativní přístupy, jako je statistika či korelace s kvalitativními přístupy jako je vizualizace a interpretace. Explorační analýza je považována za nezbytný první krok při každé hlubší analytické práci.

Cílem explorační analýzy je získat přehled o datovém souboru, o jeho rozsahu a kvalitě obsahovaných dat. Má odhalit odlehlé hodnoty, skryté souvislosti mezi jednotlivými proměnnými a zjistit, zda jsou data vhodná pro další analýzy.

Klíčovou technikou v rámci exploračních metod je vizualizace dat pomocí *histogramů* (zobrazuje rozložení četnosti jednotlivých jevů), *boxplotů* (zobrazuje rozsah, mediány a odlehlé hodnoty) nebo *scatter plotů* (zobrazuje vztah mezi dvěma číselnými proměnnými). Dále do kategorie exploračních metod spadá *matice korelací*, *shluková analýza* nebo *heatmapy*.

V praxi se explorační analýza využívá při zákaznické segmentaci, kdy se vizualizují vzorce nákupního chování. Při detekci podvodů, pomocí odhalování odlehlých hodnot a neobvyklých transakcí. Používají se také při předzpracování dat, kdy se identifikují chybné a chybějící hodnoty. [58],[59],[64],[65]

## 5.2 Moderní metody analýzy

V souvislosti s neustále rostoucím množstvím dat se objevují nové přístupy a technologie, které usilují o efektivnější zpracování, analýzu a interpretaci těchto dat. V čele se strojovým učením, data miningem nebo analýzou sentimentu se tyto principy stávají klíčovým nástrojem nejen v oblasti marketingu.

Na rozdíl od tradičních metod analýzy dat, jsou tyto přístupy často schopné automaticky odhalovat složité vzorce v datech bez nutnosti stanovování předchozích hypotéz.[58]

### 5.2.1 Strojové učení

Strojové učení (machine learning) je podmnožinou umělé inteligence, která umožňuje strojům učit se z dat a na jejich základě vytvářet predikce či rozhodnutí bez nutnosti explicitního naprogramování. Algoritmy strojového učení hledají vzory v datech a vytvářejí modely, jejichž přesnost se zvyšuje s rostoucím množstvím vstupních informací. V marketingu i byznysu je strojové učení využíváno k analýze zákaznického chování, personalizaci kampaní či predikci poptávky. [2],[58],[66],[67],[68]

Strojové učení lze rozdělit do tří hlavních kategorií:

- **Učení s učitelem (supervised learning)** – model se učí na datech, kde jsou známy vstupy i správné výstupy.
- **Učení bez učitele (unsupervised learning)** – model pracuje s daty bez předem definovaných výstupů, hledá v nich skryté vzory.
- **Zpětnovazební učení (reinforcement learning)** – model se učí na základě odměn a trestů v průběhu interakce s prostředím.

### Učení s učitelem

Učení s učitelem vyžaduje trénovací data obsahující vstupy i správné výstupy. Cílem je, aby model dokázal správně predikovat nové hodnoty. Typickými úlohami jsou *klasifikace* (např. predikce nákupu – ano/ne) a *regrese* (např. předpověď tržeb).

Mezi běžné algoritmy patří:

- **Lineární regrese** – predikce spojité hodnoty
- **Logistická regrese** – predikce kategorií (binární klasifikace)
- **Rozhodovací stromy** – rozhodování na základě sekvence otázek

Výhodou je přesnost predikcí při kvalitních datech, nevýhodou pak vysoká náročnost na přípravu dat a odbornou implementaci. V marketingu se využívá například k segmentaci zákazníků nebo predikci pravděpodobnosti nákupu.[58],[69],[70],[71],[72],[73]

### Učení bez učitele

Učení bez učitele pracuje pouze s neoznačenými daty a cílem je odhalit v nich přirozené struktury. Nejčastěji se využívá:

- **Shlukování (clustering)** – seskupování dat podle podobnosti (např. K-means clustering při segmentaci zákazníků).
- **Pravidla asociace** – odhalování souvislostí mezi proměnnými (např. analýza nákupního koše).
- **Redukce rozměrnosti** – zjednodušení dat (např. analýza hlavních komponent PCA).

Výhodou je schopnost objevovat nové vzorce bez nutnosti znalosti správných odpovědí, nevýhodou vyšší výpočetní náročnost a složitější interpretace výsledků. [2],[58],[74],[75],[76]

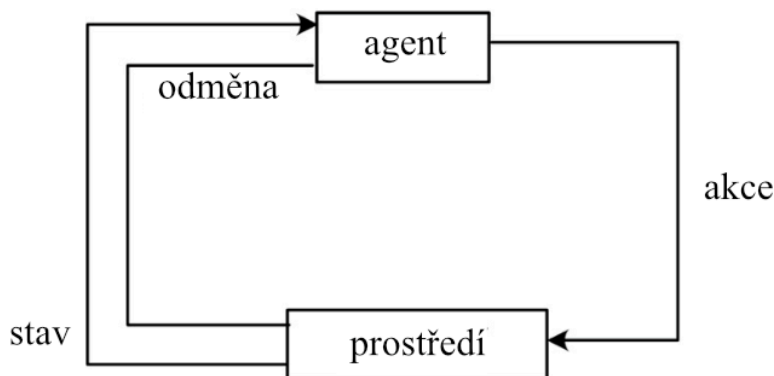


Obrázek 3 - Algoritmus učení bez učitele

Zdroj: Vlastní zpracování podle MathWoks [74]

## Zpětnovazební učení

Zpětnovazební učení funguje na principu odměn a trestů. Agent (např. marketingový algoritmus) v prostředí volí akce a na základě zpětné vazby se postupně učí optimalizovat své chování.



Obrázek 4 - Zpětnovazební učení

Zdroj: Vlastní zpracování podle IBM [77]

Využívá se například:

- v personalizaci obsahu v reálném čase (nabídka vhodných produktů na e-shopu)
- při dynamickém stanovování cen
- v automatizaci rozhodovacích procesů

Výhodou je adaptabilita na měnící se podmínky, nevýhodou vysoké nároky na výpočetní výkon a obtížná přenositelnost mezi různými úkoly. [2],[58],[77],[78],[79]

### 5.2.2 Data mining

Data mining, v češtině označovaný také jako dolování dat, je proces systematického vyhledávání užitečných a dříve neznámých vzorců, struktur, pravidel nebo vztahů ve velkých datových souborech. Stručně řečeno – cílem data miningu je získávat hodnotné informace z rozsáhlých dat. Data mining lze využít v široké škále oblastí, od identifikace nákupního chování zákazníků přes analýzu zájmů až po detekci podvodů.

Ačkoli se pojmy strojové učení a data mining částečně podobají, jedná se o odlišné přístupy k analýze dat. Zatímco cílem strojového učení je vytvoření modelu schopného predikce nebo klasifikace nových vstupů, data mining se zaměřuje na objevování dosud neznámých a potenciálně užitečných vzorců v historických datech.[82],[83]

Prostřednictvím data miningu se firmy snaží objevit nové vzorce chování zákazníků, nalézt asociace mezi produkty nebo službami, identifikovat jednotlivé zákaznické segmenty a predikovat jejich budoucí chování. Rovněž se využívá k detekci anomálií a podvodů.

Mezi typické techniky využívané při dolování dat patří:

- **Asociační pravidla** – hledání pravidel typu „Když X, pak Y“.
- **Shluková analýza** – seskupování podobných záznamů na základě jejich vlastností.
- **Klasifikace** – rozřazování objektů do kategorií podle jejich charakteristik.

V praxi se data mining uplatňuje například v marketingu pro analýzu kombinací produktů, které zákazníci nejčastěji nakupují společně, při zákaznické segmentaci v rámci zákaznické analytiky nebo ve finančním sektoru pro detekci podvodů a hodnocení úvěrového rizika.

Aplikací metod data miningu mohou firmy odhalovat nové poznatky a trendy ve svých datových souborech. Jelikož se jedná o všestranný nástroj, jeho přínosy mohou využívat prakticky všechna oddělení firmy.

Nevýhodou data miningu je však jeho technická složitost. Vyžaduje pokročilé technické dovednosti a specializované softwarové nástroje, což může některým společnostem představovat překážku při jeho zavádění. Kromě toho je třeba počítat s vyššími náklady, a to jak na získávání velkých a rozmanitých datových souborů, tak na jejich kvalitní zpracování. Firmy mohou data získávat vlastním sběrem, což je finančně náročné, nebo jejich nákupem od externích zdrojů, což rovněž znamená nemalé investice. [2],[58],[80],[81],[82],[83]

### **Proces data miningu**

Proces data miningu je obvykle realizován podle metodologie CRISP-DM (Cross-Industry Standard Process for Data Mining), která se skládá ze šesti hlavních fází:

- porozumění byznysovému problému
- porozumění dostupným datům
- příprava dat
- modelování
- vyhodnocení výsledků
- praktické nasazení modelu

Cílem není pouze technické zpracování dat, ale především objevování užitečných vzorců v datech.

V první fázi si musí společnost stanovit své obchodní cíle. Tento krok je považován za jeden z nejnáročnějších v celém procesu dolování dat. Na definici cíle spolupracují datoví vědci společně s vedením společnosti tak, aby byl problém vymezen co nejpřesněji.

Po jasném vymezení problému je snazší určit, jaký datový soubor bude potřebný. Je třeba zvolit taková data, která pomohou odpovědět na stanovené otázky a vyřešit zadaný problém.

Následuje fáze přípravy dat pro budoucí analýzu. V této fázi je nutné očistit data od šumu, kterým se rozumí například duplicitní, chybějící nebo odlehlé hodnoty. V případě potřeby dochází také ke snížení hloubky datového souboru, přičemž je nezbytné zachovat nejdůležitější proměnné.

Po přípravě dat přichází na řadu tvorba modelu a samotné dolování vzorců. Výběr vhodné techniky závisí na typu problému – mezi často využívané techniky patří asociační pravidla, shluková analýza, klasifikace či regrese.

Po vytvoření modelu následuje jeho vyhodnocení, které nezahrnuje pouze statistickou validaci, ale především zhodnocení praktické využitelnosti z hlediska byznysu. Například může být objeveno pravidlo s vysokou pravděpodobností, ale pokud není prakticky využitelné, nemá pro firmu přínos.

Proces dolování dat vrcholí implementací změn vyplývajících z analýzy. Nově zavedené změny jsou následně monitorovány a vedení společnosti hodnotí, zda měly požadovaný přínos. [2],[58],[80],[81]

### **Bodovací metoda s váhami**

Bodovací metoda s váhami je tradiční technikou rozhodování, která nachází široké využití v marketingu při hodnocení variant na základě předem stanovených kritérií. Patří mezi vícekritériální rozhodovací metody, které jsou využívány v situacích, kdy je třeba porovnávat více alternativ z hlediska několika různých hledisek.

Princip bodovací metody spočívá v tom, že každému kritériu je přiřazena určitá váha, která vyjadřuje jeho důležitost v rozhodovacím procesu. Následně jsou jednotlivé varianty bodově ohodnoceny podle toho, jak danému kritériu vyhovují. Celkové skóre varianty se vypočítá jako vážený součet bodů – tedy součet součinů váhy a bodového hodnocení pro každé kritérium. [83]

Postup bodovací metody s váhami lze shrnout do několika kroků:

- **Definice variant** – stanovení alternativ, které budou porovnávány.
- **Určení kritérií** – výběr klíčových hledisek, podle nichž se bude hodnotit.
- **Přiřazení vah kritériím** – váhy vyjadřují relativní důležitost jednotlivých kritérií, obvykle v rozmezí 0–1, přičemž součet všech vah je roven 1.
- **Bodové ohodnocení variant** – u každé varianty je stanoveno, jak dobře naplňuje jednotlivá kritéria, obvykle na škále (např. 1–5 nebo 1–10).
- **Výpočet celkového skóre** – pro každou variantu se vypočítá vážený součet bodů.
- **Výběr nejlepší varianty** – nejlepší varianta je ta, která dosáhne nejvyššího celkového skóre.

Výhodou bodovací metody s váhami je její jednoduchost, přehlednost a snadná aplikovatelnost v různých oblastech marketingu, například při hodnocení potenciálních zákaznických segmentů, výběru cílových skupin či optimalizaci marketingových kampaní.

Nevýhodou však může být vyšší subjektivita při stanovení vah a hodnocení jednotlivých variant, což může vést ke zkreslení výsledků.[83]

### **Text mining**

Dolování textu, také označované jako textová analytika, je proces, při kterém se transformuje nestrukturovaný text do strukturovaného formátu s cílem identifikovat relevantní informace, vzorce a nové poznatky. Používá se k analýze obsahu textů, které nemají pevnou tabulkovou strukturu.

Hlavním cílem text miningu je porozumět obsahu textu, identifikovat klíčová témata či slova a zachytit, o čem se diskutuje. Následně je důležité určit sentiment, tedy zda je diskuse vedena v pozitivním, neutrálním, či negativním tónu. Analýzy zároveň slouží ke třídění a klasifikaci textů podle jejich obsahu nebo vyjádřeného názoru.

Základní techniky text miningu se zaměřují na jednotlivá slova či fráze v každém dokumentu a lze je rozdělit do tří skupin podle zaměření: vyhledávání informací, zpracování přirozeného jazyka a extrakce informací.

Vyhledávání informací je proces zaměřený na nalezení relevantních textů na základě zadaného dotazu. Tento druh algoritmů se běžně používá v katalogových systémech a internetových vyhledávačích, jako je *Google*. V rámci těchto analýz se využívá technika tokenizace, jejímž cílem je rozdělit text na jednotlivá slova či fráze (tzv. tokeny), které následně slouží jako základní jednotky pro další analýzy.

*Zpracování přirozeného jazyka (Natural Language Processing, NLP)* je metodologie vyvinutá na základě počítačové lingvistiky, datové vědy a umělé inteligence. Jejím cílem je umožnit počítačům rozumět lidskému jazyku, a to jak v psané, tak i v mluvené podobě. Do oblasti NLP patří například *sumarizace dlouhých textů* (zkrácení textu na hlavní body), *PoS tagování* (přirazení slovních druhů jednotlivým tokenům) či *analýza sentimentu*, která umožňuje marketingovým specialistům sledovat, zda zákazníci vyjadřují pozitivní, neutrální, nebo negativní postoje vůči značce. Tento proces umožňuje monitorovat změny v názorech a náladách zákazníků v čase.

Extrakce informací je proces zaměřený na vyhledávání specifických údajů z různých dokumentů, a jejich transformaci do strukturované podoby.

V praxi se text mining využívá například při budování image značky sledováním zmínek o firmě na internetu či sociálních sítích. V oblasti e-commerce se uplatňuje při analýze recenzí produktů a identifikaci klíčových problémů či trendů v zákaznických hodnoceních. [86],[87],[87]

### **5.3 Business Intelligence a její analytické nástroje**

Business Intelligence, zkráceně označovaná jako BI, je souhrnný pojem pro soubor procesů, aplikací a technologií, které dnes tvoří běžnou součást řízení podniků a jejich informačních systémů. BI umožňuje sbírat, analyzovat a interpretovat data za účelem podpory rozhodování v rámci organizace.

Aplikace BI pokrývají jak analytickou, tak plánovací funkci většiny oblastí podnikového řízení – od prodeje a nákupu až po řízení lidských zdrojů. Mezi nástroje a aplikace Business Intelligence patří například datová uložště, datové sklady, reportingové nástroje, manažerské aplikace či nástroje pro správu metadat.

Cílem BI je poskytovat správné informace správným lidem ve správný čas tak, aby bylo podpořeno kvalitní rozhodování napříč odděleními. To přispívá ke zvyšování efektivity firemních procesů, včasné identifikaci rizik a odhalování nových příležitostí.

Využívání BI přináší firmám řadu výhod. Umožňuje podporovat rozhodování založené na faktech, nikoliv na domněnkách, a pomáhá zaměstnancům vyhledávat relevantní poznatky k řešení problematice. Nástroje BI zároveň umožňují měřit a sledovat výkon klíčových ukazatelů, monitorovat pokrok směrem k dosažení cílů a upozorňovat na odchylky včas.

Celkově využívání Business Intelligence přispívá ke zvýšení tržeb i ziskovosti firem. Mezi hlavní výzvy při implementaci BI patří kvalita a dostupnost analyzovaných dat, protože model BI je jen tak kvalitní, jak kvalitní jsou vstupní data. Další výzvou je nutnost školení zaměstnanců, aby dokázali s BI nástroji efektivně pracovat.

V praxi se Business Intelligence využívá zejména v marketingu pro sledování výkonnosti reklamních kampaní nebo segmentaci zákazníků. Své uplatnění však nalézá také ve zdravotnictví, logistice či v oblasti řízení lidských zdrojů (HR). [89],[90],[91],[91]

### 5.3.1 Nástroje Business Intelligence

V současné době existuje velké množství nástrojů spadajících do kategorie Business Intelligence, přičemž jejich zaměření se neustále rozšiřuje. Firmy po celém světě je využívají pro své analýzy, vizualizace a jako nástroj pro podporu jejich rozhodování.

V rámci marketingu se nejčastěji využívá *Google Analytics*, *Looker Studio*, *Tableau*, *Power BI* a mnoho dalších.[92]

#### Google Analytics

Google Analytics je bezplatný nástroj od společnosti Google který se od jeho vzniku v roce 2005 stal nejpopulárnějším nástrojem pro analýzu webových stránek na světě. Je určen pro vlastníky webových stránek a aplikací, kteří chtějí lépe porozumět jejich výkonu. Umožňuje jim sledovat a analyzovat chování návštěvníků.

Jedná se o základní ale přesto velice užitečný nástroj pro webovou analytiku, zejména v oblasti online chování uživatelů, měření výkonnosti marketingových kampaní nebo optimalizace webových stránek.

Google Analytics sleduje celou řadu činností, které provádějí zákazníci na internetu. Spadá sem například to, odkud uživatel přišel na webovou stránku, jak interaguje s obsahem na webu, zda uživatel provedl požadovanou konverzi s webem a množství dalších souvisejících faktorů. Sleduje činnost uživatelů napříč zařízeními, dokáže tak propojit data pocházející z mobilních telefonů, webů či aplikací.

V prostředí Google Analytics se pracuje se dvěma základními typy dat – metrikami a dimenzemi. Metriky jsou číselné hodnoty, které ukazují například kolik uživatelů navštívilo webovou stránku nebo jak dlouho zde byli. Metriky se vztahují k dimenzím. Dimenze představují kvalitativní popisy informace jako je například odkud zákazník přišel na webovou stránku či z jakého zařízení. Jejich kombinací lze získat podrobné a srozumitelné přehledy o chování uživatelů na webových stránkách.

Typické metriky, které se vyskytují v Google Analytics jsou například:

- *Sessions* = Počet návštěv stránky
- *Users* = Počet uživatelů, kteří navštívili web
- *New users* = Počet nových uživatelů, kteří navštívili web
- *Engaged sessions* = Návštěvy, kde uživatel aktivně interagoval
- *Conversions* = Počet splněných konverzí

Hlavní výhodou, která mnohé firmy přiláká k používání Google Analytics je fakt, že je zadarmo. Proto se z něj stal ideální nástroj i pro malé firmy. Poskytuje komplexní přehled o uživateli, díky sledování uživatelů napříč zařízeními. Zaznamenává velké množství interakcí uživatelů s webem, na základě kterých je možné provést detailní analýzu jejich chování. V kooperaci s dalšími nástroji od Google jako je Ads nebo Search Console se z něj stává ideální nástroj pro internetový marketing. V neposlední řadě poskytuje data v reálném čase spolu s aktuálními přehledy.

Nevýhodou však může být absence některých známějších metrik nebo omezenost exportování dat. [94],[95],[96],[97],[97]

### **Looker Studio**

Looker Studio, původně známé jako Google Data Studio, je další nástroj od společnosti Google, který slouží k vytváření vizualizací a reportování dat. Společnost ho popisuje jako drag-and-drop nástroj, který přemění firemní data na interaktivní a vizuálně působivé reporty.

Umožňuje vytvářet interaktivní dashboardy, které vyobrazují jednotlivé metriky pomocí tabulek, grafů nebo i map. Data získává přímým napojením na jednotlivé datové zdroje – Google Analytics, Sklik nebo Facebook Ads. Data se pak automaticky aktualizují podle datumu. Reporty je možné pak sdílet prostřednictvím Google dokumentů. Typicky se využívá pro vytváření reportů jednotlivých marketingových kampaní.

Stejně jako tomu je u Google Analytics, tak i u Looker Studio je velká výhoda v nulové pořizovací ceně softwaru. Jedná se o velice snadný nástroj pro použití díky drag-and-drop systému tvorby reportů. Výhodou je možnost sjednocení různých datových zdrojů, které se pak i automaticky aktualizují.

Nevýhodou je jeho závislost na zdrojích dat, které pocházejí od třetích stran – Facebook Ads či Sklik. Obecně není vhodný pro práci s velkými daty nebo pro pokročilé výpočty. [99],[99]

### **Tableau Software**

Tableau je jeden z nejrozšířenějších nástrojů Business Intelligence na světě od společnosti Salesforce. Je to výkonný nástroj používaný pro vytváření poutavých vizualizací, analýzu a sdílení dat. Oblibě se těší zejména u korporátních firem díky své flexibilitě, rychlosti a kvalitě.

Tento nástroj je vhodný pro vytváření interaktivních vizualizací – grafů, map, heatmap, časových řad a podobných. Tableau je možné napojit na několik různých datových zdrojů. V rámci analýzy a správy datových souborů je možné vytvářet i vlastní metriky, filtry či proměnné. Pro pokročilé analýzy mohou společnosti využít možnost integrace programovacích jazyků jako je R či Python nebo využití různých AI modelů.

Tableau je velice uživatelsky přívětivý nástroj pro vytváření přehledů bez nutnosti znalosti psaní kódu. Vyznačuje se schopností vytvářet velice kvalitní a přehledné vizualizace a zároveň svou flexibilitou při tvorbě reportů. Stejně jako tomu je u předchozích nástrojů tak i Tableau má schopnost napojení se na vícero datových zdrojů – od Google Analytics po různé datové sklady.

Nevýhodou tohoto nástroje oproti ostatním je, že není k dispozici zdarma a pro plný přístup je nutné zakoupit licenci. Existuje však i bezplatná verze tohoto nástroje, a to Tableau Public. Vzhledem k tomu, že je schopen pracovat s většími datovými soubory a provádět náročnější operace, vyžaduje také vyšší výpočetní výkon. Nevýhodou může být omezené využití v offline prostředí, protože jeho hlavní výhodou je právě práce s online daty a napojením na online datové zdroje [101],[102],[102]

### **Power BI**

Power BI je dalším klíčovým nástrojem v oblasti Business Intelligence, vyvinutým společností Microsoft. Tento nástroj je zaměřen na analýzu a vizualizaci nezpracovaných dat s cílem

efektivně prezentovat výsledky. Je součástí ekosystému Microsoft 365, což zaručuje bezproblémovou integraci s nástroji, jako jsou Excel, Azure nebo SharePoint.

Nástroj umožňuje importovat a transformovat data prostřednictvím funkce ETL. Data lze vizualizovat ve formě tabulek, grafů nebo KPI karet, které zobrazují klíčové ukazatele výkonnosti. Nabízí možnost vlastních výpočtů pomocí jazyku DAX, který se využívá pro zpracování a analýzu dat. Zároveň má podporu AI funkcí či funkcí strojového učení.

Výhodou použití Power BI je jeho propojenost s ekosystémem Microsoft, proto je ideální volbou pro firmy, které pracují s produkty MS Office. Zároveň je k dispozici zdarma pro tvorbu reportů. Je vhodný pro práci s velkými daty a pro automatizovanou tvorbu reportingu, jelikož má možnost plánované obnovy dat. Umožňuje tvořit pokročilejší datové analýzy, pracuje s predikcí a segmentací.

Nevýhodou je, že pro plné fungování cloudového sdílení musí firma zakoupit verzi Power BI Pro, která tuto funkci umožňuje. Jistá omezení se mohou skrývat ve složitosti jazyku DAX, který je určen pro výpočty složitějších operací. [104],[105],[105]

## 6 Role big data v marketingu

### 6.1 Big data

Pojem big data označuje velké objemy digitálních informací, které jsou natolik rozsáhlé a různorodé, že je nelze efektivně zpracovávat tradičními databázovými nástroji. Big data jsou charakterizována pěti hlavními vlastnostmi známými jako model 5V: *objem (volume)*, *různorodost (variety)*, *rychlost (velocity)*, *důvěryhodnost (veracity)* a *hodnota (value)*.

Objem dat představuje množství informací, které mohou zahrnovat až miliardy záznamů. Různorodost zdůrazňuje, že data mají různou strukturu – od textů a obrázků až po data ze senzorů nebo sociálních sítí. Rychlost se vztahuje k tempu, jakým data vznikají, často v reálném čase. Veracity se zabývá otázkou kvality a spolehlivosti dat, která je zásadní pro správné interpretace. Hodnota pak označuje potenciál dat přinést firmám užitečné a obchodně relevantní informace [107],[108],[109],[110],[111],[111]

#### Zpracování a ukládání

Vzhledem k rozměrům a charakteru big data bylo nutné vyvinout nové technologie, které umožní jejich efektivní ukládání a analýzu. [107],[108]

#### Ukládání

Mezi klíčové technologie pro ukládání velkých dat patří *distribuované souborové systémy* a *NoSQL databáze*.

Distribuované souborové systémy, jako například *Hadoop Distributed File System (HDFS)*, rozdělují data na menší bloky a ukládají je paralelně na více serverech. To umožňuje škálovatelnost a zajišťuje odolnost systému i v případě výpadku jednotlivých uzlů. Nevýhodou však je, že přístup k datům není okamžitý, což omezuje použití v reálném čase.

NoSQL databáze, naproti tomu, umožňují ukládat data bez pevně dané tabulkové struktury. Jsou ideální pro práci s nestrukturovanými daty, jako jsou sociální média nebo záznamy z IoT zařízení, a vynikají rychlostí při čtení a zápisu. [107],[108]

#### Princip zpracování dat

Zpracování velkých dat je postup rozdělený do několika po sobě jdoucích kroků. Prvním krokem je sběr dat. Data pocházejí z různých zdrojů jako je například webová analytika, sociální sítě, transakční data nebo data ze senzorů.

Následuje jejich uložení v distribuovaných systémech nebo na cloudových uložiscích. Dalším krokem je předzpracování dat, což zahrnuje jejich čištění a přípravu. Tato fáze je klíčová v procesu zpracování, protože kvalita dat má zásadní vliv na výsledky analýz. Tento krok zahrnuje odstranění duplicitních či neúplných záznamů, standardizaci a transformaci dat.

Po předzpracování dat přichází na řadu samotná analýza dat. Dochází zde k získávání užitečných informací a vzorů z datového souboru. Mezi nejčastěji používané techniky v rámci analýzy velkých dat patří strojové učení, statistická a prediktivní analýza nebo textová a sentimentová analýza.

Posledním krokem je vizualizace výsledků a jejich interpretace. Výsledky musí být prezentovány ve srozumitelné podobě, formou grafických dashboardů, reportů nebo interaktivní prezentace. [107],[108],[108]

### **Frameworky pro zpracování big data**

Velká data vyžadují nejen nové metody ukládání, ale také specializované frameworky, které umožňují jejich paralelní zpracování.

**Apache Hadoop** je dnes jedním z nejznámějších frameworků. Nabízí robustní platformu pro ukládání a zpracování dat pomocí modelu MapReduce. Hadoop dokáže efektivně rozdělit zpracování mezi mnoho serverů a následně výsledky seskládat. Je vhodný především pro dávkové zpracování velkých objemů dat, kdy není nutná okamžitá odezva. [113],[114]

**MapReduce**, na kterém Hadoop stojí, je programovací model umožňující paralelní zpracování dat. Map fáze rozdělí úkoly mezi jednotlivé uzly, Reduce fáze výsledky sloučí. Tento přístup zvyšuje odolnost systému vůči chybám a umožňuje horizontální škálování. [115]

**Apache Spark** je modernější alternativou k Hadoopu, zaměřenou na vyšší rychlost. Na rozdíl od MapReduce, Spark zpracovává data přímo v operační paměti (in-memory), což umožňuje analýzu až stonásobně rychlejší než tradiční Hadoop. Spark je ideální pro real-time analýzu, strojové učení a prediktivní modelování. [116]

**Apache Kafka** se specializuje na zpracování datových proudů v reálném čase. Umožňuje přijímat, ukládat a předávat obrovské objemy dat téměř okamžitě. Kafka se využívá při online sledování návštěvnosti webových stránek nebo dynamickém přizpůsobování reklam. [117]

**Apache Flink** je dalším frameworkem zaměřeným na streamové zpracování dat. Díky velmi nízké latenci a podpoře komplexnějších analytických operací je Flink ideální pro aplikace, které vyžadují okamžité reakce na aktuální data, jako jsou real-time personalizace obsahu nebo monitoring sentimentu na sociálních sítích. [118]

### **Využití big data v marketingu**

Velká data umožňují firmám lépe porozumět svým zákazníkům, personalizovat komunikaci a zefektivnit rozhodovací procesy.

Firmy mohou na základě analýzy big data vytvářet personalizované marketingové kampaně, které lépe odpovídají individuálním potřebám zákazníků. Segmentace trhu, doporučovací systémy a cílené nabídky jsou díky tomu výrazně efektivnější.

Prediktivní analýza umožňuje firmám předvídat budoucí chování zákazníků a tržní trendy, což poskytuje strategickou výhodu.

Dynamická cenotvorba pak využívá analýzu v reálném čase ke stanovení optimálních cen podle aktuální poptávky a konkurence.

Big data hrají klíčovou roli také v marketingu na sociálních sítích. Analýza sentimentu, sledování zmínek o značce a pochopení chování uživatelů umožňuje lépe přizpůsobit kampaně a budovat vztah se zákazníky.

Praktické příklady využití zahrnují Amazon s jeho doporučovacími systémy, Netflix s personalizací nabídky obsahu, nebo Google s dynamickým cílením reklamy. [120],[121],[122],[122]

## 7 Personalizace marketingu na základě datové analýzy

Personalizace marketingu znamená přizpůsobení obsahu nebo nabídky individuálním preferencím zákazníka. Díky datové analýze je možné vytvářet individuální zážitky, posilovat zákaznickou loajalitu a zvyšovat pravděpodobnost interakce i konverze.

### 7.1 Výhody a nevýhody personalizace

Hlavním přínosem personalizace je možnost segmentace klientely, efektivnější cílení kampaní a vyšší návratnost investic. Přesně cílená komunikace zvyšuje zapojení zákazníků a celkovou efektivitu marketingu. Nevýhodou je vysoká náročnost na sběr a analýzu kvalitních dat. Personalizace může také vyvolat obavy o soukromí a v případě přehnaného přizpůsobení působit invazivně. Pro úspěch personalizace je klíčové využívat relevantní data, chránit soukromí zákazníků a být transparentní ohledně jejich využití. [2],[60],[124],[124]

### 7.2 Proces personalizace

Proces začíná sběrem dat – demografických údajů, historie nákupů, chování na webu a sociálních sítích. Následuje analýza, kde se zákazníci segmentují pomocí prediktivní analýzy nebo RFM analýzy.

Dalším krokem je tvorba personalizovaného obsahu, jako jsou cílené nabídky, newslettery nebo doporučené produkty. Obsah je často testován pomocí A/B testování.

Distribuce personalizovaného obsahu probíhá přes web, e-mail marketing, sociální sítě či online reklamu. Důraz je kladen na využívání více kanálů a real-time přizpůsobování obsahu.

Úspěšnost kampaní se vyhodnocuje podle konverzní míry, návratnosti investic a průměrné hodnoty objednávek. Na základě výsledků se proces dále optimalizuje. Automatizace pak umožňuje rutinní personalizační aktivity zjednodušit a zefektivnit. [2],[60],[124],[124]

### 7.1 Principy personalizace obsahu

Existuje celá řada způsobů, které se využívají k personalizaci obsahu. Avšak každý přístup má jinou strategii nebo metodu, jak obsah efektivně cílit.

#### 7.1.1 Personalizovaný obsah

Personalizovaný obsah, je druh personalizace, kdy se obsah dynamicky přizpůsobuje preferencím nebo chování uživatele. Personalizace se vyhodnocuje na základě historie předchozích nákupů nebo prohlížení webu. V praxi to znamená, že každý uživatel může na stejné webové stránce nebo v rámci kampaně vidět odlišný obsah. Obsah odpovídá tomu, co ho nejvíce zajímá podle vyhodnocení dat, které má firma k dispozici. Využívá se v případech, kdy existuje dostatek historických dat o uživateli.

Personalizovaný obsah využívá prakticky každá společnost. Netflix a Spotify jí využívají k doporučení filmů, seriálů či hudby podle historie dříve sledovaných pořadů či puštěných interpretů. Z oblasti internetových obchodů, Amazon anebo i česká společnost Alza zobrazují uživatelům produkty, které jsou podobné těm, které si dříve zakoupili nebo jen prohlíželi.

S personalizací obsahu se zvedá míra relevance obsahu, protože jeho tvorba vychází z požadavků zákazníka. Když uživatelé vidí obsah, který je zajímavý, zvyšuje se pravděpodobnost

provedení konkrétní akce. Tím se zvyšuje míra provedené konverze. Zlepšuje se i zákaznická zkušenost, která je spojená i s prohloubením loajality zákazníků vůči značce.

Personalizace nebude efektivní, když nebude mít firma dostupná kvalitní data v dostatečném množství. Zároveň je důležité uchovat uživatelská data v bezpečí před zneužitím. [2],[60],[124],[124]

### 7.1.2 Segmentace zákazníků

Segmentace zákazníků je klíčová pro efektivní marketing. Zákazníci nejsou homogenní skupina, a proto je nutné je rozdělit do segmentů podle věku, nákupního chování či preferencí. Díky segmentaci mohou firmy lépe přizpůsobit marketingová sdělení a zvýšit relevanci i návratnost investic.

Segmentace umožňuje efektivnější komunikaci a lepší pochopení potřeb různých skupin zákazníků, čímž přispívá ke zvýšení konverzí a snížení marketingových nákladů. Nevýhodou je však náročnost sběru a analýzy dat, riziko špatné interpretace segmentů a potřeba jejich pravidelné aktualizace. [2],[60],[125],[126],[127]

#### Druhy segmentace

Segmentaci lze provádět podle různých kritérií:

- **Demografická:** věk, pohlaví, vzdělání, zaměstnání; snadná dostupnost dat, ale horší odhad potřeb.
- **Geografická:** poloha, klima; vhodná pro lokální kampaně, omezená pro globální.
- **Behaviorální:** nákupní historie, reakce na kampaně; velmi efektivní, ale náročná na sběr dat.
- **Psychografická:** životní styl, hodnoty, zájmy; vysoce relevantní, ale obtížněji dostupná data.

V praxi se doporučuje kombinovat více typů segmentací. [2],[60],[126],[127],[127]

#### 7.1.2.1 RFM analýza

RFM analýza je jednoduchá ale velice účinná metoda spadající do kategorie segmentace zákazníků. Využívá se zejména při analýze e-shopů, věrnostních programů a při personalizaci kampaní.

Název je tvořen počátečními písmeny tří složek, které jsou v rámci této analýzy zkoumány a odpovídají na následující otázky: Recency (nedávnost) – jak nedávno zákazník nakoupil, Frequency (četnost) – jak často nakupuje a Monetary (utrácení) – jakou částku utratí.

Jednotlivé metriky se během analýzy hodnotí hodnotou v rozmezí 5 (nejlepší) až 1 (nejhorší). Spojením jednotlivých metrik se vytvoří RFM skóre, podle kterých se zákazníci mohou rozdělit do jednotlivých segmentů. Pro nejlepšího zákazníka bude vycházet RFM skóre 555, ze kterého lze zjistit, že nakupuje velice často, nedávno a utrací hodně peněz.

Tato analýza je zvláště užitečná při identifikaci nejceněnějších zákazníků. Nevyžaduje složité modely ani strojové učení, což výrazně zjednodušuje celkové provedení a cílení marketingových kampaní.

Hlavní předností použití RFM analýzy je její jednoduchost a rychlost. Zvládne jí praktický každý, jelikož je snadno pochopitelná i pro méně technologicky zdatné jedince.

Slabou stránkou této analýzy je, že nepočítá s psychologickými faktory zákazníků, jako je motivace a důvod nákupu. Nezachycuje ani trendy v chování zákazníků a zaměřuje se pouze na historická data, nebere v potaz budoucí potenciál. Zároveň není moc užitečná pro služby, které jsou specifické svou nízkou frekvencí využití. [129],[129]

### 7.1.2.2 A/B testování

A/B testování je marketingová metoda, jejímž cílem je zjistit, zda konkrétní strategie skutečně přináší požadované výsledky. Považuje se za nezbytný nástroj pro optimalizaci reklamních kampaní.

Je to tedy metoda, která přináší dvě a více variant něčeho – ať už e-mailového newsletteru, reklamy, variant úvodních stránek a podobně. Návštěvníci jsou pak náhodně rozděleni do skupin, které vidí rozdílné verze.

Následně se měří jednotlivé metriky, z kterých se na konci vyhodnocuje, která varianta testování byla lepší a lépe na ní zákazníci reagovali.

Sledují se metriky:

- **CTR** – míra prokliku
- **CR** – míra konverze
- **Bounce rate** – kolik zákazníku stránku ihned opustilo
- **Open rate** – kolik zákazníků otevřelo zasláný e-mail

Výhodou A/B testování je, že firma může přijímat rozhodnutí na základě skutečných dat. Tato metoda pomáhá minimalizovat rizika spojená se zaváděním změn, s cílem zvýšit konverze a zároveň snížit náklady.

Nevýhodou však je, že při malém testovacím vzorku mohou výsledky zkreslené. Testování nepočítá s dlouhodobým dopadem – některé varianty mohou fungovat pouze krátkodobě, ale z dlouhodobého hlediska nejsou účinné k udržení zákazníka. [131],[132],[132]

### 7.1.3 Retargeting

Retargeting, nebo také remarketing, je online marketingová metoda, která funguje na principu zpětného oslovení návštěvníků webových stránek. Zaměřuje se na uživatele, kteří již interagovali s webem, produktem či značkou, ale neprovedli v souvislosti s ní požadovanou akci (např. nákup, registrace). Cílem retargetingu je oslovit zpětně tyto zákazníky a motivovat je k tomu, aby dokončili požadovanou akci.

Jednou z hlavních výhod retargetingu je jeho vysoká efektivita v konverzích. Cílením na uživatele, kteří již projevíli zájem o produkt, se zvyšuje pravděpodobnost, že dojde k požadované akci. Retargeting také pomáhá budovat větší povědomí o značce právě pomocí znovu vyhledávání kontaktu se zákazníkem. V rámci personalizace sdělení umožňuje zobrazení zprávy na základě předchozích interakcí uživatele.

Mezi nevýhody se může řadit možnost vzniku efektu přehlcení. Ten vzniká, když je retargeting příliš intenzivní a může odradit zákazníka od provedení jakékoliv akce. Znovuzobrazování reklamy může u uživatelů vzbudit obavy ohledně bezpečnosti jejich soukromí. [134],[135],[135]

### 7.1.3.1 Proces retargetingu

Stejně jako tomu je u jakéhokoliv jiného procesu, i u retargetingu se začíná stanovením cílů, kterých chce firma dosáhnout. Ať už se jedná o dokončení nákupů, opětovné návštěvy webových stránek či přihlášení se k odběru newsletteru.

Pro úspěšné provedení retargetingu je nezbytné na webovou stránku implementovat sledovací kód, známý také jako Tag nebo Pixel. Tento kód slouží k monitorování a měření chování uživatelů – například toho, na co klikli, jaké stránky navštívili a které z nich opustili. Trackingových kódů existuje celá řada, mezi nejpoužívanější se řadí Facebook Pixel nebo Google Ads Remarketing Tag.

V závislosti na použité reklamní platformě vytvoří firma cílové publikum na základě nasbíraných dat. Je důležité klást velký důraz na co nejpřesnější vymezení cílového publika, čímž se zajistí účinnější retargeting. [134],[135],[135]

Firmy si vybírají cílové skupiny zákazníků z následujících možností:

- Všichni návštěvníci webové stránky
- Zákazníci, co vložili produkty do košíku, ale nedokončili nákup
- Zákazníci, kteří navštívili konkrétní produkt
- Zákazníci, kteří provedli interakci na sociálních sítích

Na základě výběru konkrétní skupiny či skupin, se vytvoří personalizované reklamní sdělení. Může se jednat o personalizovanou reklamu, kde zákazník uvidí produkt, který předtím navštívil. Připomínkovou zprávu se slevovým kódem pro ty, kteří měli produkt v košíku a neprovedli konverzi. Mohou také využít časové limitace, která spíše pomůže zákazníkovi se rozhodnout k nákupu.

S tím se pojí i výběr kanálu, kde se budou reklamy zobrazovat. Výběr cílové platformy musí být podle toho, kde se cílové publikum pohybuje. Jedná se například o sociální sítě, vyhledávače nebo webové stránky. [134],[135],[135]

Na vybrané platformě se nastaví kampaň tak, aby odpovídala cílům, kterých chce společnost dosáhnout. Je nutné vybrat cílové publikum a nahrát připravená reklamní sdělení. Dále je třeba nastavit následující parametry kampaně:

- Celkový rozpočet
- Doba trvání
- Frekvence zobrazení
- Délku retargetingového okna

Po spuštění kampaně se její výkon testuje pomocí metody A/B. U jednotlivých verzí se sleduje, která kampaň dosahuje lepších výsledků v oblasti CTR, konverzí a návratnosti investice.

Během kampaně je důležité ji průběžně monitorovat a na základě dosažených výsledků jednotlivých verzí provádět optimalizace pro zlepšení její efektivity. [134],[135],[135]

## 8 Praktická část

Praktická část diplomové práce se zaměřuje na analýzu výkonnosti online marketingových kampaní realizovaných prostřednictvím reklamní platformy Sklik. Cílem této části je nejen zhodnocení efektivity jednotlivých kampaní na základě vybraných metrik, ale také návrh optimalizačních kroků s využitím poznatků z datové analýzy.

Analýza vychází z dat jedné z dceřiných společností stavebního holdingu a je koncipována v souladu s metodickým rámcem CRISP-DM, který slouží jako struktura pro jednotlivé fáze postupu – od porozumění datům až po interpretaci výsledků.

Výstupy jsou zpracovány pomocí nástrojů Microsoft Excel a Power BI s důrazem na přehlednost, srozumitelnost i praktickou využitelnost.

### 8.1 Porozumění cíli (Business Understanding)

V praktické části diplomové práce bude analyzována marketingová kampaň realizovaná dceřinou společností stavebního holdingu, která se primárně zaměřuje na Pardubický kraj.

Cílem této analýzy je vyhodnotit efektivitu uskutečněné online kampaně a na základě dostupných dat navrhnout doporučení pro optimalizaci budoucích marketingových aktivit.

I když se jedná o data získaná v rámci holdingu, primárním předmětem analýzy je dceřiná společnost, která je taktéž aktivní v oblasti stavebnictví. Kampaň byla zaměřena na nábor nových pracovníků, především pro lokalitu Praha, což se odrazilo i ve výběru klíčových slov.

Marketingové aktivity probíhaly prostřednictvím reklamní platformy Sklik od společnosti Seznam.cz, a to formou dvou paralelních kampaní:

- **Obsahová kampaň**, jejímž cílem bylo zvýšit povědomí o společnosti a přivést nové návštěvníky na web.
- **Vyhledávací kampaň**, která se zaměřovala na zachycení aktivního zájmu uživatelů prostřednictvím relevantních dotazů ve vyhledávání. Mezi použitá klíčová slova patřily například výrazy „práce Praha“, „zaměstnání Praha“ a „volná místa Praha“.

Obě kampaně byly zacíleny nejen na platformu Seznam.cz, ale i na širokou síť jeho partnerských webů v rámci mediálního domu. Časově byly kampaně vymezeny dvouměsíčním obdobím od začátku září do konce října 2024.

### 8.2 Porozumění datům (Data Understanding)

Analýza bude vycházet z dat získaných z reklamního systému Sklik, který provozuje společnost Seznam.cz. Tato data pocházejí ze dvou samostatných kampaní – obsahové a vyhledávací, které byly zaměřeny na klíčová slova a probíhaly souběžně od začátku září do konce října 2024. Obě kampaně se zaměřovaly na nábor zaměstnanců v oblasti stavebnictví, konkrétně na pracovní pozice v lokalitě Praha.

### 8.2.1 Datový zdroj

Data byla vyexportována přímo ze systému Sklik ve formátu Excel. Jsou rozdělena do dvou souborů podle měsíce – září a říjen. Obsahují denní souhrny výkonu reklamních kampaní, a to jak v obsahové, tak ve vyhledávací síti. Každý řádek představuje souhrnné hodnoty za jeden den kampaně.

### 8.2.2 Popis proměnných

Mezi klíčové metriky, které se v dokumentech vyskytují patří:

- **Datum** → den, ke kterému se vztahují konkrétní hodnoty.
- **Název kampaně** → identifikátor kampaně.
- **Stav kampaně**
- **Prokliky** → počet kliknutí na reklamu.
- **Zobrazení** → počet zobrazení reklamy.
- **CTR (Click Through Rate)** → míra prokliku (poměr kliknutí k zobrazení).
- **CPC (Cost Per Click)** → průměrná cena jednoho kliknutí.
- **Cena** → celkové náklady vynaložené na den.
- **Pozice** → pozice, na které se reklama zobrazovala.
- **Konverze** → počet akcí, které byly definovány jako cíl kampaně.
- **Konverzní poměr** → poměr konverzí vůči počtu prokliků.
- **Hodnota konverze** → náklady na jednu konverzi.
- **PNO** → podíl nákladů na obratu.
- **Podíl zobrazení** → podíl reálně dosažených zobrazení na celkovém potenciálu v daném segmentu.
- **Ztracená zobrazení** → procento zobrazení, která nebyla realizována.
- **Kvalita** → skóre kampaně či reklamy, které vychází z její relevance a výkonu.

### 8.2.3 Kvalita a rozsah dat

Data jsou ve formě souhrnných tabulek, které po jednotlivých dnech obsahují téměř všechny klíčové metriky, které jsou potřebné pro vyhodnocení výkonnosti kampaní. Vyskytují se zde chybějící či nulové hodnoty, například u konverzí nebo u hodnoty PNO.

Celkově datová sada poskytuje dostatečný základ pro analýzu efektivity kampaní.

## 8.3 Příprava dat

Po shromáždění a prostudování datového souboru následuje jeho příprava do formátu, který umožní provést analýzu výkonnosti kampaní. Cílem je, aby data byla strukturována tak, aby umožňovala provádět výpočty, porovnávat jednotlivé kampaně a sledovat jejich vývoj v čase.

### 8.3.1 Úprava struktury dat

Datové soubory jsou rozděleny do dvou samostatných částí podle kalendářního měsíce. V původním excelovém souboru byly všechny kampaně uvedeny v jedné velké tabulce. Pro přesnější porovnání byly kampaně rozděleny do samostatných listů. Tento přístup umožnil oddělené zpracování výkonu jednotlivých kampaní podle jejich zaměření.

Kampaně byly rozděleny následovně:

- **Obsahové kampaně:** „Bannery – Obsah“ a „Bannery – Retargeting“
- **Vyhledávací kampaně:** „Zaměstnání – region – vyhledávání“ a „Zaměstnání – Praha – vyhledávání“

Kromě toho byl vytvořen souhrnný dokument, který sloučil data z obou měsíců na základě jednotlivých kampaní. Celkově se tedy pracuje se třemi excelovými soubory.

### 8.3.2 Sjedení datových formátů

Formáty číselných údajů byly sjednoceny s cílem zajistit konzistenci napříč celou datovou sadou. Upravena byla také podoba dat a procentuálních hodnot, aby odpovídala standardizovanému formátu a umožňovala bezchybné provádění výpočtů a analýz.

### 8.3.3 Odstranění řádků a sloupců

Z datového souboru byly odstraněny řádky, které obsahovali informace ohledně společnosti a jejich účtu. Ty jsou pro účely analýzy nepotřebné a pro zachování anonymity společnosti důležité.

### 8.3.4 Doplnění sloupců

Do datového souboru byl doplněn nový sloupec vyjadřující typ dne (pracovní den vs. víkend), a dále také název dne v týdnu. Tento krok umožnil identifikovat rozdíly ve výkonnosti kampaní v závislosti na dni, což je důležitý faktor při plánování budoucích marketingových aktivit.

Přidání sloupce dne v týdnu bylo provedeno pomocí funkce převedení hodnoty na text. Díky čemuž se převedla data na jednotlivé dny v týdnu.

*=HODNOTA.NA.TEXT(A2; "ddd")*

Pro rozlišení pracovních dnů a víkendů bylo využito převedení hodnoty datumu na číselné označení dne v týdnu. Následně byla aplikována podmínka, která přiřadila označení „pracovní den“ všem dnům s pořadovým číslem menším než šest (tj. pondělí až pátek). V opačném případě, tedy při hodnotách, které odpovídají sobotě nebo neděli, byl řádek označen jako „víkend“.

*=KDYŽ(DENTÝDNE(A2;2)<6;"pracovní den"; "víkend")*

Po doplnění sloupců do datové tabulky je struktura následující:

- |                            |                      |
|----------------------------|----------------------|
| • Datum                    | • Konverze           |
| • Název kampaně            | • Konverzní poměr    |
| • Stav kampaně             | • Hodnota konverze   |
| • Prokliky                 | • PNO                |
| • Zobrazení                | • Podíl zobrazení    |
| • CTR (Click Through Rate) | • Ztracená zobrazení |
| • CPC (Cost Per Click)     | • Kvalita            |
| • Cena                     | • Den v týdnu        |
| • Pozice                   | • Fáze týdne         |

## 8.4 Modelování

Na základě předzpracovaných a analyzovaných dat byla v této části práce realizována fáze modelování, jejímž cílem bylo prohloubit porozumění vztahům mezi jednotlivými metrikami kampaní a identifikovat vzorce, které mohou sloužit jako základ pro budoucí rozhodování a optimalizaci. V rámci modelování byly využity kvantitativní metody, jako je korelační analýza, a vícekritériální hodnocení účinnosti jednotlivých dnů v týdnu, jež umožnilo porovnat výkonnost kampaní v čase z různých pohledů.

### 8.4.1 Výkonnostní analýza

První část modelování se zaměřuje na analýzu výkonnosti jednotlivých reklamních kampaní, jejich časový vývoj a souvislosti mezi klíčovými metrikami.

Cílem je identifikovat faktory, které měly vliv na úspěšnost kampaní a navrhnout doporučení pro budoucí marketingová rozhodnutí.

Prvním krokem bylo porovnat jednotlivé kampaně z hlediska základních výkonnostních metrik. Do analýzy byly zahrnuty obsahové kampaně typu bannerová a retargetingová a dvě vyhledávací kampaně na klíčová slova (regionální a pražská).

U kampaní byly sledovány klíčové metriky výkonnosti:

- Počet prokliků
- Počet zobrazení
- CTR (Click-Through Rate) – míra prokliku (%)
- CPC (Cost per Click) – průměrná cena prokliku (kč)
- Celkové náklad (kč)

Srovnání výkonu bylo provedeno jak samostatně u jednotlivých měsíců, tak i u celkové výkonnosti kampaně.

Hodnoty pro celkové prokliky, zobrazení a náklady, byly vypočítány pro jednotlivé kampaně pomocí funkce SUMA.

$$=SUMA('Bannery - obsah'!D:D)$$

Pro výpočet průměrných hodnot CRT a CPC byl použit následující vzorec s využitím funkce průměr:

$$=PRŮMĚR('Bannery - obsah'!F:F)$$

Pomocí podmíněného formátování pak byly vyznačeny ty hodnoty, které u dané metriky vykazovali žádoucí hodnotu.

### 8.4.1.1 Výkonnost kampaně – září

V rámci zářijové fáze kampaně byly vyhodnoceny čtyři hlavní reklamní sestavy. Klíčové výkonnostní metriky jsou uvedeny v tabulce níže a dále interpretovány.

Tabulka 1 - Výkonnostní kampaň září

	<b>Celkové prokliky</b>	<b>Celkové zobrazení</b>	<b>Průměrné CRT (%)</b>	<b>Průměrné CPC (Kč)</b>	<b>Celkové náklady (Kč)</b>
<b>Bannery obsah</b>	<b>1 820</b>	<b>173 425</b>	1,15 %	3,75 Kč	6 657,01 Kč
<b>Bannery retargeting</b>	760	51 687	1,49 %	4,03 Kč	3 110,90 Kč
<b>Zaměstnání region</b>	782	4 134	<b>19,73 %</b>	<b>2,87 Kč</b>	2 207,82 Kč
<b>Zaměstnání Praha</b>	672	4 230	16,61 %	3,29 Kč	<b>2 193,08 Kč</b>

Zdroj: Vlastní

Obsahová kampaň, která je zaměřená na masivní zásah uživatelů, vykázala od počátku fungování spuštění 9.9.2024 do konce měsíce celkově 173 425 zobrazení, z toho 1 820 uživatelů na reklamní banner kliklo. Nicméně, míra prokliku se pohybuje v průměru okolo 1,15%, tedy nejnižší ze všech sledovaných kampaní, což může naznačovat nízkou relevanci. Cena za proklik byla průměrná, což značí, že se reklamy sice zobrazovaly často, ale nezaujaly natolik, aby kliknutí bylo častější. Kampaň plní spíše účel budování povědomí o značce než výkonnostní cíle.

U retargetingové kampaně je vidět o poznání nižší zobrazení i prokliky, ale o to vyšší je CTR hodnota, než tomu je u bannerové kampaně. Tento jev je typický pro tento druh kampaní, jelikož je cílená na uživatele, které již byly s firmou v kontaktu. Zároveň měla nejvyšší CPC ze všech kampaní, což je běžné – kampaň pracuje s menším, ale cennějším publikem. Vyšší cena za klik může být odůvodněna vyšší pravděpodobností konverze, která však v rámci systému Sklik nebyla sledována. Kampaň sice byla dražší na jednotku výstupu, ale o to cílenější a přesnější.

Vyhledávací kampaň „Zaměstnání – region“ byla nejefektivnější ze všech. Extrémně vysoké CTR naznačuje, že klíčová slova byla výborně zacílena na potřeby uživatelů, s maximální relevancí. Kampaň zároveň vykázala nejnižší průměrnou cenu za proklik i celkové náklady, což znamená, že přinesla firmě nejlepší výkon za nejnižší investici.

Druhá kampaň zaměřená na cílová slova („Zaměstnání – Praha“), měla srovnatelný zásah jako ta regionální, ale nižší počet prokliků i CTR. To může naznačovat větší konkurenci na trhu práce v Praze, nebo méně atraktivní nabídku/slovní spojení.

### 8.4.1.2 Výkonnost kampaně – říjen

V rámci říjnové fáze kampaně byly vyhodnoceny v následující tabulce čtyři hlavní reklamní sestavy a jejich klíčové metriky.

Tabulka 2 - Výkonnosti kampaň – říjen

	<b>Celkové prokliky</b>	<b>Celkové zobrazení</b>	<b>Průměrné CRT (%)</b>	<b>Průměrné CPC (Kč)</b>	<b>Celkové náklady (Kč)</b>
<b>Bannery obsah</b>	<b>1 415</b>	<b>113 797</b>	1,41 %	3,52 Kč	5 046,58 Kč
<b>Bannery retargeting</b>	824	42 147	1,95 %	3,11 Kč	3 216,33 Kč
<b>Zaměstnání region</b>	1 078	5 685	<b>19,54 %</b>	<b>2,90 Kč</b>	<b>3 083,85 Kč</b>
<b>Zaměstnání Praha</b>	942	5 941	16,10 %	3,33 Kč	3 093,43 Kč

Zdroj: Vlastní

Obsahová kampaň za měsíc říjen stejně jako v září patří z hlediska zásahu mezi nejúčinnější. CRT se stále pohybuje nízko, ale mírně se zlepšilo v porovnání v zářím. Průměrná cena za jeden proklik mírně klesla, s tím klesli i celkové náklady. Obsahová kampaň ukazuje známky optimalizace a zefektivnění, přesto však zůstává primárně brandovou.

U retargetingové kampaně je z hlediska poměru výkon / cena je vidět výrazné zlepšení – lepší CTR, nižší cena za klik i celkové náklady.

Vyhledávací kampaň (“Zaměstnání – region”) opět potvrdila svou absolutní dominanci. Nejvyšší míra prokliku, nejnižší cena za kliknutí a zároveň i nejnižší celkové náklady dokazují její efektivitu. Tato sestava byla nejvýkonnější i v září, takže se dá říct, že se jedná dlouhodobě o nejsilnější kanál.

U druhé kampaně na klíčová slova, která se zaměřuje na Prahu, se dosahuje taktéž nadstandardních výsledků. CTR je zde lehce nižší než regionální verze, ale stále nadstandardní, cena za klik zůstává nízká, a náklady se drží velmi nízko.

### 8.4.1.3 Výkonnost kampaně

Poslední tabulka vyjadřuje výkonnost celé kampaně za období září a říjen.

Tabulka 3 - Výkonnostní kampaň

	<b>Celkové prokliky</b>	<b>Celkové zobrazení</b>	<b>Průměrné CRT (%)</b>	<b>Průměrné CPC (Kč)</b>	<b>Celkové náklady (Kč)</b>
<b>Bannery obsah</b>	<b>3 235</b>	<b>287 222</b>	1,30 %	3,31 Kč	11 703,59 Kč
<b>Bannery retargeting</b>	1 584	93 834	1,76 %	3,49 Kč	6 327,23 Kč
<b>Zaměstnání region</b>	1 860	9 819	<b>19,62 %</b>	<b>2,88 Kč</b>	5 291,67 Kč
<b>Zaměstnání Praha</b>	1 614	10 171	16,31 %	3,31 Kč	<b>5 286,51 Kč</b>

Zdroj: Vlastní

Bannerová obsahová kampaň byla neúspěšnější z hlediska celkových počtů zobrazení (287 222) a prokliků (3 235). Z hlediska výkonu však dosáhla nejnižší míry prokliku CTR 1,30 % a průměrné náklady na jeden proklik, činily 3,31 Kč. Celkové náklady přesáhly 11 700 Kč, což z této kampaně činí nejnákladnější položku.

Kampaň lze vyhodnotit tak, že je vhodná pro zvýšení povědomí o firmě, nikoli pro přímou konverzi. Celková efektivita byla nízká, ale zásah uživatelů je obrovský.

Retargetingová kampaň je výrazně méně výrazná z hlediska zobrazení – 93 834 uživatelů, ale navzdory tomu má lepší výkonnost z hlediska CTR, která dosahuje až 1,76% a celkem 1 584 prokliků.

Oproti klasickým bannerům byla efektivnější, i když v přepočtu nákladnější. Je vhodná jako doplněk pro zacílení na známé publikum.

Z hlediska výkonnosti jsou kampaně zaměřené dlouhodobě účinnější jak obsahové. První kampaň je celkově nejvýkonnější kampaň, které probíhali. S nejvyšším CTR 19,62 % a zároveň nejnižším CPC (2,88 Kč) dosáhla celkově 1 860 prokliků, a to při pouhých 9 819 zobrazeních. Celkové náklady na ní činily pouze 5 291 Kč.

Kampaň je vysoce efektivní – vysoká relevance, nízké náklady a stabilní výkon poskytuje v obou dvou měsících.

Výsledky poslední vyhledávací kampaně, která byla zaměřená na klíčová slova – “Zaměstnání – Praha”, byly velmi podobné jako u regionální varianty. CTR zde dosahuje 16,31 %, průměrné CPC činilo 3,31 Kč a počet prokliků byl 1 614. Její nejvýraznější výhodou byly nejnižší celkové náklady ze všech sledovaných kampaní

## 8.4.2 Výkonnostní analýza podle fáze týdne

Pro rozšíření výkonnostní analýzy byla data kampaní rozdělena podle typu dne na pracovní dny (pondělí až pátek) a víkendy (sobota a neděle). Cílem této analýzy bylo zjistit, zda fáze týdne ovlivňuje výkonnost jednotlivých reklamních kampaní.

Pro jednotlivé fáze týdne byly průměrné hodnoty vypočítány pomocí funkce *AVERAGEIFS*, která umožňuje spočítat průměr z hodnot, jež splňují specifikovanou podmínku – v tomto případě odpovídající fázi týdne.

$$=AVERAGEIFS('Bannery - obsah'!D:D;'Bannery - obsah'!$S:$S;"pracovní den")$$

### Výkonnostní analýza podle fáze týdnu – září

Následující tabulka popisuje výkonnost jednotlivých kampaní v závislosti na fázi týdne během měsíce září.

Tabulka 4 - Výkonnostní kampaň podle fáze týdne (září)

		Průměrné prokliky	Průměrné zobrazení	Průměrné CRT (%)	Průměrné CPC (Kč)	Průměrné náklady (Kč)
<b>Bannery obsah</b>	pracovní den	<b>82,81</b>	<b>8 139</b>	1,13 %	3,78 Kč	303,21 Kč
	víkend	82,50	7 199	<b>1,20 %</b>	<b>3,70 Kč</b>	<b>300,94 Kč</b>
<b>Bannery retargeting</b>	pracovní den	33,06	2 282	1,48 %	4,06 Kč	<b>137,87 Kč</b>
	víkend	<b>38,50</b>	<b>2 530</b>	<b>1,52 %</b>	<b>3,96 Kč</b>	150,84 Kč
<b>Zaměstnání region</b>	pracovní den	<b>37,50</b>	<b>204</b>	19,32 %	<b>2,78 Kč</b>	103,13 Kč
	víkend	30,33	145	<b>20,82 %</b>	3,11 Kč	<b>92,97 Kč</b>
<b>Zaměstnání Praha</b>	pracovní den	<b>31,63</b>	<b>209</b>	15,60 %	<b>3,16 Kč</b>	<b>99,17 Kč</b>
	víkend	27,67	149	<b>19,30 %</b>	3,66 Kč	101,07 Kč

Zdroj: Vlastní

U první bannerové kampaně jsou rozdíly mezi pracovními dny a víkendy minimální. Během víkendů bylo zaznamenáno mírně vyšší CTR i nižší CPC, avšak v praxi je tento rozdíl zanedbatelný. Kampaň tak má stabilní výkon bez výrazných výkyvů bez závislosti na fázi týdne.

Retargetingová kampaň na rozdíl od klasické bannerové kampaně o víkendu vykázala vyšší výkon – vyšší míru prokliku i vyšší počet prokliků. Retargeting byl tedy efektivnější o víkendech, kdy uživatelé zřejmě více reflektují své dřívější interakce.

Kampaně zaměřené na konkrétní klíčová slova vykazují v klasické výkonnostní kampani vysokou účinnost. První kampaň (“Zaměstnání – region”) vykazuje trvale vysoký výkon, a to v obou typech dnů. Během víkendu stoupá CTR zhruba o 1,5 %, ale klesá počet zobrazení i kliknutí. Nízké průměrné náklady v obou případech ukazují na mimořádnou efektivitu tohoto druhu kampaní.

U kampaně “Zaměstnání – Praha” lze sledovat také vyšší CTR o víkendu, ale celkový objem výkonu byl nižší, než tomu je v pracovních dnech. Víkendové dny přinášejí menší průměrný počet zobrazení i prokliků, avšak stále má velmi dobrý výkon. Kampaň má tak konzistentní výsledky.

V závěru lze říci, že během září vyhledávací kampaň fungovala dobře jak ve všední dny, tak i o víkendu. Nejvíce cenově efektivní byla víkendová kampaň „Zaměstnání – region“. Retargetingové kampaně vykazovaly výrazně lepší výsledky o víkendech, zatímco klasická bannerová kampaň předváděla stabilní výkon po celý týden.

### Výkonnostní analýza podle fáze týdnu – říjen

Stejně jako v září byla i v říjnu data jednotlivých kampaní rozdělena podle typu dne. Cílem bylo ověřit, zda se trendy z předchozího měsíce opakují, nebo zda došlo k významným změnám ve výkonnosti mezi pracovním týdnem a víkendem.

Tabulka 5 - Výkonnostní kampaň podle fáze týdne (říjen)

		Průměrné prokliky	Průměrné zobrazení	Průměrné CRT (%)	Průměrné CPC (Kč)	Průměrné náklady (Kč)
<b>Bannery obsah</b>	pracovní den	43,74	<b>3 674</b>	1,38 %	3,57 Kč	<b>158,28 Kč</b>
	víkend	<b>51,13</b>	3 663	<b>1,50 %</b>	<b>3,41 Kč</b>	175,77 Kč
<b>Bannery retargeting</b>	pracovní den	25,35	<b>1 400</b>	1,73 %	<b>2,99 Kč</b>	<b>99,27 Kč</b>
	víkend	<b>30,13</b>	1 245	<b>2,57 %</b>	3,46 Kč	116,65 Kč
<b>Zaměstnání region</b>	pracovní den	<b>35,48</b>	<b>183</b>	<b>19,97 %</b>	<b>2,84 Kč</b>	99,49 Kč
	víkend	32,75	183	18,29 %	3,05 Kč	<b>99,44 Kč</b>
<b>Zaměstnání Praha</b>	pracovní den	<b>32,30</b>	<b>204</b>	15,96 %	<b>3,18 Kč</b>	102,33 Kč
	víkend	24,88	155	<b>16,50 %</b>	3,74 Kč	<b>92,48 Kč</b>

Zdroj: Vlastní

V rámci bannerové kampaně se o víkendu prokázal vyšší počet prokliků i vyšší CTR. V porovnání se zářím se rozdíl mezi jednotlivými fázemi zvýraznil – podle hodnot klíčových

metrik se zdá, že bannerová kampaň začala lépe fungovat o víkendech než ve všední dny. Zároveň díky nižší ceně CPC o víkendu se snižuje její nákladovost.

Retargetingová kampaň i v říjnu opět dosahovala lepších výsledků o víkendech. I když byly náklady vyšší, došlo k nárůstu CTR. Víkendová efektivita se tak potvrdila, podobně jako v září.

Výkon u vyhledávací kampaně – “Zaměstnání – region”, zůstává konzistentní – vysoké CTR u obou fází týdne. Lehce vyšší efektivita je viděna ve všední dny. Víkend přináší méně prokliků a vyšší CPC, ale rozdíly jsou menší, než tomu je v září.

U kampaně – “Zaměstnání – Praha”, se v říjnu zvedá víkendová hodnota CTR nad pracovními dny, ale počet prokliků i zobrazení zůstává stále vyšší ve všední dny. CPC o víkendu stoupl. Víkendy zde fungují o něco lépe než v září, ale stále jsou méně výkonné než pracovní část týdne.

Lze říct, že bannerová kampaň a retargeting si vedou výrazně lépe o víkendu, zejména z hlediska míry prokliku. Kampaně zaměřené na klíčová slova si stejně jako v září vedou lépe ve všední dny, ale rozdíl s víkendy se mírně dorovnáva.

### Výkonnostní analýza podle fáze týdnu – celková kampaň

Na základě sloučených dat za období září a říjen 2024 byla provedena souhrnná analýza výkonnosti jednotlivých kampaní z hlediska fáze dne (pracovní den vs. víkend).

Tabulka 6 - Výkonnostní kampaň podle fáze týdne

		Průměrné prokliky	Průměrné zobrazení	Průměrné CRT (%)	Průměrné CPC (Kč)	Průměrné náklady (Kč)
<b>Bannery obsah</b>	pracovní den	59,77	<b>5506</b>	1,28 %	3,65 Kč	<b>217,74 Kč</b>
	víkend	<b>64,57</b>	5179	<b>1,37 %</b>	<b>3,53 Kč</b>	229,42 Kč
<b>Bannery retargeting</b>	pracovní den	28,51	1761	1,63 %	<b>3,43 Kč</b>	<b>115,10 Kč</b>
	víkend	<b>33,71</b>	<b>1795</b>	<b>2,12 %</b>	3,67 Kč	131,30 Kč
<b>Zaměstnání region</b>	pracovní den	<b>36,31</b>	<b>192</b>	<b>19,70 %</b>	<b>2,82 Kč</b>	100,98 Kč
	víkend	31,71	167	19,37 %	3,07 Kč	<b>96,67 Kč</b>
<b>Zaměstnání Praha</b>	pracovní den	<b>32,03</b>	<b>206</b>	15,81 %	<b>3,17 Kč</b>	101,03 Kč
	víkend	26,07	153	<b>17,70 %</b>	3,71 Kč	<b>96,16 Kč</b>

Zdroj: Vlastní

Bannerová kampaň si vedla lépe o víkendech – víkendové průměrné CRT bylo vyšší a cena za proklik mírně nižší. Přesto že náklady byly vyšší, víkendy přinášely větší objem prokliků.

Retargetingová kampaň vykazuje výrazně lepší výsledky o víkendech, kdy byly vyšší počty prokliků a díky tomu i vyšší míra prokliků. Cena za jedno kliknutí je sice vyšší, ale v porovnání s celkovým výkonem je stále efektivnější o víkendů.

Vyhledávací kampaň – “Zaměstnání – region” si vedla výborně v obou fázích týdne, avšak v pracovních dnech byla efektivnější – přinesla více prokliků, měla nižší CPC a vyšší CTR. Regionální zaměstnanecká kampaň tak potvrzuje vysokou efektivitu v pracovním týdnu.

Kampaň “Zaměstnání – Praha” dosáhla vyšší míry prokliku o víkendů, ale celkový výkon (počet prokliků i zobrazení) byl vyšší ve všední dny.

Z výsledků vyplývá, že nejvyšší efektivitu dosahují kampaně klíčových slov ve všedních dnech. Naopak bannerové kampaně (včetně retargetingu) jsou úspěšnější o víkendech. Tyto rozdíly by měly být zohledněny při plánování denních rozpočtů a časování jednotlivých typů kampaní.

### 8.4.3 Výkonnostní analýza podle dne v týdnu

Z hlediska výkonnostní analýzy bylo potřebné se podívat na výkonnost kampaní během jednotlivých dnů.

Výkonnostní analýza zaměřená na jednotlivé dny byla provedena pomocí kontingenčních tabulek. Vycházela ze souhrnné tabulky všech kampaní za celé období. Na pozice řádků byly dány dny v týdnu a názvy jednotlivých kampaní. Jako hodnoty posloužily metriky – prokliky, zobrazení, průměrné CPC a cena.

Hodnota CTR musela být dopočtena zvlášť z výsledných hodnot prokliků a zobrazení. Následně byl pro všechny metriky vypočítán denní průměr a výkon.

#### Pondělí

Pondělí se ukázalo jako den, kdy byly nejefektivnější textové kampaně ve vyhledávání, zejména ta regionální. Tyto kampaně měly vysokou míru prokliku, a přitom nízké náklady, což z nich činí klíčové jednotky výkonu. Bannerové formáty sice generovaly vysoký počet zobrazení, ale jejich efektivita a návratnost byla ve srovnání s nimi nižší.

Tabulka 7 - Výkonnostní kampaň (pondělí)

	Prokliky	Zobrazení	CTR	CPC Ø	Cena
pondělí	Součet	Součet		Průměr	Součet
<b>Bannery – Obsah</b>	<b>602</b>	<b>52 187</b>	1,15 %	3,40 Kč	1 947,38 Kč
<b>Bannery – Retargeting</b>	220	13 462	1,63 %	3,75 Kč	855,86 Kč
<b>Zaměstnání – Praha</b>	259	1 706	15,18 %	3,34 Kč	859,30 Kč
<b>Zaměstnání – Region</b>	291	1 507	<b>19,31 %</b>	<b>2,83 Kč</b>	<b>816,50 Kč</b>
<b>Celkem</b>	<b>1 372</b>	<b>68 862</b>	1,99 %	<b>3,33 Kč</b>	<b>4 479,04 Kč</b>

Zdroj: Vlastní

## Úterý

Stejně jako v pondělí podává regionální textová kampaň ve vyhledávání vysoce efektivní výkon. I přes nižší zásah má vysoký počet prokliků a minimální náklady. Přestože bannerová kampaň měla největší zásah, její CTR nepřekročilo ani 1 %, což výrazně snižuje její návratnost.

Tabulka 8 - Výkonnostní kampaň (úterý)

	Prokliky	Zobrazení	CTR	CPC Ø	Cena
úterý	Součet	Součet	Průměr	Průměr	Součet
<b>Bannery – Obsah</b>	<b>420</b>	<b>44 403</b>	0,95 %	3,81 Kč	1 639,65 Kč
<b>Bannery – Retargeting</b>	212	14 012	1,51 %	3,64 Kč	881,37 Kč
<b>Zaměstnání – Praha</b>	265	1 688	15,70 %	3,02 Kč	<b>798,97 Kč</b>
<b>Zaměstnání – Region</b>	293	1 487	<b>19,70 %</b>	<b>2,76 Kč</b>	800,19 Kč
<b>Celkem</b>	<b>1 190</b>	61 590	1,93 %	3,31 Kč	4 120,18 Kč

Zdroj: Vlastní

## Středa

Výsledky středečního dne opět potvrzují dlouhodobou dominanci regionální vyhledávací kampaně. Regionální kampaň se ukazuje jako nejvýhodnější formát – za málo peněz přináší stabilně vysoký výkon.

Tabulka 9 - Výkonnostní kampaň (středa)

	Prokliky	Zobrazení	CTR	CPC Ø	Cena
středa	Součet	Součet	Průměr	Průměr	Součet
<b>Bannery – Obsah</b>	<b>434</b>	<b>39 997</b>	1,09 %	3,75 Kč	1 670,46 Kč
<b>Bannery – Retargeting</b>	226	14 420	1,57 %	3,12 Kč	914,57 Kč
<b>Zaměstnání – Praha</b>	264	1 772	14,90 %	3,09 Kč	812,44 Kč
<b>Zaměstnání – Region</b>	297	1 573	<b>18,88 %</b>	<b>2,69 Kč</b>	<b>791,40 Kč</b>
<b>Celkem</b>	<b>1 221</b>	57 762	2,11 %	3,16 Kč	4 188,87 Kč

Zdroj: Vlastní

## Čtvrtek

Obě vyhledávací kampaně si i ve čtvrtek drží výbornou výkonnost. Poměr cena/výkon je u nich opět bezkonkurenční. Bannerové kampaně zde dosahují zásahu v součtu přes 43 tisíc zobrazení za celkové náklady 1 639,02 Kč. Nejnižší náklady byly vynaloženy za vyhledávací kampaň zaměřenou na Prahu.

Tabulka 10 - Výkonnostní kampaň (čtvrtek)

	<b>Prokliky</b>	<b>Zobrazení</b>	<b>CTR</b>	<b>CPC Ø</b>	<b>Cena</b>
čtvrtek	Součet	Součet	Průměr	Průměr	Součet
<b>Bannery – Obsah</b>	<b>445</b>	<b>43 455</b>	1,02 %	3,66 Kč	1 639,02 Kč
<b>Bannery – Retargeting</b>	219	13 764	1,59 %	3,15 Kč	899,00 Kč
<b>Zaměstnání – Praha</b>	259	1 624	15,95 %	3,04 Kč	<b>784,90 Kč</b>
<b>Zaměstnání – Region</b>	301	1 702	<b>17,69 %</b>	<b>2,71 Kč</b>	806,51 Kč
<b>Celkem</b>	1 224	60 545	2,02 %	3,14 Kč	4 129,43 Kč

Zdroj: Vlastní

## Pátek

Bannery i v pátek táhnou z hlediska objemu, ale jejich efektivita je slabší – stále platí trend vysokého zásahu s nižším zaujetím publika. V souhrnných metrikách se odráží i to, že se jedná o konec pracovního týdne – snížení počtu zobrazení a prokliků, který se odráží jak v průměrné ceně za jeden proklik, tak i ve vynaložených nákladech. Avšak CTR dosahuje své maximální hodnoty za všechny pracovní dny.

Tabulka 11 - Výkonnostní kampaň (pátek)

	<b>Prokliky</b>	<b>Zobrazení</b>	<b>CTR</b>	<b>CPC Ø</b>	<b>Cena</b>
pátek	Součet	Součet	Průměr	Průměr	Součet
<b>Bannery – Obsah</b>	<b>430</b>	<b>34 679</b>	1,24 %	3,65 Kč	1 595,24 Kč
<b>Bannery – Retargeting</b>	235	13 040	1,80 %	3,48 Kč	938,18 Kč
<b>Zaměstnání – Praha</b>	202	1 244	16,24 %	3,40 Kč	<b>684,66 Kč</b>
<b>Zaměstnání – Region</b>	234	1 212	<b>19,31 %</b>	<b>3,14 Kč</b>	723,73 Kč
<b>Celkem</b>	1 101	50 175	2,19 %	3,42 Kč	3 941,81 Kč

Zdroj: Vlastní

## Sobota

Obě vyhledávací kampaně zaznamenávají během soboty propad v zobrazení a proklikách. I přes to si ale udržují svou efektivitu a generují poměrně kvalitní návštěvnost. Regionální kampaň dokonce zaznamenává své maximum v rámci CTR, které překračuje hranici 20 %. Bannerové kampaně si stále udržují svoji efektivitu v počtu zobrazení.

Tabulka 12 - Výkonnostní kampaň (sobota)

	Prokliky	Zobrazení	CTR	CPC Ø	Cena
sobota	Součet	Součet	Průměr	Průměr	Součet
<b>Bannery – Obsah</b>	<b>471</b>	<b>40 218</b>	1,17 %	3,40 Kč	1 602,24 Kč
<b>Bannery – Retargeting</b>	214	12 182	1,76 %	3,45 Kč	848,61 Kč
<b>Zaměstnání – Praha</b>	172	962	17,88 %	3,81 Kč	<b>654,31 Kč</b>
<b>Zaměstnání – Region</b>	219	1 080	<b>20,28 %</b>	<b>3,07 Kč</b>	662,71 Kč
<b>Celkem</b>	1 076	54 442	1,98 %	3,43 Kč	3 767,87 Kč

Zdroj: Vlastní

## Neděle

V posledním dni týdne bannery – zejména retargeting – vykazuje vysoké ceny za proklik a nízkou návratnost. Vyhledávací kampaně zůstávají efektivní a obě hodnoty CTR přesahují hranici 16 %. Celkové CTR dne je 2,33 %, což je nejvyšší hodnota za celý týden.

Tabulka 13 - Výkonnostní kampaň (neděle)

	Prokliky	Zobrazení	CTR	CPC Ø	Cena
neděle	Součet	Součet	Průměr	Průměr	Součet
<b>Bannery – Obsah</b>	<b>433</b>	<b>32 283</b>	1,34 %	3,66 Kč	1 609,60 Kč
<b>Bannery – Retargeting</b>	258	12 954	1,99 %	3,89 Kč	989,64 Kč
<b>Zaměstnání – Praha</b>	193	1 175	16,43 %	3,60 Kč	691,93 Kč
<b>Zaměstnání – Region</b>	225	1 258	<b>17,89 %</b>	<b>3,08 Kč</b>	<b>690,63 Kč</b>
<b>Celkem</b>	1 109	47 670	2,33 %	3,56 Kč	3 981,80 Kč

Zdroj: Vlastní

## Vyhodnocení

Pro identifikaci nejefektivnější kampaně v jednotlivých dnech v týdnu byla aplikována metoda vícekritériálního porovnávání – bodovací metoda s využitím vah.

Každé kampani bylo přiřazeno bodové ohodnocení na základě výkonu v klíčových metrikách:

- **Počet prokliků** – maximální počet
- **Počet zobrazení** – maximální počet
- **Cena za proklik (CPC)** – minimální cena
- **Míra prokliku (CPR)** - maximální
- **Celkové náklady** – minimální cena

Bodové ohodnocení bylo přiděleno v rozmezí 1 až 4, kde 4 značí nejlepší výsledek a 1 nejslabší.

Tabulka 14 - Ohodnocení metrik body

	<b>Prokliky</b>	<b>Zobrazení</b>	<b>CTR</b>	<b>CPC Ø</b>	<b>Cena</b>
pondělí	Max	Max	Min	Max	Min
<b>Bannery – Obsah</b>	4	4	2	1	1
<b>Bannery – Retargeting</b>	1	3	1	3	2
<b>Zaměstání – Praha</b>	2	2	3	2	3
<b>Zaměstání – Region</b>	3	1	4	4	4

Zdroj: Vlastní

Pro zpřesnění analýzy byla jednotlivým metrikám přiřazena váha reflektující jejich relativní důležitost při vyhodnocování efektivity kampaní. Díky této úpravě bylo možné lépe rozlišit skutečně výkonné kampaně, které by v jednoduchém součtu pořadí mohly být nadhodnoceny či podhodnoceny.

- **Součet prokliků** – 30 % váha
- **Součet zobrazení** – 20 % váha
- **Průměrné CPC** – 20 % váha
- **Součet ceny** – 10 % váha
- **CTR** – 20 % váha

Tedy jednotlivé metriky byly přepočítány pomocí vynásobení s váhou, která je jí přiřazována.

Tabulka 15 - Přepočet metriky s váhou

	<b>Prokliky</b>	<b>Zobrazení</b>	<b>CTR</b>	<b>CPC Ø</b>	<b>Cena</b>
pondělí	30 %	20 %	20 %	10 %	20 %
<b>Bannery – Obsah</b>	1,20	0,80	0,40	0,10	0,20
<b>Bannery – Retargeting</b>	0,30	0,60	0,20	0,30	0,40
<b>Zaměstání – Praha</b>	0,60	0,40	0,60	0,20	0,60
<b>Zaměstání – Region</b>	0,90	0,20	0,80	0,40	0,80

Zdroj: Vlastní

Na závěr se hodnoty jednotlivých metrik sečetli v rámci kampaně pro jednotlivé dny a vznikla nová tabulka s výkoností kampaní v jednotlivých dnech.

Tabulka 16 - Vyhodnocení dnů

	Pondělí	Úterý	Středa	Čtvrtek	Pátek	Sobota	Neděle
<b>Bannery Obsah</b>	2,70	2,50	2,50	2,50	2,50	2,90	2,70
<b>Bannery Retargeting</b>	1,80	1,90	1,90	1,90	2,50	2,20	2,30
<b>Zaměstnání Praha</b>	2,40	2,60	2,30	2,40	2,30	1,70	2,00
<b>Zaměstnání Region</b>	<b>3,10</b>	<b>3,00</b>	<b>3,30</b>	<b>3,20</b>	<b>2,70</b>	<b>3,20</b>	<b>3,00</b>

Zdroj: Vlastní

Vyhledávací kampaň "Zaměstnání – region " byla nejvýkonnější ve všech dnech v týdnu. Tato kampaň dosáhla nejvyššího váženého skóre každý den, což ukazuje na její vysokou konzistenci a efektivitu napříč celým sledovaným obdobím. Její výkon v klíčových metrikách byl stabilně nadprůměrný, a to jak v pracovní dny, tak o víkendech.

Druhá vyhledávací kampaň "Zaměstnání – Praha" dosahovala druhých nejlepších výsledků převážně v průběhu pracovního týdne. V pondělí až čtvrtek se umísťovala těsně za kampaní zaměřené na region, avšak v sobotu a neděli její efektivita poklesla, pravděpodobně kvůli nižší relevanci pracovních inzerátů o víkendech.

Obsahová kampaň s bannery vykazovaly nejlepší výsledky zejména o víkendu. V sobotu a neděli se jejich vážené skóre zlepšovalo oproti pracovnímu týdnu, což naznačuje, že bannery lépe oslovují uživatele v době jejich volného času, kdy jsou více otevřeni nenáročným formám inzerce.

Nejnižší se umísťovala retargetingová kampaň. Většinu týdne dosahovaly slabších vážených skóre, což poukazuje na nutnost optimalizace nastavení retargetingu, ať už v oblasti kreativy, frekvence zobrazení nebo cílení.

Z analýzy vyplývá, že každý den v týdnu měl svého „vítěze“, avšak vyhledávací kampaň "Zaměstnání – Region " dominovala konzistentně napříč všemi dny. To potvrzuje, že tato kampaň měla nejvhodnější kombinaci zásahu, ceny i angažovanosti uživatelů v celém sledovaném období.

#### 8.4.4 Korelační analýza

Cílem korelační analýzy bylo ověřit existenci vzájemných vztahů mezi vybranými metrikami:

- zobrazeními
- prokliky
- náklady
- mírou prokliku (CTR)
- cenou za proklik (CPC)

Výsledky korelací byly vypočítány zvláště pro jednotlivé kampaně a barevně vyznačeny podle jejich síly dle rozložení síly korelace.

##### Korelace mezi zobrazení a prokliky

Obecně platí, že korelace mezi zobrazeními a prokliky je silně pozitivní. Tedy že zvyšování počtu zobrazení vede ke zvýšení počtu prokliků u všech kampaní. Tento výsledek logicky potvrzuje to tvrzení, že čím více uživatelů uvidí obsahovou reklamu, tím více uživatelů na ní klikne. Nejvýrazněji je to viditelné u retargetingové kampaně, kde korelace dosahuje hranice 9,92.

Tabulka 17 - Korelace mezi zobrazeními a prokliky

Korelace mezi zobrazeními a prokliky		
<b>Bannery – obsah</b>	0,7830	Silně pozitivní korelace
<b>Bannery – retargeting</b>	0,9210	Velmi silně pozitivní korelace
<b>Zaměstnání – region</b>	0,7744	Silně pozitivní korelace
<b>Zaměstnání – Praha</b>	0,6247	Středně pozitivní korelace

Zdroj: Vlastní

##### Korelace mezi náklady a prokliky

Tabulka vzájemné korelace mezi náklady a prokliky opět logicky potvrzuje to, že čím více prokliků bude, tím vyšší náklady musí firma vynaložit. Výjimečně silný vztah je vidět zejména u bannerové a retargetingové kampaně, kde se obě pohybují nad hranicí 0,9.

Tabulka 18 - Korelace mezi náklady a prokliky

Korelace mezi náklady a prokliky		
<b>Bannery – obsah</b>	0,9431	Velmi silná pozitivní korelace
<b>Bannery – retargeting</b>	0,9933	Velmi silná pozitivní korelace
<b>Zaměstnání – region</b>	0,6766	Středně pozitivní korelace
<b>Zaměstnání – Praha</b>	0,6985	Středně pozitivní korelace

Zdroj: Vlastní

## Korelace mezi CPC a CTR

U korelační analýzy mezi CPC a CTR hodnotami, se vyhodnocuje, zda vyšší atraktivita reklamy (vyšší CTR) souvisí s její cenou (CPC).

Z analýzy vyplývá, že pouze u bannerové kampaně se mírně projevuje klesající cena při vyšší míře prokliku, což naznačuje odměňování efektivních reklam systémem Sklik. Naopak u retargetingu i textových kampaní byla korelace spíše pozitivní, tedy vyšší cena za klik byla spojena s vyšším CTR, což může být způsobeno přesnějším cílením a vyšší konkurencí.

Tabulka 19 - Korelace mezi CPC a CTR

Korelace mezi CPC a CTR		
<b>Bannery – obsah</b>	-0,2826	Slabá negativní korelace
<b>Bannery – retargeting</b>	0,5796	Středně pozitivní korelace
<b>Zaměstnání – region</b>	0,1664	Velmi slabá pozitivní korelace
<b>Zaměstnání – Praha</b>	0,2389	Slabá pozitivní korelace

Zdroj: Vlastní

## Korelace mezi náklady a CPC

Cílem korelační analýzy mezi náklady a CPC bylo zjistit, zda se cena za jeden proklik promítá a jak výrazně do celkových nákladů. Je nutné brát v potaz i to, že do tohoto vztahu zasahuje také množství prokliků.

Z výsledků vyplývá, že mezi cenou za proklik a celkovými náklady existuje pouze slabá nebo žádná závislost. Výjimkou je retargetingová kampaň, kde byl zaznamenán středně silný pozitivní vztah. To znamená, že výše nákladů je ve většině případů řízena primárně objemem prokliků, nikoliv samotnou cenou za jeden klik.

Tabulka 20 - Korelace mezi náklady a CPC

Korelace mezi náklady a CPC		
<b>Bannery – obsah</b>	0,2776	Slabá pozitivní korelace
<b>Bannery – retargeting</b>	0,5403	Středně pozitivní korelace
<b>Zaměstnání – region</b>	-0,0412	Žádná korelace
<b>Zaměstnání – Praha</b>	0,0122	Žádná korelace

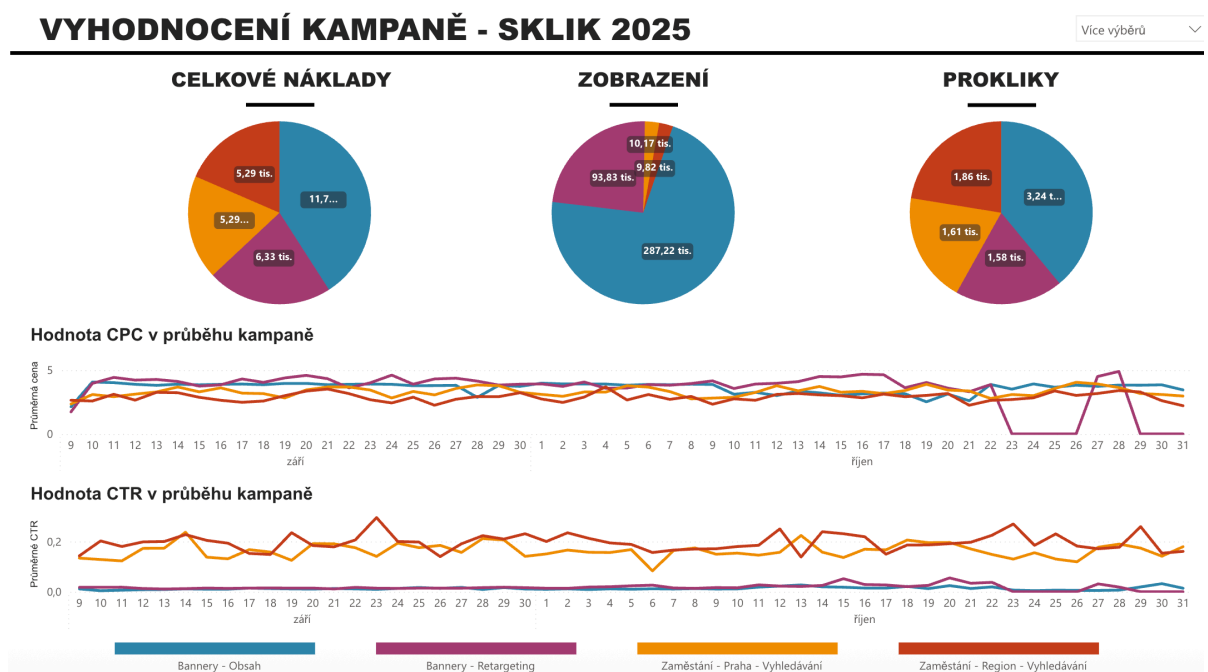
Zdroj: Vlastní

### 8.4.5 Power BI model

Pro efektivnější prezentaci výsledků analýzy byla vytvořena interaktivní vizualizace dat v nástroji Power BI od společnosti Microsoft. Tento nástroj umožňuje tvorbu přehledných dashboardů, které kombinují různé typy grafických výstupů a interaktivních filtrů, čímž usnadňují intuitivní interpretaci výkonnostních metrik.

Součástí dashboardu jsou tři koláčové grafy zobrazující relativní podíl jednotlivých kampaní na celkových nákladech, počtu zobrazení a prokliků. Pro znázornění vývoje hodnot v čase byly využity spojnicové grafy, které sledují denní průměrné hodnoty metrik CPC a CTR za jednotlivé kampaně.

Dashboard dále obsahuje rozbalovací nabídku pro výběr sledovaného měsíce, což uživateli umožňuje jednoduše přepínat mezi obdobími září a října. V dolní části vizualizace je umístěna legenda usnadňující orientaci mezi jednotlivými typy kampaní. Díky možnosti interaktivní selekce lze v Power BI snadno získat detailní informace o konkrétní kampani či časovém úseku, což z něj činí vhodný nástroj pro prezentaci a vyhodnocování marketingových dat.



Obrázek 5 - Dashboard Power BI

Zdroj: Vlastní

## 8.5 Vyhodnocení praktické části

Praktická část diplomové práce byla zaměřena na analýzu dat z výkonnostních online kampaní, které probíhaly v rámci platformy Sklik během měsíců září a říjen 2024. Pro zpracování dat byla využita kombinace nástrojů Microsoft Excel a Power BI.

V metodologickém rámci byla analýza vedena podle struktury CRISP-DM, která poskytla systematický přístup od počátečního porozumění datům až po jejich interpretaci a návrh optimalizačních opatření.

Analýza zahrnovala několik klíčových částí:

- zhodnocení výkonnosti kampaní v čase (měsíční i denní vývoj),
- srovnání výkonu jednotlivých typů kampaní,
- analýzu vztahů mezi klíčovými metrikami (zobrazení, prokliky, CTR, CPC, náklady),
- korelační analýzu vybraných metrik,
- vícekriteriální hodnocení efektivity jednotlivých dnů a kampaní s využitím bodovací metody a přiřazení vah jednotlivým metrikám,
- vizualizaci dat prostřednictvím interaktivního dashboardu v Power BI.

Použití vícekriteriální metody s váhováním jednotlivých metrik umožnilo detailnější rozlišení výkonu kampaní a poskytlo hlubší pohled na efektivitu reklamy v závislosti na konkrétním dni v týdnu.

### 8.5.1 Klíčové poznatky

Výsledky provedené analýzy přinesly několik zásadních poznatků, které mohou sloužit jako podklad pro optimalizaci budoucích marketingových aktivit.

Vyhledávací kampaně s regionálním cílením dosahovaly dlouhodobě nejvyšší efektivity. Tyto kampaně vykazovaly velmi příznivý poměr mezi mírou prokliku (CTR), cenou za proklik (CPC) a celkovými náklady, což potvrzuje vysokou relevanci jejich obsahu pro cílovou skupinu.

Na základě vícekriteriálního porovnání s aplikací vah na jednotlivé metriky (prokliky, zobrazení, CPC, náklady a CTR) bylo možné detailněji posoudit výkonnost kampaní v průběhu týdne. Nejúspěšnějšími dny pro většinu kampaní byly pondělí a čtvrtek, kdy kampaně dosahovaly nejvyšší efektivity napříč sledovanými ukazateli. Nejúčinnější kampaň v rámci celého týdne byla vyhledávací kampaň „Zaměstnání – region“. Nejslabší výsledky napříč kampaněmi byly zaznamenány během víkendových dnů, a to především v oblasti nákladovosti a zapojení uživatelů

Použitá metoda bodového ohodnocení a váhování umožnila komplexnější srovnání výkonu kampaní a odhalila důležité trendy, které mohou být využity pro optimalizaci budoucích marketingových aktivit.

Korelační analýzy odhalily silnou pozitivní korelaci mezi počtem zobrazení a prokliků, což potvrzuje očekávanou závislost výkonu kampaně na jejím dosahu. Zároveň byla identifikována mírně negativní korelace mezi CPC a CTR, která naznačuje, že vyšší zapojení uživatelů může snižovat cenu za proklik.

Z hlediska prezentace dat se jako velmi přínosný nástroj ukázal interaktivní dashboard vytvořený v Power BI. Ten umožnil nejen vizualizaci základních metrik (náklady, prokliky, zobrazení), ale také dynamickou filtraci podle kampaní a časových období, čímž přispěl k lepšímu porozumění.

Tyto poznatky poskytují důležitý základ pro informované rozhodování o alokaci rozpočtu, časování kampaní a výběru vhodného formátu podle marketingových cílů.

### 8.5.2 Omezení analýzy

Ačkoli analýza výkonnostních kampaní přinesla řadu cenných poznatků a umožnila identifikovat klíčové faktory ovlivňující efektivitu online reklamy, je nezbytné se zaměřit také na její omezení. Tato omezení mohou mít vliv na rozsah interpretace výsledků i na možnosti jejich praktického využití.

Jedním z hlavních omezení je absence dat o konverzích, která by umožnila přesněji vyhodnotit skutečnou návratnost investice (ROI) a obchodní přínos jednotlivých kampaní. Bez těchto údajů je možné hodnotit výkonnost pouze z pohledu interakcí uživatelů se samotnou reklamou (pomocí prokliků, zobrazení, CTR či CPC), nikoli však z pohledu naplnění finálních marketingových nebo prodejních cílů.

Dále je třeba zmínit, že analýza nezohledňuje demografické, behaviorální ani geografické charakteristiky uživatelů, což do jisté míry omezuje možnosti segmentace cílového publika a hlubší personalizace marketingových sdělení. Chybějící informace tohoto typu by v budoucnu mohly být doplněny například prostřednictvím propojení dat z Google Analytics nebo systémů CRM.

Další omezení představuje samotný rozsah a povaha analyzovaných dat. Výsledky vycházejí pouze z období dvou měsíců a ze specifického typu kampaní, což může omezovat zobecnitelnost závěrů na širší marketingové aktivity nebo jiná časová období.

Dalším omezením je způsob vícekritériálního vyhodnocení jednotlivých dnů a kampaní, který sice využívá vážené hodnocení, avšak právě určení vah představuje určitý subjektivní prvek. Přestože zavedení vah umožňuje lépe zohlednit různou důležitost jednotlivých metrik, výběr jejich konkrétních hodnot závisí na úsudku analytika a nemusí přesně odpovídat všem typům kampaní či marketingovým cílům. Nevhodně nastavené váhy mohou vést ke zkreslení výsledků a ovlivnit interpretaci efektivity. Navíc váhy definované pro tuto analýzu nemusí být plně přenositelné na jiné kampaně nebo období bez dalšího ověření a úpravy.

V neposlední řadě je třeba zmínit, že veškerá data byla analyzována retrospektivně, tedy po ukončení kampaní. Výsledky tak reflektují historický výkon a pro predikci budoucího chování by bylo nutné je doplnit o aktuální kontext a proměnné v čase.

Přes uvedená omezení lze výsledky považovat za relevantní a přínosné pro další rozhodování, zejména v oblasti plánování kampaní, optimalizace nákladů a efektivnějšího cílení marketingových aktivit.

### 8.5.3 Příležitosti pro další rozvoj

Na základě realizované analýzy a identifikovaných omezení je možné vymezit několik oblastí, které představují potenciál pro další rozvoj a zkvalitnění marketingových aktivit i samotného procesu datové analýzy.

Jednou z klíčových příležitostí je doplnění konverzních dat, která by umožnila nejen sledovat počet interakcí s reklamou, ale také posoudit, jaký reálný obchodní přínos tyto interakce přinesly. Zavedení měření konverzí by výrazně rozšířilo analytický rámec směrem k posouzení výkonnosti z pohledu návratnosti investic (ROI) a umožnilo by efektivnější rozhodování o alokaci rozpočtu.

Za významnou příležitost lze považovat také implementaci A/B testování, tedy porovnávání různých variant reklamních sdělení, umístění či časování. Tento přístup by umožnil testovat konkrétní hypotézy o chování cílové skupiny a na základě reálných dat zvolit nejefektivnější variantu kampaně.

Další možností je rozšíření analytických nástrojů o behaviorální, demografické a geografické údaje, které by poskytly hlubší vhled do charakteristik publika. Získané informace by bylo možné využít k cílenější personalizaci sdělení a vytváření segmentovaných kampaní s vyšší relevancí pro jednotlivé skupiny uživatelů.

Z hlediska metodiky analýzy představuje příležitost další práce s váženým vícekriteriálním rozhodováním. Nastavení vah jednotlivým metrikám umožňuje přizpůsobit hodnocení různým strategickým prioritám firmy (například preferenci nižších nákladů nebo vyššího zapojení uživatelů) a vytvořit tak flexibilnější a přesnější analytické modely. Možné je také využít pokročilejší metody, jako je Analytic Hierarchy Process (AHP), které pomáhají formálně strukturovat rozhodovací procesy.

V neposlední řadě se nabízí možnost rozšíření analýzy o dlouhodobé trendy v čase – například sledování vývoje výkonnosti kampaní v jednotlivých čtvrtletích, sezónních obdobích či v reakci na vnější události.

Tyto příležitosti ukazují, že datová analýza výkonnostních kampaní představuje dynamickou oblast s vysokým potenciálem pro neustálé zlepšování marketingových strategií a dosažení vyšší efektivity vynakládaných investic.

## 9 ZÁVĚR

Cílem této diplomové práce bylo analyzovat data z online marketingových kampaní stavební společnosti a na jejich základě navrhnout strategii optimalizace výkonnosti kampaní.

V teoretické části byly vymezeny klíčové pojmy z oblasti marketingu, datové analýzy a metodiky CRISP-DM, která byla následně využita jako rámec pro strukturované zpracování praktické části. Dále byly popsány zdroje dat pro marketingové účely, metody a techniky jejich analýzy a rovněž význam big data v marketingovém prostředí. Tato teoretická východiska vytvořila pevný základ pro následnou aplikaci v praxi.

Praktická část se zaměřila na datovou analýzu kampaní probíhajících v rámci reklamní sítě Sklik během září a října 2024. Pomocí nástrojů Microsoft Excel a Power BI byly vyhodnoceny metriky jako počet zobrazení, prokliků, CTR, CPC a celkové náklady. Analýza zahrnovala vývoj výkonu v čase, srovnání jednotlivých typů kampaní a jejich efektivitu podle dnů v týdnu. Součástí byla také korelační analýza vztahů mezi klíčovými metrikami a vícekritériální porovnání pomocí bodovací metody s přiřazenými vahami jednotlivým ukazatelům.

Výsledky ukázaly, že nejvyšší efektivitu dosahovaly kampaně zaměřené na vyhledávání v regionech. Nejvhodnějším dnem pro nasazení kampaní se jevil čtvrtek, zatímco víkendové dny vykazovaly nejnižší výkonnost. Korelační analýzy potvrdily očekávané vztahy mezi metrikami, přičemž vyšší míra angažovanosti uživatelů byla často spojena s nižšími náklady na proklik.

Přestože analýza přinesla řadu praktických poznatků, identifikovala také určitá omezení, zejména absenci dat o konverzích a demografických charakteristikách publika. Z těchto zjištění vyplývají příležitosti pro budoucí rozšíření analýzy – například implementace A/B testování, zapojení behaviorálních dat či dlouhodobé sledování trendů.

Práce tak ukazuje, že kombinací dostupných analytických nástrojů a promyšleného metodického přístupu lze získat cenné poznatky pro datově podložené rozhodování v oblasti digitálního marketingu a zároveň identifikovat směr pro jeho další rozvoj.

## POUŽITÁ LITERATURA

- [1] CUESTA, Hector. *Analýza dat v praxi*. Albatros Media, 2015. ISBN 978-80-251-4361-2.
- [2] BAIG, Mirza Rahim; GOVINDAN, Gururajan a SHRIMALI, Vishwesh Ravi. *Data Science for Marketing Analytics – Second Edition: A practical guide to forming a killer marketing strategy through data analysis with Python*. 2. vydání. Packt Publishing, 2021. ISBN 978-1800560475.
- [3] NELSON, Daniel. *Strukturovaná vs nestrukturovaná data*. Online. Dostupné z: <https://www.unite.ai/cs/structured-vs-unstructured-data/>. [cit. 2025-01-11].
- [4] *Structured vs Unstructured data*. Online. Dostupné z: <https://www.ibm.com/think/topics/structured-vs-unstructured-data>. [cit. 2025-01-11].
- [5] *What is Semi-structured data?* Online. Dostupné z: <https://www.geeksforgeeks.org/what-is-semi-structured-data/>. [cit. 2025-01-11].
- [6] *Data-driven marketing*. Online. Adverity. Dostupné z: <https://www.adverity.com/data-driven-marketing>. [cit. 2025-02-13].
- [7] *How to design an AI marketing strategy*. Online. Harvard Business Review. Dostupné z: <https://hbr.org/2021/07/how-to-design-an-ai-marketing-strategy>. [cit. 2025-01-11].
- [8] *What is marketing data*. Online. Dostupné z: <https://www.cognism.com/what-is-marketing-data>. [cit. 2025-01-11].
- [9] KOZEL, Roman; MYNÁŘOVÁ, Lenka a SVOBODOVÁ, Hana. *Moderní metody a techniky marketingového výzkumu*. Grada, 2011. ISBN 978-80-247-3527-6.
- [10] *Marketingový výzkum trhu*. Online. Ecommerce Bridge. Dostupné z: <https://www.ecommercebridge.cz/marketingovy-vyzkum-trhu-jak-ho-delat-efektivne/>. [cit. 2025-01-16].
- [11] FORET, Miroslav. *Marketingový výzkum v udržitelném marketingovém managementu*. Grada, 2020. ISBN 978-80-271-1723-9.
- [12] *Jaké jsou typy výzkumů?* Online. Mind The Graph. Dostupné z: <https://mindthegraph.com/blog/cs/jake-jsou-typy-vyzkumu/>. [cit. 2025-01-14].
- [13] *Primární a sekundární výzkum*. Online. Mind The Graph. Dostupné z: <https://mindthegraph.com/blog/cs/co-je-deduktivni-duvodova-kopie/>. [cit. 2025-01-14].
- [14] *Kvalitativní a Kvantitativní výzkum*. Online. Mind The Graph. Dostupné z: <https://mindthegraph.com/blog/cs/kvalitativni-a-kvantitativni-vyzkum/>. [cit. 2025-01-14].
- [15] FRANCIS, Buttle a STAN, Maklan. *Customer Relationship Management : Concepts and Technologies*. Taylor & Francis, 2019. ISBN 978-1-138-49825-9.
- [16] DAVENPORT, Thomas H. a HARRIS, Jeanne. *Competing on Analytics: The New Science of Winning*. 2. Harvard Business Review Press, 2017. ISBN 9781633693722.

- [17] What is data sourcing. Online. Medium. 2024. Dostupné z: <https://medium.com/@datajournal/what-is-data-sourcing-126283ae4b72>. [cit. 2025-03-04].
- [18] Data gathering. Online. OpenDataSoft. Dostupné z: <https://www.opendatasoft.com/en/glossary/data-gathering/>. [cit. 2025-03-04].
- [19] What is Data Sourcing. Online. Reltio. 2022. Dostupné z: <https://www.reltio.com/resources/blog/data-sourcing-sources-to-include/>. [cit. 2025-03-04].
- [20] Internal and external data. Online. Forloop. 2023. Dostupné z: <https://www.forloop.ai/blog/internal-and-external-data>. [cit. 2025-03-04].
- [21] What is hubspot CRM. Online. Innovation Visual. Dostupné z: <https://www.innovationvisual.com/knowledge/what-is-hubspot-crm>. [cit. 2025-03-04].
- [22] Types of CRM. Online. Oracle. Dostupné z: <https://www.oracle.com/cz/cx/what-is-crm/types-of-crm/>. [cit. 2025-03-06].
- [23] Co je CRM. Online. Raynet. 2023. Dostupné z: <https://raynet.cz/co-je-crm/#>. [cit. 2025-03-06].
- [24] What are the functions of a CRM system? Online. Grow. 2024. Dostupné z: <https://blog.growinternational.eu/en/what-are-the-functions-of-a-crm-system>. [cit. 2025-03-06].
- [25] CHAFFEY, Dave a ELLIS-CHADWICK, Fiona. Digital Marketing. 8th. Pearson, 2022. ISBN 9781292400969.
- [26] What is transactional data. Online. Tibco. 2025. Dostupné z: <https://www.tibco.com/glossary/what-is-transactional-data>. [cit. 2025-03-11].
- [27] Transakční data. Online. Managementmania. Dostupné z: <https://managementmania.com/cs/transakcni-data>. [cit. 2025-03-11].
- [28] What is transactional data. Online. Indeed. Dostupné z: <https://ca.indeed.com/career-advice/career-development/what-is-transactional-data>. [cit. 2025-03-11].
- [29] WILSON, Alan. *Marketing Research An Integrated Approach*. 3. Pearson India, 2014. ISBN 978-9332535572.
- [30] HARIHARAN, Naveen Kunnathuvalappil. DATA SOURCES FOR BUSINESS INTELLIGENCE. INTERNATIONAL JOURNAL OF INNOVATIONS IN ENGINEERING RESEARCH AND TECHNOLOGY. 2018, roč. 5, č. 11, s. 6. ISSN 2394-3696.
- [31] The What, Why, and How of External Data. Online. Demyst. Dostupné z: <https://demyst.com/blog/the-what-why-and-how-of-external-data>. [cit. 2025-03-17].
- [32] External data. Online. HR Forecast. Dostupné z: <https://hrforecast.com/hr-glossary/external-data/>. [cit. 2025-03-17].

- [33] Činnost ČSÚ. Online. Český statistický úřad. Dostupné z: <https://csu.gov.cz/cinnost-csu>. [cit. 2025-03-17].
- [34] WHO - Data. Online. World Health Organization. Dostupné z: <https://www.who.int/data>. [cit. 2025-03-17].
- [35] Social media analytics. Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/social-media-analytics>. [cit. 2025-03-17].
- [36] Social media management. Online. Sprout Social. Dostupné z: <https://sproutsocial.com/social-media-management/>. [cit. 2025-03-17].
- [37] IBM Watson. Online. IBM. Dostupné z: <https://www.ibm.com/watson>. [cit. 2025-03-17].
- [38] Průzkum trhu. Online. Zeptej se Filipa. Dostupné z: <https://zsf.cz/slovník/pruzkum-trhu>. [cit. 2025-03-18].
- [39] How to Do Market Research, Types, and Example. Online. Investopedia. Dostupné z: <https://www.investopedia.com/terms/m/market-research.asp>. [cit. 2025-03-18].
- [40] How IoT Works? Online. Appscrip. Dostupné z: <https://appscrip.com/blog/how-internet-of-things-works-process-explained/>. [cit. 2025-03-18].
- [41] Internet of things. Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/internet-of-things>. [cit. 2025-03-18].
- [42] What is IoT. Online. SAP. Dostupné z: <https://www.sap.com/cz/products/artificial-intelligence/what-is-iot.html>. [cit. 2025-03-18].
- [43] Digital Marketing Analytics: Making Sense of Consumer Data in a Digital World. 2. Que Publishing, 2018. ISBN 978-0789759603.
- [44] Laurie, Sally & Mortimer, Kathleen & Holtz, Matthew & Little, Billy. (2023). Enhancing Students' Understanding of Social Media Marketing and the Use of Advertising and Public Relations Terminology Within IMC: A Participatory Action Research Project. *Journal of Marketing Education*. 46. 027347532311626. 10.1177/02734753231162610.
- [45] POEM model. Online. Dostupné z: <https://www.engati.com/glossary/poem-model>. [cit. 2025-02-17].
- [46] POEM. Online. Dostupné z: <https://www.generaxion.com/get-inspired/poem-paid-owned-and-earned-media/>. [cit. 2025-02-17].
- [47] Bannerová reklama od A do Z. Online. Dostupné z: <https://www.seoconsult.cz/blog/bannerova-reklama-od-do-z>. [cit. 2025-02-17].
- [48] Co je PPC reklama. Online. Dostupné z: <https://hanakobzova.cz/co-je-ppc-reklama/>. [cit. 2025-02-17].
- [49] Jak vyhodnocovat PPC reklamu pro web. Online. Dostupné z: <https://www.posunemevasvys.cz/blog/jak-vyhodnocovat-ppc-reklamu-pro-web/>. [cit. 2025-02-17].
- [50] Sklik – PPC reklama. Online. Dostupné z: <https://www.marketingppc.cz/ppc/sklik/>. [cit. 2025-02-17].

- [51] Efektivita marketingové kampaně. Online. Dostupné z: <https://www.finteza.com/cs/campaigns/analytics-metrics>. [cit. 2025-02-17].
- [52] Programatická reklama. Online. SBlog. Dostupné z: <https://blog.seznam.cz/slovník/programaticka-reklama/>. [cit. 2025-02-17].
- [53] RTB – Programatická reklama. Online. Marketing PPC. Dostupné z: <https://www.marketingppc.cz/ppc/rtb-programaticka-reklama/>. [cit. 2025-02-17].
- [54] Recenze jako silný nástroj marketingu. Online. Imperialmedia. Dostupné z: <https://www.imperialmedia.cz/recenze-jako-silny-nastroj-marketingu/>. [cit. 2025-02-17].
- [55] Word of mouth marketing. Online. Key Advantage. Dostupné z: <https://www.key-advantage.cz/word-of-mouth-marketing/>. [cit. 2025-02-17].
- [56] POEM framework in digital marketing. Online. Dostupné z: <https://nestershush.com/blog/poem-framework-in-digital-marketing/>. [cit. 2025-02-17].
- [57] How Starbucks red cup became holiday marketing icon. Online. NeonSupply. Dostupné z: <https://blog.neonsupply.com/how-starbucks-red-cup-became-holiday-marketing-icon>. [cit. 2025-02-17].
- [58] JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor a TIBSHIRANI, Robert. An introduction to statistical learning: with applications in R. 8th. Springer texts in statistics. New York: Springer, 2017. ISBN 978-1-4614-7137-0.
- [59] HAIR, Joseph a BABIN, Barry. Multivariate Data Analysis. 8. CENGAGE INDIA, 2018. ISBN 9353501350.
- [60] HEMANN, Chuck a Ken BURBARY. Digital Marketing Analytics: Making Sense of Consumer Data in a Digital World (Que Biz-Tech). 2. vydání. Pearson Que Publishing, 2018. ISBN 978-0789759603.
- [61] BAIG, Mirza Rahim; GOVINDAN, Gururajan a SHRIMALI, Vishwesh Ravi. Data Science for Marketing Analytics – Second Edition: A practical guide to forming a killer marketing strategy through data analysis with Python. 2. vydání. Packt Publishing, 2021. ISBN 978-1800560475.
- [62] Descriptive statistics. Online. Investopedia. 2024. Dostupné z: [https://www.investopedia.com/terms/d/descriptive\\_statistics.asp](https://www.investopedia.com/terms/d/descriptive_statistics.asp). [cit. 2025-03-27].
- [63] Inferential statistics. Online. Cuemath. Dostupné z: <https://www.cuemath.com/data/inferential-statistics/>. [cit. 2025-03-27].
- [64] Exploratory Data Analysis. Online. JMP. Dostupné z: <https://www.jmp.com/en/statistics-knowledge-portal/exploratory-data-analysis>. [cit. 2025-03-27].
- [65] Exploratory data analysis. Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/exploratory-data-analysis>. [cit. 2025-03-27].
- [66] Co je machine learning? Online. Microsoft Azure. Dostupné z: <https://azure.microsoft.com/cs-cz/resources/cloud-computing-dictionary/what-is-machine-learning-platform>. [cit. 2025-03-28].

- [67] Co je to strojové učení? Online. SAP. Dostupné z: <https://www.sap.com/cz/products/artificial-intelligence/what-is-machine-learning.html>. [cit. 2025-03-28].
- [68] Co je strojové učení a jak souvisí s umělou inteligencí? Online. Rascasone. Dostupné z: <https://www.rascasone.com/cs/blog/strojove-uceni-ml-metody-klasifikace>. [cit. 2025-03-28].
- [69] What is Supervised Learning? Online. Google Cloud. Dostupné z: <https://cloud.google.com/discover/what-is-supervised-learning>. [cit. 2025-03-28].
- [70] Supervised learning. Online. Oracle. Dostupné z: <https://www.oracle.com/cz/artificial-intelligence/machine-learning/supervised-learning/>. [cit. 2025-03-28].
- [71] What is supervised learning? Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/supervised-learning#How+supervised+learning+works>. [cit. 2025-03-28].
- [72] NASTESKI, Vladimir. An overview of the supervised machine learning methods. Online. S. 12. Dostupné z: <https://doi.org/10.20544/HORIZONS.B.04.1.17.P05>. [cit. 2025-03-28].
- [73] Supervised Machine Learning: A Vital Tool for Modern Business Leaders. Online. Mailchimp. <https://mailchimp.com/>. Dostupné z: <https://mailchimp.com/resources/supervised-machine-learning/>. [cit. 2025-03-28].
- [74] What Is Unsupervised Learning? Online. Mathworks. Dostupné z: <https://www.mathworks.com/discovery/unsupervised-learning.html>. [cit. 2025-03-28].
- [75] What is unsupervised learning? Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/unsupervised-learning#Challenges+of+unsupervised+learning>. [cit. 2025-03-28].
- [76] What is unsupervised learning. Online. Google Cloud. Dostupné z: <https://cloud.google.com/discover/what-is-unsupervised-learning>. [cit. 2025-03-28].
- [77] What is reinforcement learning? Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/reinforcement-learning>. [cit. 2025-03-28].
- [78] What are the Reinforcement Learning Advantages and Disadvantages? Online. Birchwoodu. Dostupné z: <https://www.birchwoodu.org/reinforcement-learning-advantages-and-disadvantages/>. [cit. 2025-03-28].
- [79] 10 Pros and Cons of Reinforcement Learning. Online. Digitaldefynd. 2025. Dostupné z: <https://digitaldefynd.com/IQ/reinforcement-learning-pros-cons/>. [cit. 2025-03-28].
- [80] Data mining. Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/data-mining>. [cit. 2025-03-29].
- [81] Data mining. Online. Investopedia. Dostupné z: <https://www.investopedia.com/terms/d/datamining.asp>. [cit. 2025-03-29].

- [82] Difference Between Data mining and Machine learning. Online. GeeksForGeeks. Dostupné z: <https://www.geeksforgeeks.org/difference-between-data-mining-and-machine-learning/>. [cit. 2025-03-29].
- [83] What is the Difference Between Data Mining and Machine Learning? Online. Discoverdatascience. Dostupné z: <https://www.discoverdatascience.org/articles/data-mining-vs-machine-learning/>. [cit. 2025-03-29].
- [84] JABLONSKÝ, Josef. *Operační výzkum: kvantitativní modely pro ekonomické rozhodování*. Praha: Professional Publishing, 2002. ISBN 80-864-1923-1.
- [85] LIU, Bing. *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*. Cambridge University Press, 2015. ISBN 1107017890.
- [86] Text mining. Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/text-mining>. [cit. 2025-03-29].
- [87] What Is Text Mining & How Does It Work? Online. Netsuite. Dostupné z: <https://www.netsuite.com/portal/resource/articles/data-warehouse/text-mining.shtml>. [cit. 2025-03-29].
- [88] NOVOTNÝ, Ota; POUR, Jan a SLÁNSKÝ, David. *Business Intelligence: jak využít bohatství ve vašich datech. Management v informační společnosti*. Praha: Grada, 2005. ISBN 80-247-1094-3.
- [89] What is business intelligence (BI)? Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/business-intelligence>. [cit. 2025-03-31].
- [90] What Is Business Intelligence? Online. Oracle. 2021. Dostupné z: <https://www.oracle.com/cz/what-is-business-intelligence/>. [cit. 2025-03-31].
- [91] What is BI? Online. SAP. Dostupné z: <https://www.sap.com/cz/products/data-cloud/cloud-analytics/what-is-business-intelligence.html>. [cit. 2025-03-31].
- [92] Business Intelligence for Digital Marketing. Online. DataScientest. 2024. Dostupné z: <https://datascientest.com/en/business-intelligence-for-digital-marketing>. [cit. 2025-03-31].
- [93] TONKIN, Sebastian; WHITMORE, Caleb a CUTRONI, Justin. *Výkonnostní marketing s Google Analytics*. Brno: Computer Press, 2011. ISBN 978-80-251-3339-2.
- [94] ALHLOU, Feras, Shiraz ASIF a Eric FETTMAN. *Google Analytics Breakthrough: From Zero to Business Impact*. Wiley, 2016. ISBN 978-1-119-14401-4.
- [95] Google Analytics. Online. Idealab. Dostupné z: <https://idealab.cz/slovník/google-analytics/>. [cit. 2025-03-31].
- [96] What is Google Analytics. Online. WebFX. Dostupné z: <https://www.webfx.com/analytics/glossary/what-is-google-analytics/>. [cit. 2025-03-31].
- [97] 12 Key Google Analytics Metrics to Track. Online. Semrush. 2024. Dostupné z: <https://www.semrush.com/blog/metrics-in-google-analytics/>. [cit. 2025-03-31].

- [98] Looker Studio. Online. Google Cloud. Dostupné z: <https://cloud.google.com/looker/docs/studio>. [cit. 2025-03-31].
- [99] Looker Studio. Online. MarketingPPC. Dostupné z: <https://www.marketingppc.cz/ppc/looker-studio/>. [cit. 2025-03-31].
- [100] Tableau. Online. BuiltIn. Dostupné z: <https://builtin.com/data-science/tableau>. [cit. 2025-03-31].
- [101] What is Tableau. Online. Tableau. Dostupné z: <https://www.tableau.com/why-tableau/what-is-tableau>. [cit. 2025-03-31].
- [102] Tableau Public. Online. Tableau Public. Dostupné z: <https://public.tableau.com/app/about>. [cit. 2025-03-31].
- [103] What is Power BI? Online. Learn Microsoft. 2024. Dostupné z: <https://learn.microsoft.com/en-us/power-bi/fundamentals/power-bi-overview>. [cit. 2025-03-31].
- [104] What is Power BI?: Architecture, and Features Explained. Online. Simplilearn. 2025. Dostupné z: <https://www.simplilearn.com/tutorials/power-bi-tutorial/what-is-power-bi>. [cit. 2025-03-31].
- [105] *ELT*. Online. AWS. Dostupné z: <https://aws.amazon.com/what-is/etl/>. [cit. 2025-03-31].
- [106] MATTER, Ulrich. Big data analytics : a guide to data science practitioners making the transition to big data. CRC Press, 2024. ISBN 978-1-003-37882-2.
- [107] MALTBY, Dylan. Big Data Analytics. Texas, USA: University of Texas at Austin, 2011.
- [108] MAYER-SCHÖNBERGER, Viktor a CUKIER, Kenneth. Big Data: A Revolution That Will Transform How We Live, Work, and Think. Harper Business, 2014. ISBN 0544227751.
- [109] EREMENKO, Kirill. Data s přehledem: naučte se pracovat s daty a zajistěte si skvělou kariéru. Brno: Lingea, 2024. ISBN 978-80-7508-952-6.
- [110] What is big data? Online. Oracle. Dostupné z: <https://www.oracle.com/cz/big-data/what-is-big-data/>. [cit. 2025-03-20].
- [111] Big data, co to je a jak je využijete ke zvýšení zisků. Online. Algotech. Dostupné z: <https://www.algotech.cz/novinky/big-data-co-to-je-a-jak-je-vyuzijete-ke-zvyseni-zisku>. [cit. 2025-03-20].
- [112] What are the 5 V's of Big Data? Online. Teradata. Dostupné z: <https://www.teradata.com/glossary/what-are-the-5-v-s-of-big-data>. [cit. 2025-03-20].
- [113] Hadoop Apache. Online. Dostupné z: <https://hadoop.apache.org/>. [cit. 2025-03-20].
- [114] What is Apache Hadoop? Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/hadoop>. [cit. 2025-03-20].
- [115] What is MapReduce? Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/mapreduce>. [cit. 2025-03-31].

- [116] What is Apache Spark? Online. IBM. Dostupné z: <https://www.ibm.com/think/topics/apache-spark>. [cit. 2025-03-20].
- [117] What is Apache Kafka? Online. Confluent. Dostupné z: <https://www.confluent.io/what-is-apache-kafka/>. [cit. 2025-03-20].
- [118] What is Apache Flink? Online. AWS Amazon. Dostupné z: <https://aws.amazon.com/what-is/apache-flink/>. [cit. 2025-03-31].
- [119] 10 Best Big Data Tools for 2024. Online. Jelvix. Dostupné z: <https://jelvix.com/blog/top-5-big-data-frameworks>. [cit. 2025-03-20].
- [120] Big Data in Marketing: Exploring Applications, Benefits, and Challenges. Online. Adaglobal. Dostupné z: <https://www.adaglobal.com/resources/insights/applications-of-big-data-in-marketing>. [cit. 2025-03-20].
- [121] Big Data In Marketing: 9 Examples & Use Cases. Online. Keboola. Dostupné z: <https://www.keboola.com/blog/big-data-in-marketing-examples>. [cit. 2025-03-20].
- [122] What is Big Data in Marketing? Online. Institute of Data. 2023. Dostupné z: <https://www.institutedata.com/blog/what-is-big-data-in-marketing/>. [cit. 2025-03-20].
- [123] Jak funguje personalizace a kde se s ní můžete setkat. Online. Ecommercebridge. 2020. Dostupné z: <https://www.ecommercebridge.cz/jak-funguje-personalizace-a-kde-se-s-ni-muzete-setkat/>. [cit. 2025-03-25].
- [124] Personalized Marketing Software: Features, Benefits, and More. Online. Moengage. 2024. Dostupné z: <https://www.moengage.com/blog/personalized-marketing-software/>. [cit. 2025-03-25].
- [125] Segmentace zákazníků: co, proč, jak. Online. Shh. Dostupné z: <https://www.shh.agency/clanek/segmentace-zakazniku-co-proc-jak>. [cit. 2025-03-25].
- [126] Co je to segmentace zákazníků a jak na ní můžete vydělat? Online. AutoCRM. Dostupné z: <https://autocrm.cz/co-je-to-segmentace-zakazniku-a-jak-na-ni-muzete-vydelat/>. [cit. 2025-03-25].
- [127] Customer Segmentation. Online. Optimove. Dostupné z: <https://www.optimove.com/resources/learning-center/customer-segmentation>. [cit. 2025-03-25].
- [128] RFM analysis. Online. Techtarget. Dostupné z: <https://www.techtarget.com/searchdatamanagement/definition/RFM-analysis>. [cit. 2025-03-25].
- [129] RFM analysis. Online. Botpenguin. Dostupné z: <https://botpenguin.com/glossary/rfm-analysis>. [cit. 2025-03-25].
- [130] What is A/B testing? Online. Oracle. Dostupné z: <https://www.oracle.com/cz/cx/marketing/what-is-ab-testing/>. [cit. 2025-03-25].
- [131] A/B Testing. Online. Mediaguru. Dostupné z: <https://www.mediaguru.cz/slovník-a-mediatypy/slovník/klicova-slova/a-b-testing/>. [cit. 2025-03-25].

- [132] A/B Testing Guide. Online. VWO. Dostupné z: <https://vwo.com/ab-testing/>. [cit. 2025-03-25].
- [133] Co je to retargeting a remarketing? A jak funguje? Online. Jakubskrbel. Dostupné z: <https://jakubskrbel.cz/co-je-to-retargeting-a-remarketing-a-jak-funguje/>. [cit. 2025-03-25].
- [134] Sklik produktové inzeráty a Sklik dynamický retargeting. Online. MarketingPPC. 2024. Dostupné z: <https://www.marketingppc.cz/marketing/produktove-inzeraty-sklik-a-dynamicky-retargeting/>. [cit. 2025-03-25].
- [135] Remarketing. Online. Pacinek. Dostupné z: <https://www.pacinek.cz/remarketing/>. [cit. 2025-03-25].