



# **BAKALÁŘSKÁ PRÁCE**

Aplikace multikanálového atribučního modelování v operativním rozhodování

Application of Multi-channel Attribution Modeling in Operational Decision-making

## **STUDIJNÍ PROGRAM**

Ekonomika a management

## **VEDOUCÍ PRÁCE**

Ing. Petr Makovský, Ph.D

DYNTERA

RICHARD

**2023**



# ZADÁNÍ BAKALÁŘSKÉ PRÁCE

## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Dyntera** Jméno: **Richard** Osobní číslo: **492930**  
Fakulta/ústav: **Masarykův ústav vyšších studií**  
Zadávající katedra/ústav: **Institut manažerských studií**  
Studijní program: **Ekonomika a management**

## II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

**Aplikace multikanálového atribučního modelování v operativním rozhodování**

Název bakalářské práce anglicky:

**Application of Multi-channel Attribution Modeling in Operational Decision-making**

Pokyny pro vypracování:

Cílem práce je předložit analýzu internetového prostředí firem v odvětví služeb (E-Commerce), která bude dávat do kontextu (vizualizovat) cesty online zákazníka na e-shopu skrze software. Aplikovaný software zesiluje pravděpodobnost úspěšného dokončení nákupního procesu zákazníkem. Přínosem práce bude empirický materiál pro operativní rozhodování manažera e-shopu. Činnosti v rámci práce musí sledovat analyticko-syntetickou a induktivně-deduktivní metodu. Práce musí mít jasně a srozumitelně definovaný cíl práce, který koresponduje s názvem práce. Cíl musí být splněn na základě potvrzení či odmítnutí stanovených hypotéz. Práce je zpravidla strukturována na teoretickou a na empirickou část. V teoretické části se student zabývá přínosem práce (research gap), rešerší literatury a popisem výzkumných metod. V empirické části předložíme aktuální case study dvou typových firem v E-Commerce, pro které by byla aplikace softwarového nástroje zisková. V emp. části je nezbytné provést kritickou diskuzi závěrů, nastínit další výzkumné otázky, provést shrnutí (conclusion) a vypracovat abstrakt práce (důležitá součást práce, která má laika motivovat se samotnou prací dále zabývat). Je nutné mít práci a její části provázané. Celou práci píšeme v první osobě množného čísla.

Seznam doporučené literatury:

Burešová, J. (2022). Online marketing: Od webových stránek k sociálním sítím. Grada Publishing as.  
Molina, E., Tejada, J., & Weiss, T. (2022). Some game theoretic marketing attribution models. Annals of Operations Research, 318(2), 1043-1075..  
Abhishek, V., Despotakis, S., & Ravi, R. (2017). Multi-channel attribution: The blind spot of online advertising. Available at SSRN 2959778.

Jméno a pracoviště vedoucí(ho) bakalářské práce:

**Ing. Petr Makovský, Ph.D. Masarykův ústav vyšších studií ČVUT v Praze**

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **09.12.2022** Termín odevzdání bakalářské práce: **27.04.2023**

Platnost zadání bakalářské práce: \_\_\_\_\_

Ing. Petr Makovský, Ph.D.  
podpis vedoucí(ho) práce

Ing. Dagmar Skokanová, Ph.D.  
podpis vedoucí(ho) ústavu/katedry

prof. PhDr. Vladimíra Dvořáková, CSc.  
podpis děkana(ky)

## III. PŘEVZETÍ ZADÁNÍ

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

\_\_\_\_\_  
Datum převzetí zadání

\_\_\_\_\_  
Podpis studenta

DYNTERA, Richard. *Aplikace multikanálového atribučního modelování v operativním rozhodování*. Praha: ČVUT 2023. Bakalářská práce. České vysoké učení technické v Praze, Masarykův ústav vyšších studií.



**MASARYKŮV ÚSTAV  
VYŠŠÍCH STUDIÍ  
ČVUT V PRAZE**

## Prohlášení

Prohlašuji, že jsem svou bakalářskou práci vypracoval samostatně. Dále prohlašuji, že jsem všechny použité zdroje správně a úplně citoval a uvádím je v příloženém seznamu použité literatury.

Nemám závažný důvod proti zpřístupňování této závěrečné práce v souladu se zákonem č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) v platném znění.

V Praze dne:  Klikněte nebo klepněte sem a  Podpis:  
 zadejte datum.

## **Poděkování**

Rád bych poděkoval Ing. Petru Makovskému, Ph.D. za cenné připomínky, odborné rady a vstřícný přístup při vedení mé práce. Děkuji také společnosti Roivenu za spolupráci během vypracování praktické části práce a Lucii Pultrové za stylistické a gramatické korekce, které mým textům dodaly na kvalitě a srozumitelnosti.

# Seznam obrázků

Obrázek 1: Schéma jednotlivých nástrojů internetového marketingu podle Krutiše. ....	11
Obrázek 2: Analogie multikanálové marketingové atribuce s fotbalovým mužstvem. ....	17
Obrázek 3: Tradiční (heuristické) atribuční modely. ....	18
Obrázek 4: Matematické vyjádření Shapleyho hodnoty. ....	18
Obrázek 5: Porovnání jednotlivých přístupů multikanálové atribuce s modelovým procentuálním vyjádřením. ....	19
Obrázek 6: Porovnání jednotlivých přístupů k multikanálové atribuci. ....	19
Obrázek 7: Grafické vyjádření modelu Markovových řetězců. ....	20
Obrázek 8: Porovnání Shapleho (modrý sloupeček) a Markovova modelu (žlutý sloupeček) v systému Roivenu 1. ....	20
Obrázek 9: Porovnání vlastností jednotlivých atribučních modelů. ....	21
Obrázek 10: Porovnání jednotlivých atribučních modelů. ....	21
Obrázek 11: Stavební kameny Big Dat vyjádřené v prolínajících se kruzích. ....	23
Obrázek 12: Rozhraní měřící platformy Analytics od společnosti Google. ....	26
Obrázek 13: Proces zákaznické cesty, kde je červeným obdelníkem zvýrazněno, která část pokrývá marketingový a analytický datový set. ....	28
Obrázek 14: URL adresa rozdělená na jednotlivé parametry s vysvětlivkami. ....	30
Obrázek 15: Roivenu for Excel – úplně první verze produktu Roivenu. ....	32
Obrázek 16: Webová aplikace Roivenu v roce 2022. ....	33
Obrázek 17: Webové stránky Roivenu. ....	33
Obrázek 18: Diagram ETL procesu. ....	35
Obrázek 19: Pohled na data v aplikaci Roivenu. ....	36
Obrázek 20: Proces zákaznické cesty, kde je červeným obdelníkem zvýrazněno, kterou část pokrývají data z objednávkového systému. ....	37
Obrázek 21: Komponenta Roivenu – Atribuční analýza. ....	38
Obrázek 22: Komponenta Roivenu – Performance Explorer. ....	39
Obrázek 23: Komponenta Roivenu – Dimension Explorer. ....	40
Obrázek 24: Tabulka v Budget optimizeru s jednotlivými úpravami marketingových investic a jejich předpokládaný růst/pokles rozpadnutý po dimenzi. ....	41
Obrázek 25: Komponenta Roivenu – Budget optimizer. ....	41
Obrázek 26: Pohled na data firmy E-commerce v listopadu a začátek prosince. ....	44
Obrázek 27: Pohled na data firmy E-commerce v prosinci. ....	44
Obrázek 28: Tyto 2 kampaně z Facebooku a Google Ads přináší firmě největší část obrátu. ....	45
Obrázek 29: Pohled na stejné kampaně přes metriku PNO. ....	45
Obrázek 30: Anonymizovaná data firmy E-commerce v Dimension exploreru. ....	46
Obrázek 31: Pohled na data celého roku pro firmu Služby. ....	48

Obrázek 32 Kampaně, které byly vypnuté během 1. vlny.....	49
Obrázek 33: Kampaně, které se podporovali dodatečnými marketingovými investicemi.....	50



# Seznam grafů

Graf 1: Vývoj celkových ročních výdajů v ČR do internetové inzerce (v mld. Kč).....	10
Graf 2: Marketing maturity model od firmy Roivenu. ....	13
Graf 3: Množství vytvořených, získaných, zkopírovaných a konzumovaných dat celosvětově od roku 2010 do roku 2020 s předpovědí na roky 2021-2025 (v zettabytech). ....	22
Graf 4: Rozpad vendorů platforem měřící webovou analytiku. ....	27

# Seznam tabulek

Tabulka 1: Seznam pojmů, zkratk a jejich definic používaných v bakalářské práci. ....	7
Tabulka 2: Rozdíl cesty tradičního zákazníka a digitálního zákazníka. ....	16
Tabulka 3: Pohled na data source/medium v Google Analytics 4. ....	29

# Abstrakt

Bakalářská práce se zabývá využitím multikanálového atribučního modelování marketingových dat při operativním rozhodování. Cílem práce je předložit analýzu internetového prostředí firem v odvětví služeb (E-Commerce), která bude dávat do kontextu (vizualizovat) cesty online zákazníka na e-shopu skrze software. Zvolený aplikovaný software zesiluje pravděpodobnost úspěšného dokončení nákupního procesu zákazníkem. Práce je rozdělena na teoretickou a praktickou část. Teoretická část práce se věnuje online marketingu a jeho reklamním platformám, popisuje stádia zákaznických cest, základy atribuční teorie a seznamuje nás s některými atribučními modely. V neposlední řadě vysvětluje důležitost dat v byznysovém rozhodování. První polovina praktické části nejdříve popisuje firmu a nástroj Roivenu. Druhá polovina praktické části se věnuje případovým studiím dvou firem se zaměřením na český a slovenský trh, které aplikováním atribučního modelování v Roivenu identifikovaly příležitosti, jež vedly ke zlepšení marketingových a byznysových výsledků.

## Klíčová slova

atribuce, atribuční modely, online marketing, data, Roivenu, zákaznické cesty

# Abstract

This bachelor thesis deals with the use of multichannel attribution modelling of marketing data and the application of resulting data in operational decision-making. The aim of the thesis is to present an analysis of the internet environment of companies in the service industry (E-Commerce), which will contextualize (visualize) the online customer journey on an e-shop through software. The selected applied software increases the probability of successful completion of the customer's purchasing process. The thesis is divided into a theoretical and practical part. The theoretical part of the thesis focuses on online marketing and its advertising platforms, describes the stages of customer journeys, the basics of attribution theory, and introduces some attribution models. Lastly, it explains the importance of data in business decision-making. The first half of the practical part first describes the company and the Roivenu software. The second half of the practical part focuses on case studies of two companies targeting the Czech and Slovak markets, which identified opportunities by applying attribution modeling in Roivenu, leading to improved marketing and business results.

## Key words

Attribution, Attribution Models, Online Marketing, Data, Revenue, Customer Journeys

# Obsah

Seznam obrázků.....	7
Seznam grafů.....	9
Seznam tabulek .....	10
Úvod .....	5
<b>1 Základní pojmy – terminologický slovník .....</b>	<b>7</b>
<b>2 Online marketing.....</b>	<b>8</b>
2.1 Hlavní rozdělení online marketingu .....	10
2.2 Nástroje online marketingu.....	11
2.2.1 Nástroje online marketingové komunikace.....	12
2.2.2 Reklama ve vyhledávání.....	12
2.2.3 PPC reklamy .....	12
2.2.4 Srovnávače .....	12
2.2.5 Webové stránky .....	13
2.3 <i>Marketing maturity</i> model.....	13
2.4 Zákaznická cesta .....	15
<b>3 Marketingová atribuce.....</b>	<b>17</b>
3.1 Vývoj marketingové atribuce .....	17
3.1.1 Atribuční modely první generace.....	18
3.1.2 Data-driven atribuční modely .....	18
3.1.3 Data-driven atribuční modely podrobně .....	19
3.1.4 Atribuční modely používající umělou inteligenci.....	21
<b>4 Role dat v marketingovém a podnikovém řízení.....</b>	<b>22</b>
4.1 Big data.....	23
4.1.1 Typy big dat.....	24
4.2 Datová vizualizace .....	25
4.3 Data o zákaznících .....	26
4.3.1 Webová analytika.....	26

4.3.2	Metody měření .....	27
4.3.3	Nedostatky webového měření.....	28
4.3.4	Data z marketingových platforem .....	28
4.3.5	Měření marketingových dat.....	29
<b>5</b>	<b>Roivenu</b> .....	<b>32</b>
5.1	Základní informace .....	32
5.2	Systém Roivenu .....	34
5.2.1	Struktura webové aplikace Roivenu .....	34
5.3	Stahování, zpracování a vizualizace dat .....	34
5.3.1	Kvalita vstupních dat.....	34
5.3.2	ETL – extraction, transform, load.....	34
5.3.3	Typy zdrojů dat v systému Roivenu .....	37
5.3.4	Interní objednávkový systém .....	37
5.4	Komponenty Roivenu .....	38
5.4.1	Attribution analysis .....	38
5.4.2	Performance explorer .....	39
5.4.3	Dimension explorer.....	39
5.4.4	Budget optimizer.....	41
<b>6</b>	<b>Případová studie</b> .....	<b>42</b>
6.1	Metoda případové studie .....	42
6.2	Výzkumné otázky.....	42
6.2.1	První výzkumná otázka.....	42
6.2.2	Druhá výzkumná otázka .....	43
6.3	Případová studie 1 – firma E-commerce .....	43
6.3.1	Současný stav .....	43
6.3.2	Pohled na data .....	44
6.3.3	Optimalizace – testování modelu AI .....	45
6.3.4	Další možné návrhy na zlepšení .....	46
6.3.5	Výsledky .....	47

6.4	Případová studie 2 – firma Služby .....	47
6.4.1	Současný stav .....	47
6.4.2	Pohled na data .....	48
6.4.3	Optimalizace marketingového mixu .....	48
6.4.4	Výsledky .....	50
6.5	Diskuze.....	51
	<b>Závěr .....</b>	<b>53</b>
	<b>Seznam použité literatury .....</b>	<b>54</b>

# Úvod

V současném světě, kde firmy každoročně zvyšují množství investovaných peněz do online marketingu, roste rovněž potřeba utrácet tyto peníze do smysluplných marketingových platforem, které organizacím přináší výsledky. A s rostoucím množstvím platforem, které organizace využívají ve svém marketingovém mixu roste také složitost identifikace kanálů na ty, které doopravdy přináší výsledky, a na ty, které pouze parazitují na úspěchu ostatních platforem. Populární metodou posledních let, jak tyto platformy objevit, je atribuční modelování. Předložená bakalářská práce se zabývá využitím multikanálového atribučního modelování marketingových dat a užívání výsledných dat při operativním rozhodování. Komplexnost tohoto problému a zkušenost autora práce z oboru dala za vznik této práci.

Cílem práce je předložit analýzu internetového prostředí firem v odvětví služeb (E-Commerce), která bude dávat do kontextu (vizualizovat) cesty online zákazníka na e-shopu skrze software, kterým je společnost Roivenu. Přínosem práce bude empirický materiál pro operativní rozhodování manažera e-shopu, který by měl představovat a podněcovat výhody rozhodování se na základě dostupných dat.

Práce je rozdělená na dvě části, a to teoretickou a praktickou. Teoretická část práce se zabývá online marketingem a jeho reklamními platformami, popisuje různá stadia zákaznických cest, základy atribuční teorie a představuje některé atribuční modely. Dále vysvětluje důležitost dat v byznysovém rozhodování. Praktická část se nejdříve zaměřuje na představení firmy Roivenu a nástrojů, které tento software poskytuje. Druhá polovina praktické části se zaměřuje na případové studie dvou firem, které cíleně využily atribuční modelování v Roivenu k identifikaci příležitostí a dosažení lepších marketingových a obchodních výsledků. Na případových si vysvětlíme, jak lze přistupovat k datům ve webové aplikaci Roivenu a snaží se poskytnout rady pro manažery, kteří k dispozici mají jiný marketingový nebo vizualizační nástroj.



# TEORETICKÁ ČÁST

# 1 Základní pojmy – terminologický slovník

Tabulka 1: Seznam pojmů, zkratk a jejich definic používaných v bakalářské práci.

Termín	Vysvětlení
API	Zkratka z anglického <i>Application Programming Interface</i> . Způsob vyměňování informací mezi dvěma systémy (Ofoeda et al. 2019).
B2B / B2C	<i>Business-to-business</i> (B2B) a <i>business-to-customer</i> (B2C) jsou 2 typy marketingových strategií s rozdílným zaměřením. B2B se zaměřuje na budování vztahu mezi firmami, zatímco B2C se zaměřuje přímo na zákazníka (Pick 2021).
<i>Business intelligence</i> (BI)	Informační systém, který manažerům pomáhá s každodenním rozhodováním ve společnosti. BI je velice důležitá složka organizace a dokáže poskytnout výhodu nad konkurencí (Foley a Guillemette 2010).
Data set	Strukturovaný zdroj dat stejného zdroje. Může mít podobu tabulky v databázi.
Displejová reklama	Reklama prezentující obsah - například banner, video, nativní reklama (Korula et al. 2016).
ERP	<i>Enterprise resource planning</i> , druh informačního systému, který mimo jiné umožňuje měření objednávek v organizaci (Klaus et al. 2000).
Hit/event/událost	Jakákoliv interakce, která způsobí poslání informace na servery platformy. Může být způsobená i flashovými nebo javascriptovými událostmi, tzn. že hity/eventy/události nemusí generovat page view (Clifton 2012; Kelsey 2017).
Hodnota konverze	Hodnota žádané akce na webu - například hodnota nákupu na e-shopu (Kelsey 2017).
Imprese	Zobrazení jedné reklamy zákazníky (Roivenuue 2022b).
Konverze	Kýžená akce na webu. Typicky třeba nákup na e-shopu (Roivenuue 2022b).
Kreativa	Dílčí obsah reklamy. Jedna kreativa může být například banner, nebo video (Nichifor et al. 2021).
Lead based konverze	Typ konverze, při které nedochází k transakci. Konverzní hodnota je 0.
Margin return ob marketing investment (mROMI)	Stejně jako ROMI, akorát místo návratnosti investic metrika počítá s maržovými výsledky. Číslo nám tedy říká, kolikanásobek peněz investovaných do marketingu nám přineslo do kasy (Roivenuue 2022b).
Marketingová atribuce nebo také marketingové	Proces ohodnocení a přiřazení hodnoty každému marketingovému touchpointu v rámci celého marketingového mixu. Cílem je spravedlivě přiřadit přínos jednotlivých touchpointů k nákupnímu rozhodnutí zákazníka a zlepšit efektivitu celkového

atribuční modelování	marketingového plánu. Atribučnímu modelování se věnuje celá kapitola 3 (Ghose a Todri-Adamopoulos 2016).
Marketingový mix	Koncept používaný v marketingu, který identifikuje konfiguraci „ingrediencí“ (marketingových kanálů) a vyhovuje zákazníkům dané organizace (Borden 1964).
MSSQL	Druh relační databáze vyvinutý společností Microsoft (Truskowski et al. 2020).
Page view	Jedna ze tří nejdůležitějších analytických metrik. Označuje, kolik stránek navštívili návštěvníci webu (Amin Omidvar et al. 2011).
Podíl nákladů na obratech (PNO)	Jedna z nejdůležitějších e-shopových metrik. Počítá poměr ceny byznysových nákladů vzhledem k obratu (Sawyer 2015).
Relační databáze	Databáze založená na relačním modelu. Jednotlivé tabulky v relační databázi jsou na sebe navázány pomocí primárního klíče (Darwen 2009).
Return on marketing investment (ROMI)	Metrika používaná k změření efektivity marketingu. Vyjádření je v číslech, označuje, kolikanásobek peněz investovaných do marketingu nám to přineslo na obratu kasy (Roivenu 2022b).
SQL	Z anglického <i>Structured Query Language</i> . Jedná se o programovací jazyk, díky kterému se získávají informace z databází (Darwen 2009).

## 2 Online marketing

Podle Burešové (2022) lze marketing 21. století v době internetu a pokročilých technologií dělit do dvou základních skupin:

- tradiční off-line marketing;
- online marketing, který vznikl jako převedení off-line marketingu do světa internetu.

*„Online marketing lze definovat jako cestu, kterou lze dosáhnout marketingových cílů pomocí internetu, díky které jde komunikovat se zákazníky v libovolném rozhodovacím stádiu za použití nových komunikačních kanálů.“* (Burešová 2022, s. 18).

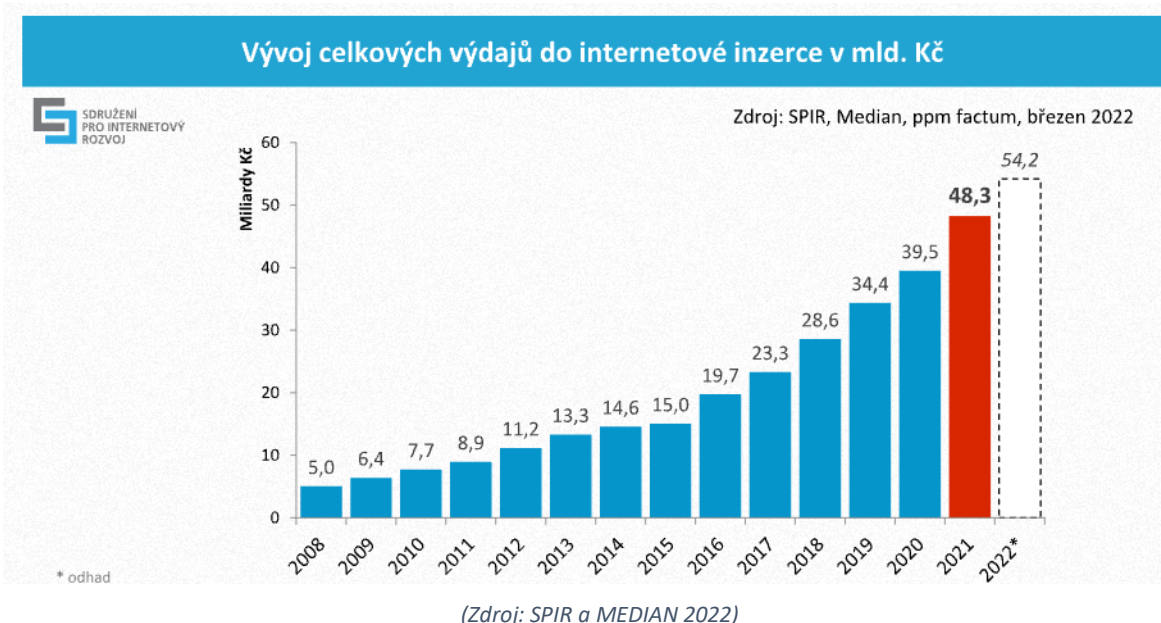
Podle Hanlonové (2021) je online marketing uspokojení zákaznických potřeb za použití digitálních nástrojů a cest. Podle Chaffeyho a Smitha (2017) je digitální marketing o bytí blíž k zákazníkovi, zákazníkovi lepšímu porozumění (v chování, potřebách atp.), rozšiřování jeho počtu pomocí marketingových kampaní na internetu.

Díky faktu, že dnes až 70 % Čechů nakupuje někdy online (v roce 2015 to bylo pouze 32 %; Czech Statistical Office 2022), se zákaznické cesty zkrátily. Zákazník si může pohodlně z domova produkt prohlédnout, zvážit konkurenci a pomocí kurýra nechat produkt doručit přímo domů. Díky internetu se i náročnost vytvoření obchodu značně zjednodušila. Není potřeba založit kamennou pobočku, vést sklad a investovat spoustu peněz do přijímání zaměstnanců. V současné době již většina firem

online marketing do svých marketingových aktivit zahrnula, některé firmy se dokonce pohybují pouze v online světě (Burešová 2022).

Online marketing je často označován pojmy jako marketing na internetu, internetový marketing, digitální marketing nebo e-marketing. Koncem 90. let, kdy byl internetový marketing v počátcích, byly marketingové aktivity omezené kvůli technologickým limitacím. Skoro jedinými používanými kanály byly bannerové reklamy a webové stránky. Jak se časem internet vyvíjel a počet jeho uživatelů zvyšoval, začala jeho důležitost brát na obrátkách a firmy se do marketingu rozhodly

Graf 1: Vývoj celkových ročních výdajů v ČR do internetové inzerce (v mld. Kč).



investovat více a více. Díky tomu se neustále objevují nové nástroje online marketingu, které mohou marketéři využívat.

## 2.1 Hlavní rozdělení online marketingu

Online marketing se dle Kolektivu autorů (2014) dělí na tyto hlavní skupiny:

- **Neplacený marketing** – nejdůležitějším úkolem neplaceného online marketingu je nalezitelnost webu dané společnosti v internetových vyhledávačích;
- **Placený marketing** – pomocí různých internetových tržišť nebo platform si společnosti mohou nakupovat prokliky a imprese s vyhovujícím uživatelským profilem; takovými místy může být například Facebook, Google nebo AdForm;
- **Sociální média** – sociální média jsou v současnosti mezi uživateli velmi populární, jen samotný Facebook má měsíčně 1 miliardu uživatelů, YouTube má stejná čísla, LinkedIn a Twitter oba kolem 200 milionů; díky tomuto růstu mohou zaměstnanci firmy komunikovat jako její zástupci a případně na sociálních sítích také nakupovat prostor pro reklamu.

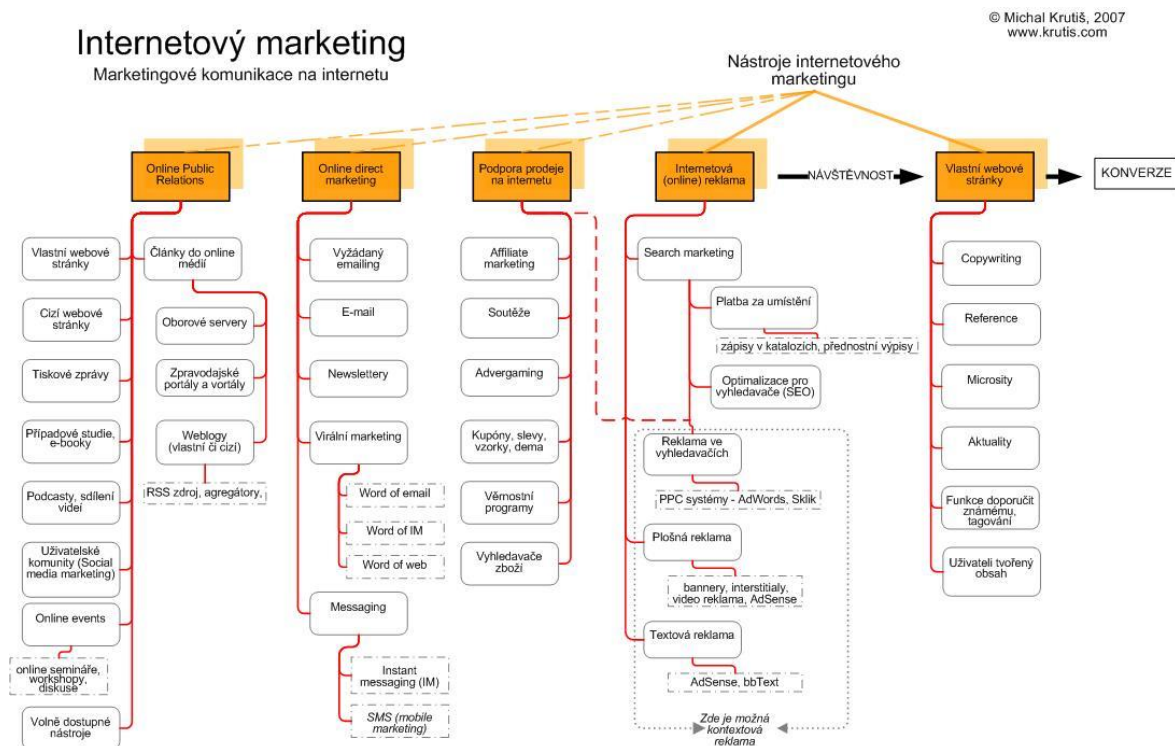
## 2.2 Nástroje online marketingu

Burešová (2022) rozděluje online marketing do několika skupin. Jsou jimi: webové stránky, nástroje online marketingové komunikace (jako třeba podpora prodeje, PR, nebo emailing), reklama ve vyhledávání, PPC reklamy, srovnávače a marketing na sociálních sítích.

Hanlonová (2021) online marketing dělí na emailing, webové stránky, SEO a reklama ve vyhledávání, obsahový marketing, marketing na sociálních sítích, reklama v komunitách, mobilní marketing a reklama v augmentované a virtuální realitě.

Dělení Krutiše (2007) je pak následující: online public relations, online direct marketing, podpora prodeje na internetu, internetová online reklama, vlastní webové stránky. Každý z nástrojů má svoje subkategorie, které jsou jednotlivě vidět na schématu.

Obrázek 1: Schéma jednotlivých nástrojů internetového marketingu podle Krutiše.



(Zdroj: Krutiš 2007)

## 2.2.1 Nástroje online marketingové komunikace

Burešová (2022) rozděluje nástroje na:

- **online podporu prodeje** – má za cíl motivovat zákazníka k rychlejšímu, opakovanějšímu nebo větším nákupům;
- **online public relations** – neslouží k přímému prodeji služeb nebo produktů, ale spíše k budování dobrého jména firmy;
- **online přímý marketing** – oslovuje zákazníky přímo, třeba emailem nebo přes webový chat.

## 2.2.2 Reklama ve vyhledávání

Reklamy ve vyhledávání fungují přes internetové vyhledávače, které jsou nejčastějším způsobem vyhledávání informací na internetu. Jsou schopné třdit a kategorizovat velmi velké množství dat a díky algoritmu doporučovat nejvhodnější výsledky. Reklama spočívá v tom, že si organizace platí, aby se jejich webová stránka ve vyhledávači umísťovala výše (Burešová 2022).

## 2.2.3 PPC reklamy

Koncept PPC (*pay per click*, „platba za proklik“) popularizoval Google začátkem nového tisíciletí. Jedná se o flexibilní, vysoce cílenou reklamu s unikátním modelem platby aukce. Uživatel si může navolit, kolik je maximální prokliková cena dané reklamy a na základě aukce s dalšími firmami se stejným cílovým publikem se draží, komu a jak se reklama zobrazí. Za PPC reklamu platíme pouze když na ni potenciální zákazník klikl (Burešová 2022).

Burešová (2022) placenou reklamu na internetu rozděluje na 3 druhy podle cílů reklamy:

- Informační – má za cíl zákazníkovi pouze komunikovat, že jako inzerent existujeme;
- Přesvědčovací – má za cíl přesvědčit potenciálního zákazníka, aby si produkt zakoupil;
- Připomínací – připomíná se, že produkt/značka existuje a že si zákazník může znovu nakoupit.

PPC reklamy mají také řadu podob. Nejčastějšími podobami jsou reklamy ve vyhledávání, obsahová reklama a video spot.

## 2.2.4 Srovnávače

Podle APEK (2022) je v České republice kolem 51 000 internetových obchodů. Tato vysoká konkurence dává vhodnou půdu pro vznik srovnávačů – webům, které srovnávají zboží konkurence, aby si zákazník mohl vybrat z nejvýhodnějších nabídek na internetu.

Firmy si na těchto webech mohou zaplatit za výhodnější pozici, když si zákazník srovnává zboží, a to pak tedy zvětšuje pravděpodobnost nákupu zboží dané firmy (Burešová 2022).

## 2.2.5 Webové stránky

Webové stránky představují jádro prezentace na internetu a fungují jako vizitka celé firmy. Díky nim je firma dohledatelná ve vyhledávačích. Někdy se jako doplněk ke stávajícímu webu či e-shopu vytvářejí tzv. mikro stránky za účelem efektivnějšího získávání zákazníků pro vybraný produkt nebo službu (Burešová 2022).

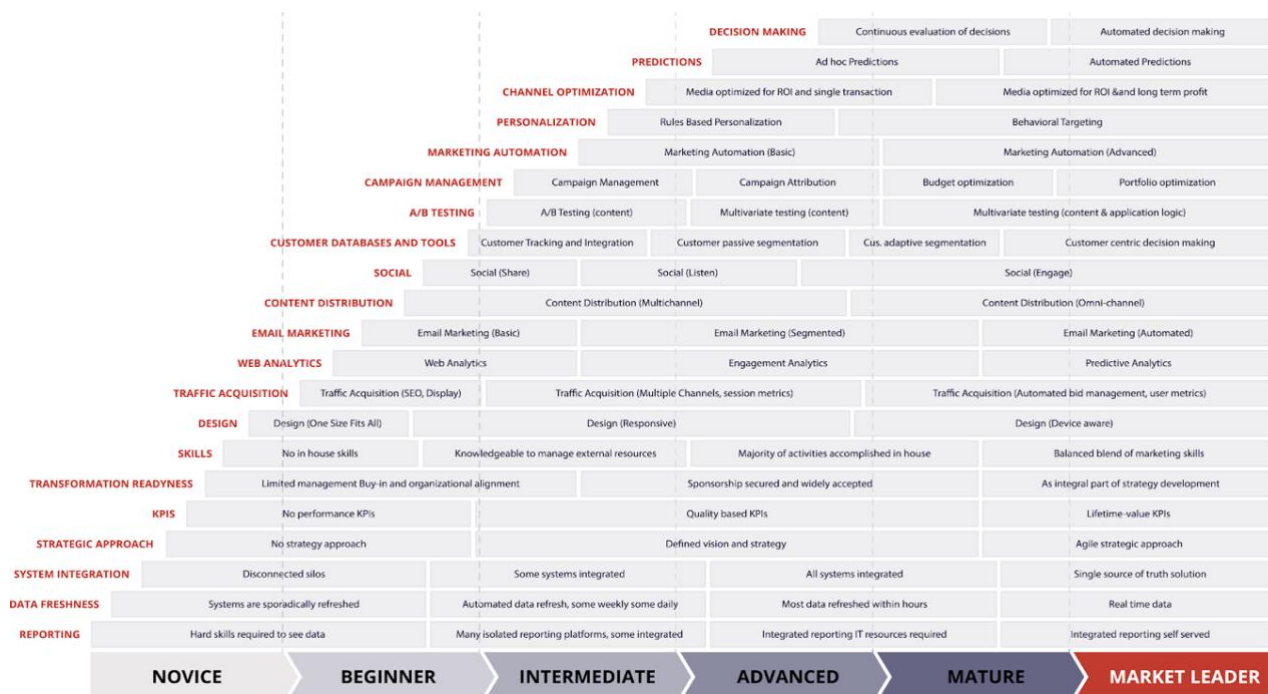
## 2.3 Marketing maturity model

Díky exponenciálnímu růstu internetu a jeho technologií a uživatelů byli marketeři donuceni přistoupit k ucelenějšímu přístupu k online marketingu.

*„Modely marketingové maturity nebo také stádia růstu popisují přístup ideálního růstu marketingu ke kýženému výsledku za použití stádií úspěšnosti v dané velikosti.“ (Bouřim a Barka 2021)*

Implementování modelu marketingové maturity pomůže marketing sledovat v kontextu s velikostí marketingového týmu, pomáhá vést marketing s vizí a nabízí celou řadu podnětů kde a za jakých podmínek se věnovat určitým tématům. Marketingové maturity firma pak dosáhne, pokud uspokojuje byznysové potřeby a zajišťuje strategické uspořádání na každé úrovni stádia.

Graf 2: Marketing maturity model od firmy Roivenu.



(Zdroj: Roivenu 2022c)

Na Grafu 2 vytvořeném firmou Roivenu můžeme vidět stádia vyspělosti marketingového týmu od nováčka (*novice*), přes začátečníka (*beginner*), pokročilého (*intermediate*), vyspělého (*advanced*),



„dospělého“ (*mature*) až po marketingový tým, který udává směr trhu (*market leader*). Na vertikální linii můžeme vidět jednotlivá témata marketingu i s přibližnou dobou startu, kdy se jimi začít zabývat.

Podle Roivenu jsou základními kameny marketingové vyspělosti reporting, integrace dat pod jednu střechu a to, jak často tato data jsme schopni získávat. Tato tři témata jsou nutnou součástí pro rozhodování na základě dat a ne emocí (Boufim a Barka 2021; Roivenu 2022b).

## 2.4 Zákaznická cesta

*Customer journey*, česky „zákaznická cesta“, označuje všechny potenciální okamžiky (nebo kontaktní body) - *touchpointy*, ve kterých je potenciální zákazník vystaven značce nebo se jí zabývá. Všechny tyto interakce jsou navrženy tak, aby nakonec přesvědčily, ovlivnily a převedly zákazníka k tomu, aby se z potenciálního stal zákazníkem skutečným.

Hanlonová (2021) uvádí, že zákaznické cesty mohou být komplikované a nákupní cyklus produktu nebo služby daného obchodu zdlouhavý. Z tohoto důvodu se marketingoví manažeři snaží vytvořit zákaznickou cestu, která je pro zákazníky co nejpříjemnější a neobsahuje žádné takzvané "*friction points*", tedy místa, kde by zákazník mohl mít překážku, která by mu zabránila v dokončení konverze. Zákaznická cesta se může lišit v závislosti na byznysovém modelu organizace, a to buď v případě B2B nebo B2C.

Podle Lemon a Verhoefa (2016) má zákaznická cesta 3 hlavní stádia:

- *Pre-purchase* (česky před-nákupní, před-konverzní) – zákazník se seznamuje se značkou a marketingová komunikace ho připravuje na nákup produktu;
- *Purchase* (konverzní) – nastává po *pre-purchase*, končí nákupem, či nějakou jinou žádanou akcí zákazníka s naší značkou (například přihlášení k odběru newsletteru);
- *Post-purchase* (česky po-nákupní) – cílem po-nákupního stádia je většinou zákazníka přimět znovu nakoupit; *post-purchase* stádium typicky využívá jiné kanály se zákazníkem, například e-mailové komunikaci, nebo zanechání doporučení.

Tabulka 2: Rozdíl cesty tradičního zákazníka a digitálního zákazníka.

Stádium	Typ touchpointu	Tradiční zákazník	Online zákazník
<i>Pre-purchase</i>	Vyhledávání	Nákupní centra, magazíny, billboardové reklamy	Vyhledávání online, vyhledání/doporučení na soc. sítích
	Výběr	Omakání produktu fyzicky v obchodě	Porovnání ceny dopravy, nákladů
	Rozhodování	Rozhodování v obchodě v rámci otevírací doby	Na základě porovnání se rozhoduje, jestli nakoupí hned nebo později
<i>Purchase</i>	Nakupování	Fyzicky navštíví obchod, ve kterém chce nakoupit	Nakupuje přímo přes prodejce nebo přes třetí stranu
	Nákup	Stojí v řadě a čeká, až bude obslužen	Nákup na pár kliknutí, doprava do následujícího dne, doprava na poštu
	Dárek	Další náklady – fyzické nebo peněžní na dopravu domů, balné atp.	Automatická možnost objednat z jedné adresy a darovat na druhou
	Pronájem	Fyzicky navštíví obchod, aby podepsal nájemní smlouvu	Pronajímá filmy, muziku a další na pár kliknutí myši


(Zdroj: Lemon a Verhoef 2016)

## 3 Marketingová atribuce

V kolektivních sportech trenéři týmů nespolehají pouze na jednoho hráče k výhře nad protivnickým týmem. Cílem každého správného trenéra je vytvořit tým z hráčů, kteří společně dokážou skórovat a vyhrát nejvíce zápasů. Někteří hráči v týmu jsou dobří pro rozehrání hry a jiní hráči zase naopak umějí dávat góly.

Stejně tak v marketingu marketingoví ředitelé nespolehají, že jeden marketingový kanál přinese veškerý zisk marketingových kampaní. Potřebují marketingovou strategii, která je schopná zákazníka nejdříve seznámit se značkou a jejími výhodami, ale také ho dovést k úspěšnému nákupu. Pro správné sestavení týmu je potřeba ale umět ohodnotit důležitost daného hráče na hřišti (Kakalejčík et al. 2018).

Obrázek 2: Analogie multikanálové marketingové atribuce s fotbalovým mužstvem.



(Zdroj: Roivenu 2022b)

### 3.1 Vývoj marketingové atribuce

V dobách, kdy internet nebyl tak technologicky vyspělý a populární, roli v určování hodnoty atribuce hrály ekonometrické modely. Díky technologiím, které teď marketingoví manažeři mohou využívat, se situace ale změnila. S rozšířením webových stránek a tzv. *cookies* jsou manažeři schopni měřit jednotlivé interakce uživatelů s webem, měřit délku zákaznické cesty a její jednotlivé marketingové kanály. Toto dalo za vznik moderním modelům marketingové atribuce (Romero Leguina et al. 2020).

Podle Romera a ostatních (2020) se dají rozdělit atribuční modely na dva druhy:

- Atribuční modely první generace;
- Data-driven atribuční modely.


### 3.1.1 Atribuční modely první generace

Romero Leguina et al. (2020) ve své práci píše, že ačkoliv jsou atribuční modely první generace principiálně jednoduché a zvýhodňují některé kanály více než jiné, jsou momentálně nejvíce používané mezi marketéry.

Na základě znalosti jednotlivých kliků, které uživatel udělal, tyto atribuční modely přidělí hodnotu atribuce jedné z interakcí nebo ji heuristicky rozdělí poměrně mezi ně. Nejčastěji používaný je tzv. model poslední interakce - „*last click*“ nebo také „*last touch*“. Už jak jméno implikuje, tento atribuční model přidělí celou hodnotu konverze poslednímu kanálu v interakci. Dalšími modely první generace jsou:

- **First click/ First touch** – všechna hodnota konverze se přičte první interakci v daném řetězci;
- **Lineární** – každá interakce v cestě přispěla ke konverzi stejně;
- **Time decay** – hodnota konverze, která se přidělí interakci stoupá s časem, který se blíží ke konverzi;
- **Position based** – 40 % hodnoty konverze se připočte k první a poslední interakci v cestě, zbytek se rovnoměrně přidělí všem zbylým interakcím v cestě.

Obrázek 3: Tradiční (heuristické) atribuční modely s vyznačenými šedými sloupci, kam se hodnota konverze přičítá.



(Zdroj: Romero Leguina et al. 2020)

### 3.1.2 Data-driven atribuční modely

Vznik *data-driven* atribučních modelů byl podnícen problémy tradičních modelů první generace. Jsou založené na základě statistických vzorců.

Obrázek 4: Matematické vyjádření Shapleyho hodnoty.

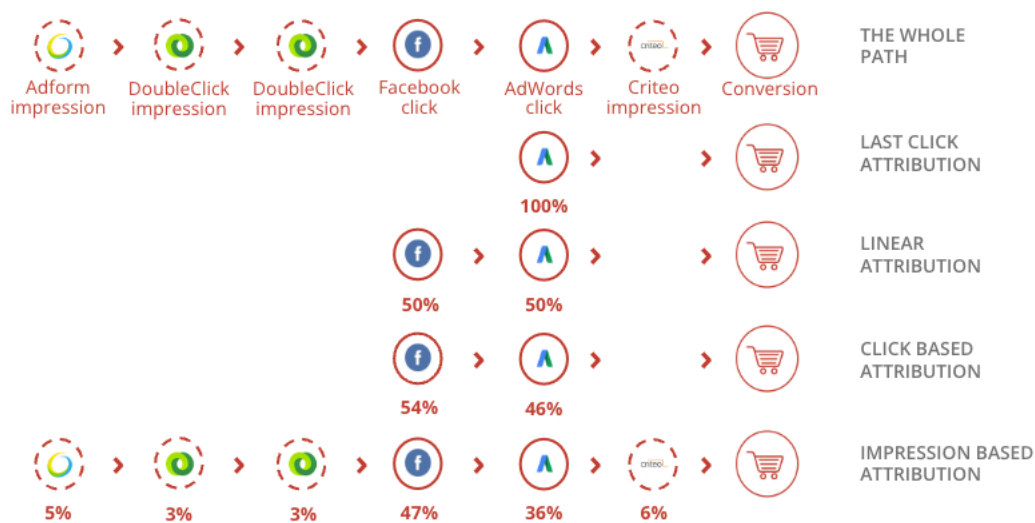
$$\phi_i(v) = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (n - |S| - 1)!}{n!} (v(S \cup \{i\}) - v(S))$$

(Zdroj: Roivenu 2022b)

Pokud modelům poskytneme historická marketingová data, bude model schopný předpovědět pravděpodobnost hodnoty konverze, a tedy interakci správněji hodnotit. Výhody *data-driven* přístupu oproti tradičnímu jsou:

1. **Parametrizace** – do jednotlivých proměnných statistického modelu lze poskytnout více informací o zákaznících a cestách, model je tedy přesnější a spočítaný na datech pro každou firmu zvlášť;
2. **Konverzní vs. nekonverzní cesty** – modely první generace braly v potaz jen konverzní cesty, kterých je přibližně pouze 1 %, to znamená, že 99 % dat se nepoužívalo; statistické modely používají všechna data, které má marketingový manažer k dispozici;
3. **Data-driven přístup** – atribuce jednotlivých interakcí je na základě dat; tradiční atribuční modely určují hodnotu interakce na základě pozice v cestě zákazníka (Romero Leguina et al. 2020).

Obrázek 5: Porovnání jednotlivých přístupů multikanálové atribuce s modelovým procentuálním vyjádřením



(Zdroj: Roivenu 2022b)

### 3.1.3 Data-driven atribuční modely podrobně


Podle Kakalejčika, Bucka a Resendeho (2018) je momentálně nejspravedlivější statistický model používající Markovovy řetězce. Ve své práci ale zmiňují i používání Shapleho hodnot. Romero a ostatní (2020) zase píšou o Shapleyho modelu jako nejspravedlivějším modelem. Roivenu ve své první verzi produktu marketingovým manažerům nabízela pohled na jejich data přes oba atribuční modely.

**Shapleyho model** je statistický model původně používaný v teorii her. Funguje na bázi rozdělení aktérů do koalic, ze kterých pak dokáže spočítat mezní přidanou hodnotu každého aktéra v koalici. Podle Romera et al. (2020) má používání Shapleyho hodnoty dva velké problémy. První spočívá v tom, že počet koalic a aktérů exponenciálně zvyšuje nutný počet operací pro spočítání Shapleyho hodnoty. Druhý je, že nejsme schopni určit, jak přesný model Shapleyho hodnoty ve skutečnosti je. Roivenu (při používání Shapleyho v marketingové atribuci) ještě dodává třetí nedostatek, a to že model hodnoty nebere v kalkulacích potaz pozici interakce v cestě. Shapleyho hodnota může tedy

doporučovat kanál útočníka v první pozici v cestě a opačně (Abhishek et al. 2017; Romero Leguina et al. 2020; Kakalejčík et al. 2018; Roivenu 2022b).

**Model Markovova řetězce**, pojmenovaný po ruském matematikovi Andrey Markovovi, hodnotí atribuci na základě znalosti historických dat cest zákazníka. Markovovy řetězce kalkulují, zda by následující interakce s nějakým kanálem v cestě zvýšila, nebo snížila procentuální pravděpodobnost konverze. Tyto řetězce se nejdříve používaly například při předpovídání počasí, od roku 1964 se ale užívají i při atribučním modelování, kdy matematici George Styan a Harry Smith Jr. ve své práci „Markov chains applied to marketing“ popsali Markovovu strukturu grafů jako podobnou zákaznické cestě (Bhatta 2022).


Obrázek 7: Grafické vyjádření modelu Markovových řetězců.



(Zdroj: Roivenu 2022b)

Pokud model kalkuluje jen s přímo následující interakcí v cestě, nazýváme ho Markovův řetězec prvního řádu, pokud s přímo následující a další interakcí v řadě, nazýváme ho Markovův řetězec druhého řádu atp. Kakalejčík, Buck a Resende (2018) píšou, že neoptimálnější pohled na data je přes Markovův řetězec třetího řádu (Bhatta 2022; Kakalejčík et al. 2018).

Obrázek 8: Porovnání Shapleho (modrý sloupeček) a Markovova modelu (žlutý sloupeček) v systému Roivenu 1.



(Zdroj: Roivenu 2022b)

### 3.1.4 Atribuční modely používající umělou inteligenci

Nedostatky statistických atribučních modelů a neustálý technologický vývoj umělé inteligence v posledních letech se propal i do způsobů, jak vyhodnocovat marketing. Roivenu jako lídr v pokročilých marketingových technologiích v říjnu 2020 oznámilo na svém blogu uvedení nového AI atribučního modelu používající machine learningové rekurentní neuronové sítě (*RNN networks*). Tento model na základě více než 20 parametrů předpovídá pravděpodobnost konverze na úrovni každého  $\alpha$ . Model také na základě opakovaného učení dokáže rozeznat sezonalitu byznysu nebo zákaznické chování (Sacco 2020).

Obrázek 9: Porovnání vlastností jednotlivých atribučních modelů.

	Last-touch	1st generation statistical models	ROIENUE RNN
Evaluation of channels based on real performance	✗	✓	✓
Daily updated	✓	✗	✓
DDA to multiple dimensions at once	✗	✗	✓
Learning and adjusting exactly for the user needs	✗	✗	✓
No minimum limit on number of orders	✓	✗	✓
Performing well in revealing parasitic channels	✗	Partly	✓
Attribution computation level of granularity	N/A	Channel level	Touchpoint level

(Zdroj: Roivenu 2022c)




## 4 Role dat v marketingovém a podnikovém řízení

„Je jasné, že data se stávají klíčovým zdrojem, základem pro úspěch každé společnosti. Tím, jak se svět stává chytřejší a chytřejší, počet a schopnost uplatnit data se stávají výhodou nad konkurencí. Úspěch na trhu bude do budoucna definovaný tím, jak společnost dokáže uplatnit data, její analytiku a implementovat nové technologie.“ (Marr 2021, s. 11)

Podle IDC a Statisty (2022) množství dat vyprodukovaného v roce 2021 je 79 zettabytů – to je 10x více než před deseti lety. A odhadované množství dat v roce 2025 činí přes 180 zettabytů.

Podle online dotazníku od Kapeho pořádaného firmou Sifenity (Kape 2016) 87 % respondentů přiznalo pozitivní vliv integrace dat ze systémů na množství konverzí a 70 % respondentů přiznalo pozitivní vliv na efektivitu marketingové komunikace.

Graf 3: Množství vytvořených, získaných, zkopírovaných a konzumovaných dat celosvětově od roku 2010 do roku 2020 s předpovědí na roky 2021-2025 (v zettabytech).



(Zdroj: IDC a Statista 2022)

Data jsou nová ropa, žijeme v době datové. Google zná naši internetovou historii, Facebook ví, s kým se přátelíme. Stejně tak manažeři jsou schopni díky datům o jejich byznysu, zákaznících a trhu dělat informovaná rozhodnutí, která jim pomáhají vydělávat peníze. Potřeba pracovat s velkým množstvím dat roste každým rokem čím dál více. Data ale sama o sobě neodhalí chyby

v rozhodovacích vzorcích. To až jejich následné očištění, filtrace a vizualizace mění ona data v ropu (Marr 2021).

*„Rozhodování musí být řízeno daty. Zvyšování kvality reportingu a implementace analytických nástrojů nutí celou organizaci se řídit jediným zdrojem pravdy.“* (Asplen-Taylor 2022, s. 151)

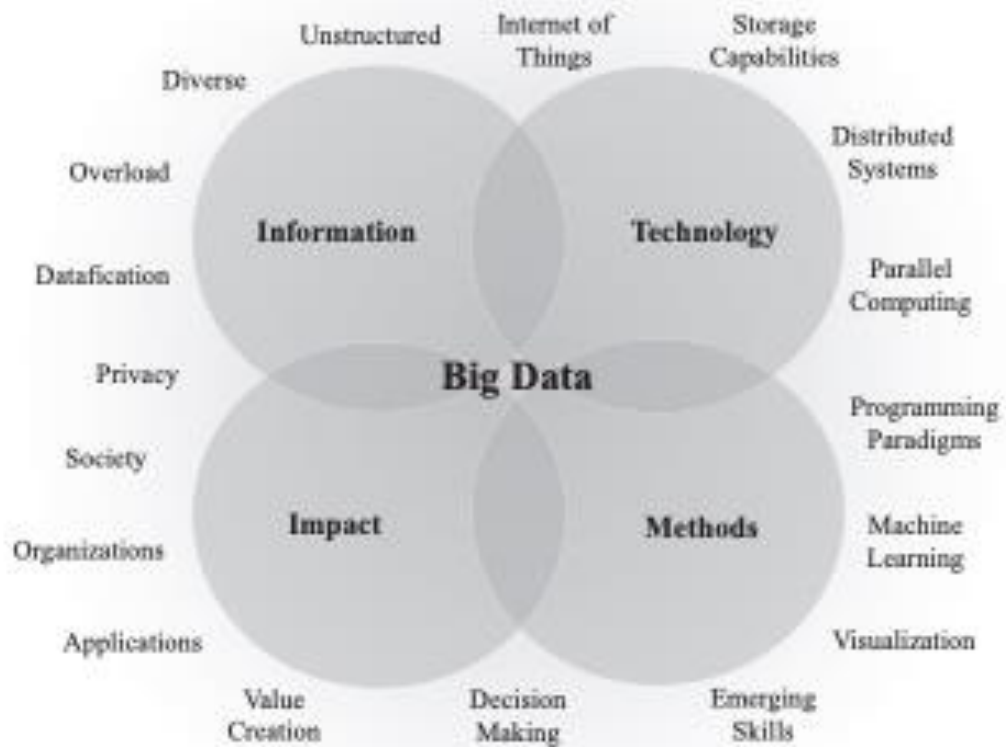
## 4.1 Big data

*„Základní idea za termínem ‚big data‘ je, že všechno, co děláme na internetu, zanechává stopu a my (anebo ostatní) tuto stopu můžeme analyzovat, abychom se stali chytřejšími.“* (Marr 2015, s. 58)

Dle De Maureové, Greca a Grimaldiho (2016) i Marra (2015) charakterizuje big data více elementů. Podle nich jsou aspekty big dat:

- „3 V“ z anglického *volume*, *velocity* a *variety*, tedy objem, rychlost a druh popisující charakteristiku dat;
- Technologie a analytické metody popisující způsob, jak z big dat získat, co nejvíce informací;
- Hodnota popisující výslednou ekonomickou hodnotu přenesení big dat z pohledů na data do byznysových změn.

Obrázek 11: Stavební kameny Big Dat vyjádřené v prolínajících se kruzích.



(Zdroj: De Mauro et al. 2016)

### 4.1.1 Typy big dat

Jsou různé standardy jak řadit různé typy dat. Anghelová, Novacescuová a Cucová (2022) se společně s Marrem (2015) shodují na rozdělení na strukturovaná data, částečně strukturovaná data a nestrukturovaná data. Marr to ještě doplňuje o rozdělení na interní, externí a nová data.

**Strukturovaná data** momentálně poskytují manažerům nejvíce pohledů na data. Nejčastěji mají formu tabulek nebo databází, díky struktuře dokážou poskytnout vztahy mezi jednotlivými sloupečky. Příkladem strukturovaných dat mohou být například:

- Data o financích
- Data o zákaznících

Strukturovaná data se ukládají často v relačních databázích. Datoví inženýři je pak z nich získávají pomocí SQL dotazů pro následnou práci ve vizualizačních softwarech jako třeba PowerBI nebo Google Data Studio (Marr 2015; Anghel et al. 2022).

**Nestrukturovaná** spolu s částečně strukturovanými daty jsou takové, které nejde jednoduše popsat v tabulkách s názvy sloupečků a řádků. Podle Marra (2015) ale až 80 % byznysově relevantních podnětů pochází z těchto dvou typů dat. Typicky obsahují spoustu textu nebo například obrázky, proto s nimi není jednoduché pracovat v tradičních programech. Příklady těchto dat mohou být:

- Webové stránky
- Prezentace
- Videá
- PDF soubory

**Částečně strukturovaná** jsou na pomezí těchto dvou typů, kdy se s nimi částečně dá pracovat jako v strukturovaných datech, ale chybí jim pravidelná kostra, a proto je nemůžeme řadit do strukturovaných (Marr 2015; Anghel et al. 2022).

**Interní data** jsou jakákoliv data, ke kterým má jedna společnost přístup ale ostatní ne. Typicky se jedná o jakýkoliv interní dokument.

**Externí data** jsou naopak všechna data z externích zdrojů, ke kterým má přístup úplně každý. Například data:

- O počasí
- Publikovaná na sociálních sítích
- Anebo ze statistických úřadů

Marr (2015) popisuje i nové druhy dat. Například:

- Senzorová data
- Foto/video data
- Data o konverzacích

*„Je důležité pochopit, že jeden typ dat není lepší nebo cennější než ten druhý. Důležité je na základě strategie sestavit takový set dat z různých typů, který dokáže odpovědět na všechny strategické otázky.“* (Marr 2015, s. 63)

## 4.2 Datová vizualizace

Sbírání a procesování big dat je smysluplné, pouze pokud cílová skupina dokáže samotným datům porozumět. Vizualizace dávají datům smysl a pomáhají si je dát do kontextu. Podle Marra (2015) jsou dva způsoby reportingu výsledků:

- Tabulky a kontingenční tabulky doplněné o grafy s vizualizacemi
- Pouze číselná interpretace dat s doprovodným komentářem vysvětlující výsledky

Nejběžnější vizualizace dat mají tyto typy grafů:

- Sloupcový graf – nejčastěji se používá ke komparaci dvou hodnot mezi sebou;
- Spojnicový graf – používá se třeba pro vizualizaci vývoje metriky a dimenze v čase;
- Koláčový graf – zobrazuje data jako části koláče. Každá část koláče reprezentuje procentuální vyjádření metriky a dimenze;
- Korelační graf – zobrazuje pomocí data pointů korelaci mezi dvěma metrikami.

Analytika dat je proces sbírání, procesování a reportování dat k porozumění způsobům, jakým děláme byznys. Ve většině případů se jedná o automatizovaný proces, ale některé malé firmy musí data sbírat a integrovat manuálně. Kvůli takové náročnosti je proto reporting dat často podceňován a přistupuje se k němu s nižší prioritou.

Od 70. a 80. let, kdy se byznysová analytika začala s technologickým vývojem výpočetních technologií poprvé používat, uběhla už řada let. Tehdy byly analýzy dat technologicky náročné, data musela být uložena v relačních databázích a firma potřebovala analytika, aby prováděl SQL dotazy do databáze k další práci s nimi.

Stejně jako u big dat byl rozvoj možností byznysové analytiky spojen s technologickými úspěchy posledních let. Cena úložišť dat šla rapidně dolů a možnosti procesování dat se zase zefektivnily a zvýšily.

## 4.3 Data o zákaznících

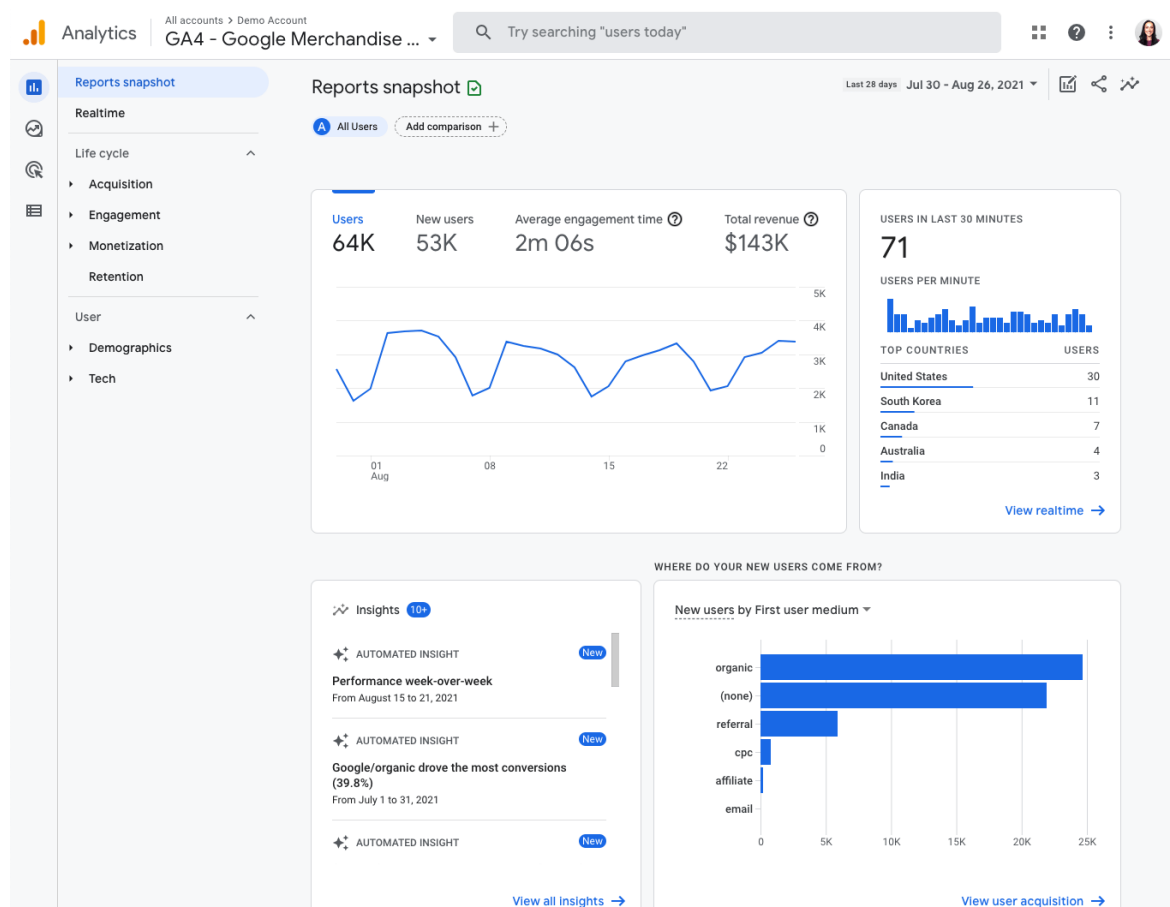
### 4.3.1 Webová analytika

Podle Pakkaly, Pressera a Christensena (2012) webová analytika jsou data popisující množství lidí na webu, webové konverze, výkon webu nebo jakákoliv jiná data, která pomůžou s mapováním prožitku zákazníka. Díky různým měřicím technikám a platformám firmy dokážou na webu zjistit spoustu informací o potenciálních zákaznících nebo trendech. Nejpoužívanější analytická platforma – Google Analytics například měří:

- Zvyšující se nebo snižující se objem návštěv
- Nejčastější zdroje návštěv (přes vyhledávač, PPC reklamu nebo přímým zadáním URL adresy)
- Zvyšující se nebo snižující se objem *page views*
- Nejčastější klíčová slova
- Nejčastěji navštěvované stránky
- a mnoho dalšího...

Pomocí analýzy těchto metrik jsme schopni pochopit, co zákazníci chtějí, pochopit, proč se na web vrací, a případně co jim brání k provedení nákupu (Janouch 2020).

Obrázek 12: Rozhraní měřicí platformy Analytics od společnosti Google.



(Zdroj: Nguyen 2020)

### 4.3.2 Metody měření

Podle Pakkaly, Pressera a Christensena (2012) jsou dva způsoby měření webové analytiky:

- *Page tagging* – měření pomocí tzv. aktivního souboru
- Používání serverových záznamů o pohybu uživatelů


Nejčastější metodou je měření pomocí tzv. aktivního souboru. Dvěma největšími výhodami oproti používání serverových záznamů jsou:

- *Page tagging* je často kompletně zdarma;
- Metoda serverových záznamů se liší na základě každé webové stránky. Neexistuje pro ně žádná platforma nebo program pro jejich analýzu jako celek. Analýza serverových záznamů by tedy trvala spoustu času, lidského času a nebyla by efektivní.

*Page tagging* měření funguje na základě hitování *javascriptového* kódu (označován také jako *tracker* nebo měřící *pixel/script*), který se vloží do hlavičky zdrojového kódu stránky firmy. Zákazník při návštěvě webu stáhnutím obsahu stránky zaktivuje *javascriptový* kód. Ten posbírá informace o návštěvě a jejím uživateli a pošle je na servery dané měřící platformy (Pakkala et al. 2012).

Podle reportu Datanyze (2022) měří pomocí softwarů od platformy Google až 70 % všech stránek. Skoro 6 % firem měří data pomocí analytických služeb od firmy Meta (Facebook Analytics) a zbylých 24 % používá další nebo jiné způsoby webové analytiky.

Graf 4: Rozpad vendorů platforem měřící webovou analytiku.



(Zdroj: Datanyze 2022)

### 4.3.3 Nedostatky webového měření

Sběr dat pomocí aktivního souboru je ale závislý na spoustě faktorů, zejména na takzvaných *cookies* nebo webových rozšířeních blokujících měření.

*„Cookies jsou malé textové soubory, které webový server přenese do webového prohlížeče k tomu, aby dokázal měřit webovou analytiku daného uživatele.“ (Clifton 2012)*

Pokud uživatel zamítne používání cookies na dané stránce nebo má uživatel v nastavení, že nechce na webových stránkách používat Javascript, měřicí kód se vůbec nespustí, a tedy nic neměří. Některé *Ad Blockery* (služby potlačující zobrazení reklam na webech) hity do platforem také blokují. Rovněž se může stát, že se během měření něco stane a hit se ani nestihne odeslat. Safari, webový prohlížeč od firmy Apple, zase defaultně cookies po určitém čase maže. To způsobí, že zákazník bude měřicím pixelem zaznamenaný jako nový zákazník, i když u firmy už několikrát nakupoval nebo její web už navštívil.

Proto se uvádí, že měřicí platformy (ale zejména Google Analytics) v Česku reportují oproti realitě v průměru až o 10 % nižší čísla. Tento průměr se ale web od webu bude lišit. Proto přehledy vykázané měřicími platformami nelze brát jako zdroj pravdy. K datům a jejím přehledům je potřeba přistupovat s rezervou a sledovat spíše trendy (například rostou tržby nebo klesají) než absolutní hodnoty.

Měřicí platformy také mají neměnná data. Jakmile se data odešlou na server a zpracují, už je nelze žádným způsobem ovlivnit či transformovat. Proto je důležité dbát na kvalitu implementace měřicích kódů, abychom byznysové rozhodnutí dělali na základě správných dat.

Některé měřicí platformy (například Google Analytics) mají i objemové limity. Na ty ale většinou naráží firmy s obrovským množstvím návštěv na webu (Roivenu 2022b).

### 4.3.4 Data z marketingových platforem

Nákladová data z marketingových platforem obsahují pro marketingové manažery neméně důležitou složku jejich online marketingu. Paradoxně je ale vůbec pro přesné spočítání hodnoty atribuce není třeba poskytovat. V systému Roivenu jsou však důležitá, protože dokážou poskytnout celý pohled na zákaznickou cestu od imprese až po objednávku a dát celou zákaznickou cestu do kontextu.

Existuje také možnost využít impresí z marketingových dat jako dalšími z parametrů atribučního modelování. Takové metodě počítání atribuce Roivenu říká impresní atribuce; je technologicky náročnější a dražší na implementaci, ale může vnést nový vhled do chování zákazníka.

*Obrázek 13: Proces zákaznické cesty, kde je červeným obdelníkem zvýrazněno, která část pokrývá marketingový a analytický datový set.*



(Zdroj: Roivenu 2022a)

Pokud marketéři využívají impresní atribuce v systému Roivenu, mohou výsledky hodnot atribuce analyzovat na základě toho, že zákazník pouze spatřil danou reklamu. Ve výsledcích atribuce to může způsobit velký rozdíl, jelikož normální kliková atribuce hodnotí, jestli by rozdíl v kliku na danou reklamu zvýšil pravděpodobnost konverze v cestě zákazníka.

Roivenu nedoporučuje se impresní atribucí zabývat, pokud firma nemá více než 30 % marketingových nákladů v displejových reklamách (Roivenu 2022b).

### 4.3.5 Měření marketingových dat

Ačkoliv marketingová data lze měřit pomocí různých trackerů nebo pixelů (podobně jako u webové analytiky), nejdůležitější informace z marketingových platform většinou bývá pouze to, z jakého zdroje se uživatel na webovou stránku dostal. Měření tohoto zdroje marketingoví manažeři provádějí přes tzv. UTM parametry.

UTM, z anglického *Urchin Tracking Module*, jsou textové parametry, které se vkládají do URL při načítání stránek.

Jednotlivé parametry se vkládají do proklikového URL každé z reklam v marketingových platformách. Analytická platforma – například Google Analytics – pak z URL rozpozná, z jakého zdroje se na stránku uživatel dostal. Díky tomuto pohledu můžeme jednoduše ohodnotit výkonost placených kampaní, které firma vede.

Tabulka 3: Pohled na data source/medium v Google Analytics 4.

Session source/medium	↓ Users	Sessions	Engaged sessions	Average engagement time per session	Engaged sessions per user
	2,144 100% of total	4,701 100% of total	2,632 100% of total	1m 50s Avg 0%	1.23 Avg 0%
1 google / cpc	979	1,400	871	0m 45s	0.89
2 (direct) / (none)	507	1,402	780	2m 17s	1.54
3 (not set)	266	327	5	1m 58s	0.02
4 google / organic	235	551	341	2m 04s	1.45
5 youtube.com / referral	89	135	101	0m 32s	1.13
6 capterra / paid	60	70	48	0m 29s	0.80

(Zdroj: vlastní)

Nejčastěji používané UTM parametry jsou:

- **Campaign** – sbírá, v jaké z kampaní se prokliková kreativa nacházela
- **Medium** – jakým způsobem se kampaň nakupovala (přímo, placená reklama, organicky, ...)
- **A source** – z jakého zdroje se uživatel na web dostal (zadání přímo do URL řádku, Google, Facebook, ...)

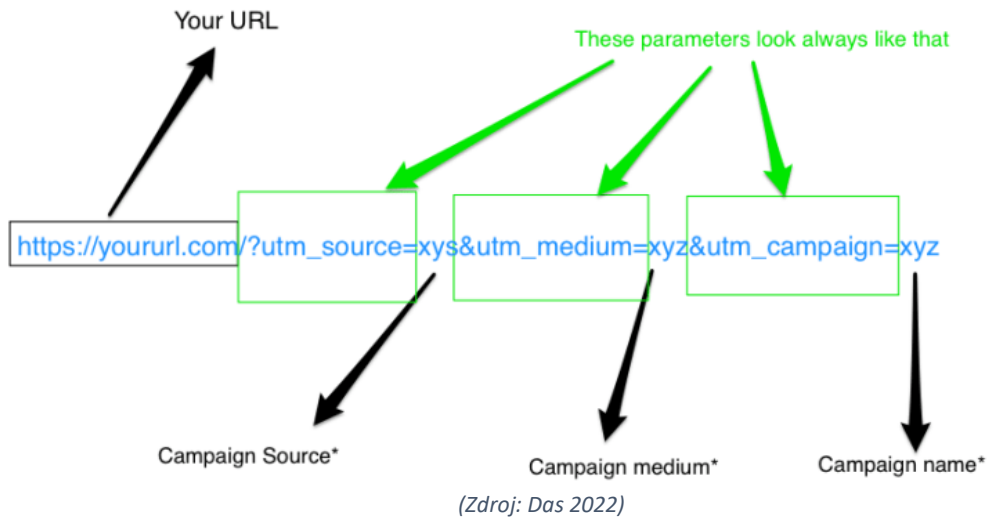
Existují ale i další, méně používané parametry, které poskytují větší granularitu marketingových dat:

- **Content** – velmi granulózní parametr, slouží na porovnání jednotlivých *call-to-actions* v reklamách nebo kreativách



- **Term** – jakými placenými klíčovými slovy se dostal na stránku (funguje pouze pro kampaně ve vyhledávačích)

Obrázek 14: URL adresa rozdělená na jednotlivé parametry s vysvětlivkami.



Na obrázku 14 vidíme modelový příklad. Uživatel vidí displejovou reklamu pro stránku `yoururl.com`. Tato reklama se mu zobrazuje skrze platformu `XYZ`. V platformě se jmenuje kampaň „`XYZ`“ a její medium je „`XYZ`“.

Měřicí platformy takto dokážou z URL určit, která kampaň, platforma i médium má zásluhu za získanou návštěvu (Burešová 2022).


# **PRAKTICKÁ ČÁST**

# 5 Roivenu

## 5.1 Základní informace

Společnost ROIVENU s.r.o. se sídlem v Praze založená 29. 1. 2018 se věnuje analýze marketingových dat a následným doporučením na základě vlastního modelu marketingové atribuce (Kurzy.cz 2023). Myšlenka na nástroj, který by pomáhal marketérům s optimalizací marketingu, vznikla už v roce 2013. V roce 2014 to dokonce dalo za vznik úplně první, nulté verzi Roivenu – v excelové tabulce (Roivenu 2022b).

Obrázek 15: Roivenu for Excel – úplně první verze produktu Roivenu.

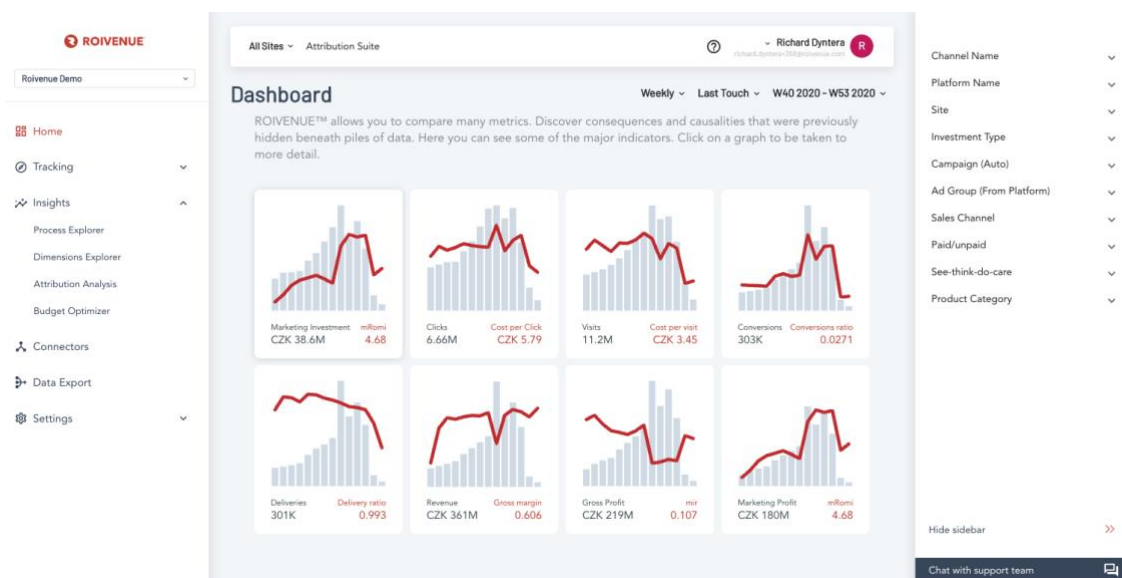


(Zdroj: Roivenu 2022b)

Situace v roce 2022 je zcela jiná. Z excelového produktu Roivenu, který se tehdy používal spíše jako konzultační nástroj, se stala webová aplikace, která momentálně pomáhá marketérům z více než 14 zemí po celém světě relokovat a optimalizovat přes 100 milionů euro marketingových investic (Roivenu 2022c).

Roivenu poskytuje software jako službu (*software as a service, SaaS*), tzn. že klienti platí služby Roivenu měsíčně, na základě míry využití softwaru.

Obrázek 16: Webová aplikace Roivenu v roce 2022.



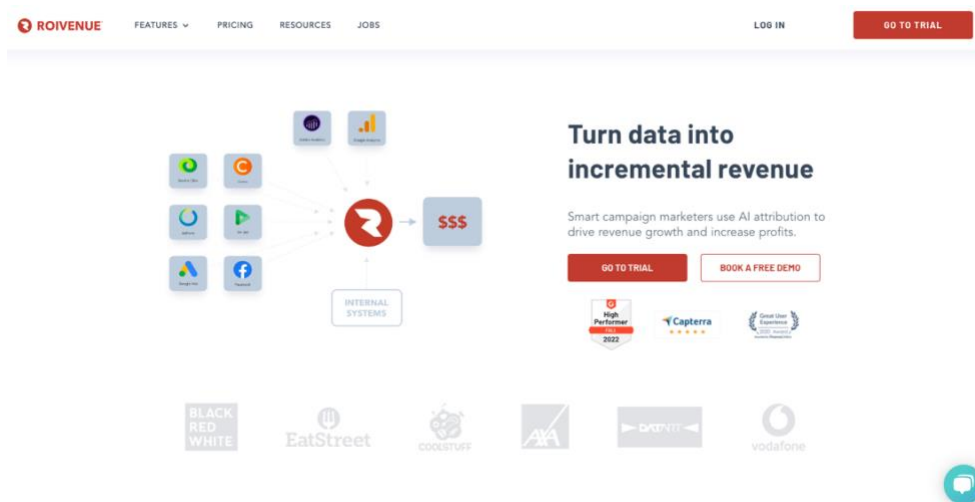
(Zdroj: Roivenu 2022a)

Na ceníkových stránkách Roivenu nabízí momentálně 2 produkty – *Connectors* a *Attribution*.

- *Connectors* má 3 cenové plány. Nejnižší verzi „Free“ zdarma, „Pipelines“ za 190 euro měsíčně a nejdražší verze se jmenuje „Power house“ a stojí 400 euro měsíčně.
- *Attribution* má 2 cenové plány. Nejlevnější plán „Professional“ za 100 euro měsíčně, „Team“ za 359 euro měsíčně a nabízí také kompletní řešení na míru „Enterprise“, kdy zaměstnanec Roivenu nakonfiguruje systém na klíč podle potřeb a problémů daného zákazníka.

Ceny obou plánů se liší podle frekvence platby – cena je vyšší, pokud se platí každý měsíc a nižší, pokud firma využívá aplikaci s ročním závazkem. Roivenu pomáhá například firmám jako je elektro specialista Datart, pojišťovna AXA nebo mobilní operátor Vodafone (Roivenu 2022c).

Obrázek 17: Webové stránky Roivenu.



(Zdroj: Roivenu 2022c)

## 5.2 Systém Roivenu

### 5.2.1 Struktura webové aplikace Roivenu

Roivenu je webová aplikace. Přihlášení do aplikace se provádí přes URL adresu `oauth.roivenu.com`. Generování přihlašovacích údajů buď provádí zaměstnanec Roivenu, nebo je možné si založit svůj vlastní účet na 14 dní v trial režimu. Po 14 dnech ale není možné dále pokračovat v používání aplikace a je třeba zakoupit si licenci na systém odpovídající ceníku Roivenu. Pro tento způsob je také nutné vlastnit účet, který má přístup k platformě Google Analytics na levelu „editor“ anebo výše.

Po vygenerování přístupů v aplikaci uživatel nalezne účet, který reprezentuje organizaci, pro kterou se do systému budou stahovat, procesovat a analyzovat data.

Účet v systému Roivenu lze rozdělit na menší celky – *sites* (česky síť, webové stránky), které umožní organizaci sledovat výsledky marketingu ne pro celou organizaci, ale jako menší celky, které se typicky odlišují jiným marketingovým cílením. Například firma Datart tak může sledovat jednotlivě svoje cílové trhy `datart.cz` a `datart.sk`.

Po vytvoření *sites* se do nich napojují jednotlivé platformy (například Facebook, Google Ads atp.), které chce organizace sledovat a po stažení a procesování dat firma může začít s optimalizací marketingových výsledků (Roivenu 2022a).

## 5.3 Stahování, zpracování a vizualizace dat

### 5.3.1 Kvalita vstupních dat

Pro celkové fungování jakéhokoliv systému, který pracuje s daty, je potřeba vstupní data poskytovat vždy ve stejné požadované struktuře dat. Díky jednotné struktuře se jednodušeji předchází defektům na datech a problémům při zpracování dat.

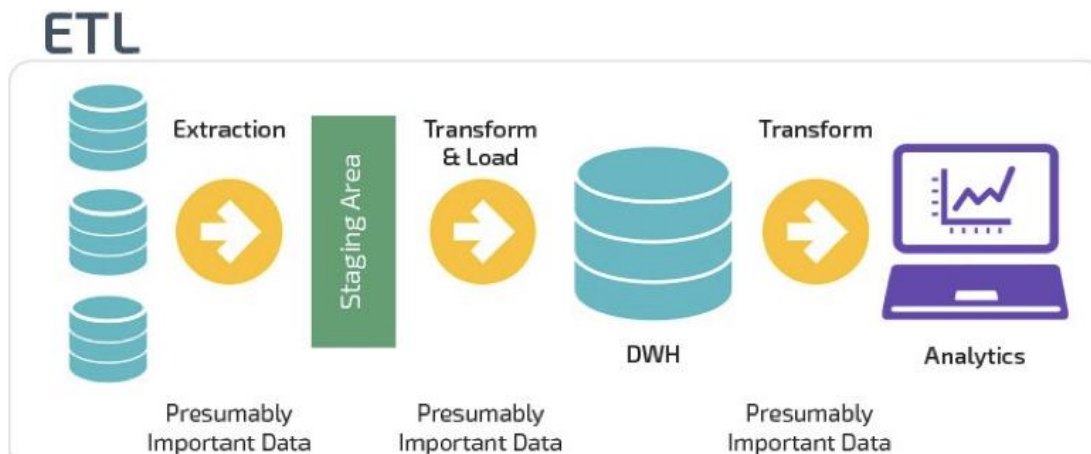
To, jakou formu mají vstupní data mít se v praxi většinou zjišťuje metodou pokus-omyl. Zkušení datoví a softwaroví inženýři modelují manuálně data krok po kroku a snaží se najít nejlepší formu výstupu vstupních dat. Pokud data budou z nějakého důvodu strukturovaná jinak a aplikace na tuto změnu nebude připravená, zpracování dat nebude možné dokončit (Quemy 2020).

### 5.3.2 ETL – *extraction, transform, load*

*Extraction, transform, load* – označuje mechanismus používaný ve výpočetní technice pro získávání dat z více systémů, jejich následné zpracování a poskytnutí aplikacím pro podporu rozhodování (BI). Proces ETL je komplikovaný, a proto představuje nezanedbatelný podíl v nákladech na budování BI systémů – nákladů ať finančních, tak i časových a lidských na následnou údržbu. Kvůli těmto důvodům Roivenu nedoporučuje řešit atribuční problémy firmám s méně než 30 000 webovými návštěvami za měsíc nebo s počtem konverzí cca třicet týdně – tedy šest až sedm denně. Těmto

firmám s nedostatečným množstvím dat Roivenu doporučuje zaměřit se na jiné marketingové problémy reflektující velikost jejich firmy, například podle *Marketing Maturity Modelu* popsaného v sekci 2.3 (Tietz et al. 2022; Bansal a Kagemann 2015; Anand 2014; Roivenu 2022b).

Obrázek 18: Diagram ETL procesu.



(Zdroj: Roivenu 2022b)

### **Extraction**

*Extraction* popisuje proces získání dat ze zdroje do „mezi“-úložiště (*staging area*). To umožňuje jednoduše s daty pracovat a poskytuje flexibilitu při transformacích.

*Extraction* v Roivenu zajišťují datové konektory. Konektory se denně ve 2:00 ráno připojí na API dané platformy a stáhnou nová data za předchozí den. Pro zjednodušení se ale tento proces dá představit stejně jako kdyby se manuálně uživatel přihlásil do dané platformy, data exportoval a nahrál přímo do systému Roivenu (Tietz et al. 2022; Bansal a Kagemann 2015; Anand 2014; Roivenu 2022b).

### **Transform**

Během části „*transform*“ dochází k očištění dat, provádí se různé výpočty, agregace a data se tvarují do požadovaného stavu pro aplikaci atribučního modelu a uložení do datových skladů.

Část „*transform*“ v Roivenu začíná po stáhnutí všech potřebných dat datovými konektory. Po jejich nutném očištění se spojují do jedné velké tabulky, aby aplikace atribučního modelu nebyla výpočetně náročná. Atribuční model se učí paralelně s tímto procesem (Tietz et al. 2022; Bansal a Kagemann 2015; Anand 2014; Roivenu 2022b).

### **Transform – aplikace AI atribučního modelu**

Aplikace atribučního modelu probíhá ve dvou částech. Model se nejdříve musí na poskytnutých datech naučit, poté je jeho výsledky potřeba aplikovat pro zobrazení konkrétních výsledků. Ačkoliv je nutné aplikaci výsledků modelu provádět denně, samotné učení modelu stačí provádět na týdenní, měsíční nebo i kvartální bázi. Model se učí na míru pro každý účet vytvořený v systému

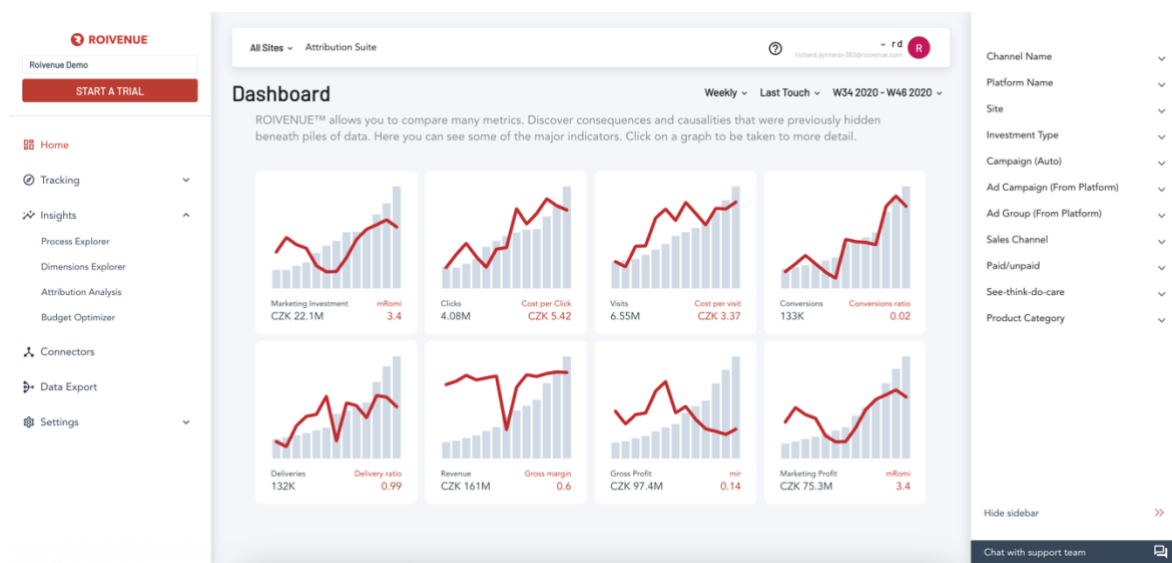
Roivenu. Každodenní učení by výrazně prodražilo systémové náklady a rozdíl výsledků učení modelu by byl minimální. Neočekává se, že by se interní či externí vlivy, které by výrazně ovlivnily výsledky učení modelů měnily na denní úrovni (Tietz et al. 2022; Bansal a Kagemann 2015; Anand 2014; Roivenu 2022b).

### Load

Load potom nahrává data z datových skladů do rozhraní reportu. Report může být v různých softwarech jako Excel, PowerBI nebo Tableau. Data jsou v datovém skladu ukládána v historizované podobě, což umožňuje reportovat vývoj metrik v čase.

V Roivenu část load obstarává interní API. To načítá data v aplikaci z MSSQL databáze, kam se data po dokončení části „transform“ nahrála. Data v databázi jsou neměnná a koncoví uživatelé je využívají k vizualizaci. Webová aplikace Roivenu nabízí několik předdefinovaných pohledů na data. Také tato data umožňuje exportovat ze systému do jiné destinace. Jelikož Roivenu není primárně vizualizační nástroj, jiná destinace může poskytovat větší flexibilitu pro práci s nimi (Tietz et al. 2022; Bansal a Kagemann 2015; Anand 2014; Roivenu 2022b).

Obrázek 19: Pohled na data v aplikaci Roivenu.



(Zdroj: Roivenu 2022a)

### 5.3.3 Typy zdrojů dat v systému Roivenu


Díky procesu ETL systém Roivenu denně pracuje s daty ve velikosti několika set gigabitů. Atribuční data z analytických nástrojů totiž obsahují záznamy každého zákazníka pro každou návštěvu, tedy mají velikost až několika set tisíc řádků strukturovaných dat – a tato data je potřeba zpracovat každý den. Do Roivenu můžeme napojit tyto typy dat o zákaznících:

- **Analytická** – data o chování zákazníků dané firmy na webových stránkách popsané v sekci 4.3;
- **Marketingová** – popisují, které reklamní platformy firma používá, a stahuje jednotlivé kampaňové metriky a dimenze z nich. Platformy, které to mohou být jsou popsané v sekci 2.2.1;
- **Informace z interního objednávkového systému** – jedná se o volitelný typ dat, který může zkvalitňovat rozhodnutí v systému Roivenu.

### 5.3.4 Interní objednávkový systém

Interní objednávková data – stažená například z ERP systému organizace – poskytují informace o reálném počtu objednávek (vrácených a doručených). Mohou obsahovat data o maržích, o ceně doručení atp. Manažeři si tak v Roivenu dokážou spočítat nejen marketingové, ale i podnikové metriky ve vztahu k online marketingu své firmy – například ROI, PNO nebo marketingový profit. Práce v aplikaci Roivenu je bez připojení interního objednávkového systému možná, ale některé metriky udávané systémem je potřeba brát spíše jako orientační než exaktní.

Obrázek 20: Proces zákaznické cesty, kde je červeným obdelníkem zvýrazněno, kterou část pokrývají data z objednávkového systému.



(Zdroj: Roivenu 2022a)

Systém Roivenu po připojení interního systému dokáže poskytnout data k reportům jako:

- RFM (*recency, monetary, frequency*) analýza;
- kohortní analýza;
- Analýza zákaznických cest ze zdrojových dat (Roivenu 2022b).



## 5.4 Komponenty Roivenu

Roivenu má v rozhraní aplikace pro vizualizaci k dispozici tři vizualizační nástroje pro reporting a jeden nástroj pro podporu plánování marketingového rozpočtu.

### 5.4.1 Attribution analysis

*Attribution analysis*, česky atribuční analýza, slouží k porovnání výsledků kteréhokoliv modelu atribuce s AI modelem Roivenu. V tabulce atribuční analýzy lze vidět procentuální rozdíl porovnávaných atribučních modelů na jakékoliv metrice a dimenzi. Atribuční analýza typicky uživatelům

Roivenu představuje pohled na jejich data v kontrastu s platformovým reportingem, jelikož marketingové platformy často využívají pohled na data pomocí last klikového modelu.

Obrázek 21: Komponenta Roivenu – Atribuční analýza.

Platform Name	Marketing Investment	Net Revenue			
		With Last Touch	With AI Data Driven	+/-	%
Google Ads	CZK 14,518,595	CZK 111,449,830	CZK 131,078,861	+CZK 19,629,031	+17.6%
TravelPayouts	CZK 7,706,416	CZK 18,011,420	CZK 20,994,180	+CZK 2,982,760	+16.6%
Facebook Business	CZK 5,500,770	CZK 17,058,551	CZK 17,024,097	-CZK 34,454	-0.2%
Adspread	CZK 2,684,367	CZK 13,713,310	CZK 15,830,475	+CZK 2,117,165	+15.4%
AffilPartner	CZK 2,042,395	CZK 0	CZK 0	CZK 0	0%
Other Platforms	CZK 1,339,590	CZK 14,133,782	CZK 6,372,005	-CZK 7,761,777	-54.9%
Reverto Stylemed	CZK 1,051,676	CZK 0	CZK 0	CZK 0	0%
AdRoll	CZK 583,657	CZK 1,795,267	CZK 1,403,328	-CZK 391,939	-21.8%

(Zdroj: Roivenu 2022a)


Na obrázku 21 lze vidět sloupečky s názvy platforem a jejich marketingovou investicí. V druhé polovině tabulky se nachází porovnávané atribuční modely (*last touch* a *AI data driven*) a jejich procentuální a absolutní rozdíl. Pokud je procentuální/absolutní rozdíl se znaménkem +, tak daná dimenze po aplikování AI atribučního modelu měla lepší výsledky oproti porovnávanému modelu, pokud s minusem, tak naopak po aplikování AI modelu měla dimenze v porovnání výsledky horší. V praxi marketéři zvyšují investice pro růst obrátu na „plusových“ dimenzích a pro zvýšení profitu zase ubírají na „minusových“ dimenzích.

## 5.4.2 Performance explorer

*Performance explorer*, česky „odhalovač výkonosti“, je multifunkční vizualizační nástroj. Nástroj umí zobrazit až 3 jakékoliv metriky zároveň. *Performance Explorer* slouží k analýze dat, objevení korelace nebo kauzalit napříč různými metrikami a následnému odhalování důvodů proč marketingové kampaně nebo celé strategie nefungují, jak mají. Nástroj také umí porovnat 2 časové periody mezi sebou.

Na obrázku 22 vidíme zobrazení tří metrik (marketingových investic, mROMI a počtu konverzí) na období posledních tří měsíců. První, hlavní metrika je zobrazená pomocí šedých sloupců, kde jeden sloupec znázorňuje jeden den. Dvě další metriky jsou znázorněny pomocí linií červenou a zelenou barvou.

Obrázek 22: Komponenta Roivenu – Performance Explorer.




(Zdroj: Roivenu 2022a)

## 5.4.3 Dimension explorer


*Dimension explorer*, česky „odhalovač dimenzí“, slouží k lepšímu porozumění dat na úrovni jednotlivých dimenzí. Oproti *Performance exploreru*, kde jsou zobrazena data dimenzí se sečtenými hodnotami metrik, *Dimension explorer* nabízí možnost si metriky rozpadnout po jakékoliv dimenzi.

Nástroj nabízí detailnější pohled na data a vyvaruje se „datové slepotě“, kdy se některé důležité údaje o dimenzích schovají za množstvím dat. *Dimension explorer* umožňuje si data vyobrazit na líniovém grafu, koláčovém grafu anebo v tabulce.

Obrázek 23: Komponenta Roivenue – Dimension Explorer.



Total marketing investments for the period 05-OCT-2020 - 31-DEC-2020



### Dimension Data

Platform Name	↓ Total Marketing Investment	Share
Google Ads	CZK 14,518,595	39.3%
TravelPayouts	CZK 7,706,416	20.9%
Facebook Business	CZK 5,500,770	14.9%
Adspread	CZK 2,684,367	7.3%
AffilPartner	CZK 2,042,395	5.5%
Other Platforms	CZK 1,339,590	3.6%
Reverto Stylemed	CZK 1,051,676	2.8%

(Zdroj: Roivenue 2022a)

## 5.4.4 Budget optimizer

*Budget optimizer* je plánovací nástroj. Pomocí znalosti historických dat a za použití statistických metod systém Roivenuu dokáže odhadnout míru přínosu a saturace jakékoliv dimenze na trhu a poskytne návrh na úpravu marketingové strategie.

Obrázek 24: Tabulka v *Budget optimizeru* s jednotlivými úpravami marketingových investic a jejich předpokládaný růst/pokles rozpadnutý po dimenzi.

Channel Name	Marketing Investment Adjustment			Impact on Net Revenue		Impact on Gross Profit		Impact on Marketing Profit	
	Last Week	Adjustment	Adj. This Week	Exp. Change	Exp. Value	Exp. Change	Exp. Value	Exp. Change	Exp. Value
Google Ads - Search - Brand	CZK 41,186	+CZK 74,617	CZK 115,803	+CZK 353,714	CZK 548,954	+CZK 203,269	CZK 315,467	+CZK 128,652	CZK 191,119
Facebook - Retargeting	CZK 10,236	+CZK 41,706	CZK 51,942	+CZK 84,167	CZK 104,826	+CZK 53,282	CZK 66,359	+CZK 11,576	CZK 14,732
Google Ads - Retargeting	CZK 5,026	+CZK 3,542	CZK 8,568	+CZK 35,743	CZK 103,297	+CZK 23,204	CZK 64,109	+CZK 19,662	CZK 51,771
Heureka	CZK 1,060	+CZK 6,000	CZK 7,060	+CZK 62,226	CZK 73,217	+CZK 24,805	CZK 29,187	+CZK 18,805	CZK 22,990
CriticalAd	CZK 7,187	+CZK 810	CZK 7,997	+CZK 1,527	CZK 20,318	+CZK 846	CZK 12,690	+CZK 36	CZK 4,876
<b>Total</b>	<b>CZK 98,659</b>	<b>+CZK 132,785</b>	<b>CZK 231,444</b>	<b>+CZK 550,987</b>	<b>CZK 1,075,813</b>	<b>+CZK 314,848</b>	<b>CZK 631,397</b>	<b>+CZK 182,063</b>	<b>CZK 391,115</b>

(Zdroj: Roivenuu 2022a)

*Budget optimizer* má několik nastavení. Uživatelé si mohou nastavit:

- svoji strategii marketingu a míru přípustnosti ke změnám v ní;
- zda chtějí být zaměřeni spíše na zvýšení obrátu anebo profitu organizace;
- zda chtějí marketingové investice v budoucnu zvyšovat, snižovat anebo je neměnit vůbec.

Obrázek 25: Komponenta Roivenuu – *Budget optimizer*.



(Zdroj: Roivenuu 2022a)

*Budget optimizer* je potřeba brát pouze jako orientační nástroj a jeho doporučení je třeba vždy testovat a porovnávat s realitou.

## 6 Případová studie

V rámci bakalářské práce byly provedeny případové studie 2 různých firem se zaměřením zejména na Česko a Slovensko. Analýza proběhla na anonymizovaných datech poskytnutých firmou Roivenue. Firmy z anonymity důvodu budou nazývány typem byznysového modelu.

### 6.1 Metoda případové studie

Dle Gerringa (2006) termín případová studie může být použit při různých smyslech a s různými definicemi. Může se například jednat o:

- Metoda výzkumu je kvalitativní, tudíž má malý počet pozorování;
- Holistické zkoumání jevu, které zahrnuje širokou škálu prvků;
- Výzkum, který zahrnuje širokou škálu prvků o využití nějakého důkazu (etnografický, klinický, historický...);
- Výzkum v přirozeném kontextu;
- Zkoumání vlastností jednoho sledování;
- Difuzní téma, kdy je obtížné rozlišit mezi případem a obsahem
- Triangulace – využití více zdrojů důkazů

Podle Hendla (2005) se případové studie zaměřují na hloubkový popis určitého jevu. Ve vědeckém světě je případová studie brána jako způsob sdělování výsledků výzkumu. Chrastina (2019) zase shrnul, že Stake (1995) definuje případovou studii čtyřmi základními pojmy. Případová studie je:

- holistická – zkoumání pouhé části celku nemůže definovat celek;
- empirická – zkoumání je založeno na zkušenostech výzkumníka;
- interpretativní – výzkumník se v případové studii řídí vlastní intuicí;
- zprostředkující – výsledky jsou zprostředkované podle zkušeností výzkumníka a subjektů studie.

Každá z těchto definic se může lišit v závislosti na určitém sledovaném kontextu. Gerring píše, že v závislosti na výzkumné otázce nebo hypotéze výzkumníka se poté tvoří i design a přístup k případové studii. I proto se dají kombinovat i různé metody srovnávání sledovaných jevů.

### 6.2 Výzkumné otázky

#### 6.2.1 První výzkumná otázka

Nejen v Česku, ale i světově atribuci vládou stále heuristické modely. V USA v roce 2016 pouze 17% dotázaných používalo jiný než heuristický model (Datalicious 2016). Důvodů může být několik. Marketingové atribuční modelování je poměrně nový termín a trh si ho ještě nedokázal dostatečně adoptovat. Nebo se také modelování se také nemusí vyplatit všem. Některé firmy nemusí mít dostatek prostředků na implementaci data-driven atribučního modelování. Například to ale také

může být z důvodu, že atribuční modelování nemusí zlepšovat výsledky firem. Proto první výzkumnou otázkou je: **Zlepšuje zapojení atribučního modelování prodeje firmy v online prostředí?**

## 6.2.2 Druhá výzkumná otázka

Kakalejčík a další (2018) se ve své práci „Multichannel Marketing Attribution Using Markov Chains for E-Commerce“ zabývají využitím atribučního modelování pro čtyři anonymizované internetové obchody pohybující se na slovenském e-commerce trhu. Analyzují poskytnutá data cest zákazníků a pomocí Markovových řetězců třetího řádu porovnávají výsledky s last klikovým modelem z Google Analytics.

Jelikož se výsledky modelů kvůli rozdílným cestám zákazníků mohou lišit od typu byznysového modelu – tedy jestli zákazníci nakupují na internetu službu anebo produkt, tak druhá výzkumná otázka zní: **Může z aplikace atribučního modelování získat i firma, která neprodává produkty, ale nabízí na internetu své služby?**

## 6.3 Případová studie 1 – firma E-commerce

### 6.3.1 Současný stav

Firma E-commerce se na trhu pohybuje už přes deset let. Každým rokem roste v obrátu v jednotkách až desítkách procent, a to dokonce i během covidové pandemie. Do digitálního marketingu investuje firma částky v nižších jednotkách milionů korun měsíčně, nejvíce pak do PPC reklam. Pro analýzu jsou dostupná anonymizovaná data z listopadu a prosince 2020, kdy probíhají velké Black Friday a Vánoční kampaně.

Konkrétní platformy, které má firma připojené do Roivenu, jsou:


- platforma na nákup programatické reklamy AdForm,
- srovnávacové a katalogové platformy Arukereso, Bianco a Ceneo,
- affiliate partneři CJ Affiliate a Dognet,
- PPC/social media platformy Criteo, Facebook a Google Ads,
- a na svoje existující zákazníky firma cílí emailovým marketingem.

V těchto platformách firmě E-commerce běží ročně dohromady až přes 5000 kampaní. Analytiku a měření konverzí na webových stránkách mají zajištěnou přes platformu Google Analytics. Pro firmu je provedení konverze zakoupení produktu na jejich internetovém obchodě. Těchto konverzí – transakcí – mají až desítky tisíc měsíčně. Do systému Roivenu nemají napojený objednávkový systém. Reporting dat a následné operativní rozhodování před používáním Roivenu bylo prováděno v systému Google Analytics v last klikovém atribučním modelu. Firma používala také dodatečné reporty z jiných platform, případně jiné reporty s podpůrnými daty.

### 6.3.2 Pohled na data

Při pohledu na data v *Performance exploreru* můžeme vidět díky celkem konzistentním marketingovým investicím, že *Black Friday* pro firmu E-commerce není tak strategicky důležitý. Na sledovaném období dva týdny před *Black Friday* (14. 11.-30. 11.) jsou na grafu vidět pouze dvě špičky růstu marketingových investic, a to 17. 11. a 19. 11. Na druhou stranu nárůst konverzí a obratu během *Black Friday* víkendu lze vidět. Firma se zřejmě strategicky zaměřila více na Vánoční sezónu, kdy pouhý týden před Vánoci byly průměrné marketingové investice dokonce výše než během nejvyšších investic během *Black Friday*.


Obrázek 26: Pohled na data firmy E-commerce v listopadu a začátek prosince.



(Zdroj: Roivue 2022a)

Firma ale ani před Vánoci neutrácela tolik peněz, jelikož investice před Vánoci už nestoupaly, a ihned po Vánocích klesly investice do reklamy na čtvrtinu oproti normálu.

Obrázek 27: Pohled na data firmy E-commerce v prosinci.



(Zdroj: Roivue 2022a)

### 6.3.3 Optimalizace – testování modelu AI

Firma E-commerce se potřebovala ujistit, zda může výsledkům modelu AI atribuce věřit. Test proběhl na základě podnětů z Atribuční analýzy pohledem last klikové atribuce v porovnání s AI modelem. Sledovanou metrikou byl obrat. Už při prvním pohledu v analýze lze nalézt několik kampaní, které by šly AI modelem zlepšit. Jelikož nejvíce peněz a obratu v tomto období firma utrácela a zároveň i vygenerovala v platformách Facebook Business a Google Ads, bylo vhodné test nejdříve provést na kampaňové úrovni pro tyto dvě platformy.

Jelikož se jednalo o test, nechtěla firma E-commerce dělat velké změny. Proto se zaměřili na první dvě kampaně těchto dvou platforem, které produkují přes polovinu obratu a plyne do nich většina marketingových prostředků. Podle Atribuční analýzy by měla jakákoliv úprava těchto dvou kampaní udělat kladný rozdíl.

Obrázek 28: Tyto dvě kampaně z Facebooku a Google Ads přináší firmě největší část obratu.

Campaign (auto)	Marketing Investment	Net Revenue			
		With Last Touch ↓	With AI Data Driven	+/-	%
Google Ads   Performance 1	CZK 1,555,123	CZK 15,185,723	CZK 35,145,331	+CZK 19,959,858	+56.80%
Google Ads   Performance 4	CZK 945,423	CZK 8,958,104	CZK 12,705,989	+CZK 3,747,885	+29.5%
Facebook   Social ad	CZK 123,875	CZK 2,153,664	CZK 2,427,325	+CZK 273,661	+11.3%
Instagram reels BF	CZK 54,689	CZK 1,878,156	CZK 1,556,253	-CZK 321,903	-20.7%
Search Google	CZK 85,127	CZK 1,277,777	CZK 1,152,012	-CZK 54,292	-10.7%

(Zdroj: Roivenu 2022a)

Při změně metriky z obratu na PNO zjistíme, že obě kampaně ho mají relativně malé, což může naznačovat nevyužitý potenciál kampaní. Pro ověření této hypotézy se firma E-commerce rozhodla ubrat z druhé kampaně skoro 40 % denních investic, podpořit první kampaň a zkusit, jestli se potenciál kampaně zvýší. Výsledkem byl nárůst obratu obou kampaní o stovky tisíc českých korun při zachování stejné ziskovosti v následujícím sledovaném časovém oknu.

Obrázek 29: Pohled na stejné kampaně přes metriku PNO.

Campaign (auto)	Marketing Investment	Marketing Investment Ratio			
		With Last Touch	↓ With AI Data Driven	+/-	%
Google Ads   Performance 1	CZK 863,491	6.2%	5.1%	-1.1%	-21.6%
Google Ads   Performance 4	CZK 1,708,249	6.8%	5.8%	-1%	-17.2%

(Zdroj: Roivenu 2022a)



Po úspěšném testu se firma rozhodla pomocí stejného rozhodovacího procesu optimalizovat další kampaně identifikované v Atribuční analýze a dokázala ušetřit 4000 korun denně při nulovém dopadu na výsledný obrat. Firma tedy kromě vydělaných stovek tisíc korun díky optimalizacím, šetří i cirka 120 000 měsíčně na investicích, které může zkusit vložit do jiných pod investovaných anebo nových kampaní.

### 6.3.4 Další možné návrhy na zlepšení

Jedním z dalších směrů, kam by se firma mohla vydat, je identifikace nevýkonných kampaní. Jedním způsobem, jak tyto kampaně v Roivenu identifikovat, je pomocí *Dimension exploreru*. Uživatelé si mohou nastavit kampaň jako hlavní dimenzi a metriku například PNO (avšak by se dalo analogicky postupovat i jinými metrikami). V tabulce *Dimension exploreru* si pak výsledky uživatelé seřadí od nejhoršího a postupně jednu kampaň po druhé sledují. Pokud výkonost v čase byla historicky nízká a nepřináší dostatek obratu, kampaň v mixu není pro zvýšení obratu důležitá.

Obrázek 30: Anonymizovaná data firmy E-commerce v *Dimension exploreru*.

Campaign (auto)	Average Marketing Investment Ratio	↓ Normalized to the average
Google Ads   Elektro - 1	132,520.7%	75.02
Google Ads   Produkt id 15	48,120.5%	22.13
Adform   display brand	35,987.3%	19.01
Facebook   Social BF campaign	25,987.6%	15.22
Display ad	11,752.9%	7.15
Dognet   Affiliate 10-12	10,166.8%	6.12
IG reel social ad	6,123.9%	4.05
instream YT ad	5,785.5%	1.9
Ceneo   Katalog ad	5,950.6%	1.85
Google ads   search longtail	5,852.1%	1.8

Items per page:  1 – 10 of 209 |< < > >|

(Zdroj: Roivenu 2022a)

Na obrázku 30 můžeme vidět jednotlivé kampaně s průměrným PNO. Poslední sloupeček (*Normalized to the average*) poté říká, kolikrát je kampaň horší oproti průměrnému kampaňovému PNO firmy.

Roivenu nedoporučuje nevýkonné kampaně ihned vypnout. Doporučený způsob je postupně na týdenní bázi kampaním snižovat investice a sledovat, jestli opravdu dopad na obrat byl nulový. Peníze, které firma E-commerce ušetří na těchto parazitických kampaních, pak mohou sloužit při realokaci do výkonnějších kampaní.

### 6.3.5 Výsledky

Firma E-commerce díky drobným změnám ve svém marketingu dokázala za dva měsíce zvýšit obrat ve vyšších stovkách tisíců korun. To je meziměsíční nárůst přes 10 %. Také zároveň šetřila peníze na marketingových investicích při zachování podobného obratu.

Dohromady firma za období těchto dvou měsíců dokázala vydělat střední desítky milionů korun v obratu a přes desítku tisíc konverzí. Celkové marketingové investice byly přes 4 miliony korun. *Return on marketing investment* (obdoba ROI, avšak se vztahuje pouze na marketingové investice) se pohybovala kolem hodnoty 10. Tedy každá koruna utracená v marketingu vygenerovala 10 korun na obratu. Nejsilnějšími platformami v tomto období byly už zmiňovaný Facebook a Google Ads.

## 6.4 Případová studie 2 – firma Služby

### 6.4.1 Současný stav

Firma Služby se na českém i světovém trhu pohybuje desítky let. Do online marketingu investuje střední desítky milionů korun ročně. Mezi její silné marketingové kanály patří displejové reklamy, ale nejvíce peněz utrací v PPC reklamách – například na Google Ads.

Do Roivenu má napojené tyto platformy:


- affiliate platformu CJ Affiliate,
- platformy na nákup programatické reklamy AdForm nebo Google Display&Video360,
- PPC platformy Google Ads, Bing a Sklik,
- sociální sítě Facebook a Instagram,
- a na své stávající klienty cílí emailíngem nebo reklamou v mobilní aplikaci.

Firma nemá do systému Roivenu napojený objednávkový systém. Webové stránky firmy měří pomocí platformy Google Analytics, avšak ve verzi Google Analytics 360 – placené rozšířené verzi. Jedna konverze je pro firmu Služby prodej jejich služby na webových stránkách, těch mají ročně stovky tisíc. Před reportováním pomocí systému Roivenu využívala reporting pomocí excelových tabulek a Google Analytics. Pro analýzu společnost Roivenu poskytla anonymizovaná data z roku 2020–leden 2021, kdy se prováděly větší optimalizační kampaně.

## 6.4.2 Pohled na data

Při pohledu na data celého roku jsou pro firmu znát dvě výraznější sezony. Ta větší, znatelnější je v létě, druhá v období prosinec/únor. Z hlediska obrátu, který je na obrázku znázorněn červenou barvou, je ale oproti létu důležitost menší.

Obrázek 31: Pohled na data celého roku pro firmu Služby.




## 6.4.3 Optimalizace marketingového mixu

Optimalizace provedené společně s Roivenu se prováděly během dvou měsíců a byly zaměřené do tří vln:

- 1. vlna se zaměřila na různé platformy v marketingovém mixu – zejména se jednalo o vypínání nefunkčních kampaní napříč platformami;
- 2. vlna se zaměřila na optimalizaci v platformě AdForm;
- 3. vlna se týkala dalších optimalizací v AdFormu a reinvestování ušetřených peněz.

Samotné optimalizace během 1. a 2. vlny probíhaly podobně jako v první případové studii s firmou E-commerce. Marketingový tým firmy Služby objevil v Atribuční analýze kampaně, kdy AI atribuční model během dvou měsíců nereportoval skoro žádný obrat. Tyto kampaně byly pravděpodobně parazitické a nefunkční, a proto se tedy vypnuly. Jen za listopad a prosinec tím firma Služby na investicích ušetřila skoro 80 000 Kč, které lze vidět na obrázku 32 na snižujících se šedých sloupcích.

Obrázek 32 Pohled v Performance exploreru na kampaně, které byly vypnuté během 1. vlny.

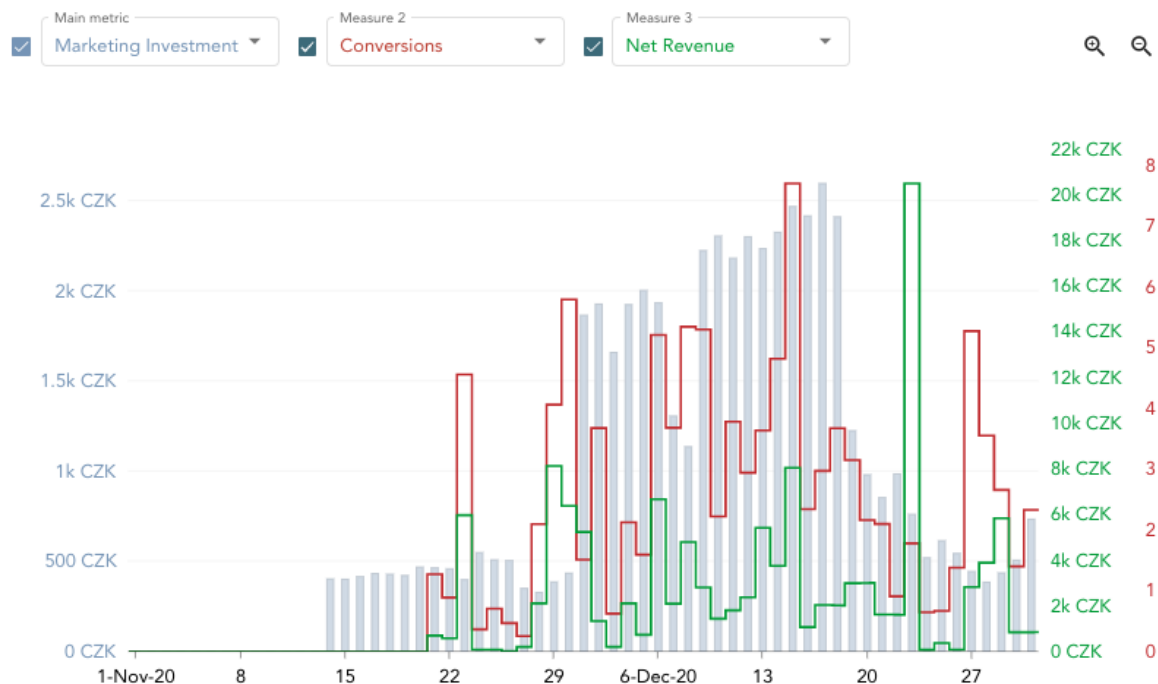


(Zdroj: Roivenu 2022a)

Ve 2. vlně se marketingový tým snažil najít a podpořit kampaně, které naopak výkon mají. Firma vedla kampaně v displejové platformě AdForm. Obsahové kampaně, které většinou stojí na počátku cesty zákazníka, jsou často podceňované last klikem, který preferuje spíše ty uzavírající kanály. Po aplikaci AI modelu se ale ukázalo, že kampaně nějaký výkon vykazují, a proto se zdály tyto kampaně jako skvělými kandidáty, u kterých zvýšit investice pro zvýšení výkonu.

Samotná identifikace těchto podceňovaných kampaní proběhla na několika nástrojích v Roivenu. První objevení bylo na Atribuční analýze. Poté firma Služby tyto kampaně sledovala pomocí výkonnostních metrik v *Performance* a *Dimension exploreru*, jelikož chybné rozhodnutí mohlo firmu stát desetitisíce korun. Na obrázku 33 můžeme vidět, jak optimalizace byly v 2. vlně úspěšné

Obrázek 33: Pohled v *Performance exploreru* na kampaně, které se podporovali dodatečnými marketingovými investicemi.



(Zdroj: Roivenu 2022a)

Poslední vlna optimalizací se týkala znovu celého marketingového mixu. Konala se zejména v 2. měsíci změn. Sledovaly se hlavně výsledky prvních 2 dvou měsíců a prováděly další drobné změny. Hlavní analýzy probíhaly znovu v *Performance* a *Dimension exploreru*, na výsledný výstup 3. vlna neměla takový vliv.

#### 6.4.4 Výsledky

Díky všem optimalizacím se během tří měsíců dokázalo ušetřit dohromady přes 150 000 Kč. Z toho bylo přibližně 42 000 Kč reinvestováno zpět. Změny dohromady vygenerovaly přes 109 000 Kč, a to i mimo sezonu firmy. Celkový dopad tedy všech změn během těchto tří měsíců byl přes 200 000 Kč. Jednalo se skoro o 10% nárůst během tří měsíců. Návratnost na investicích byla v tomto období kolem 400 %.

## 6.5 Diskuze

Díky případovým studiím jsme si odpověděli na obě výzkumné otázky, které byly:

- Zlepšuje zapojení atribučního modelování prodeje firmy v online prostředí?
- Může z aplikace atribučního modelování získat i firma, která neprodává produkty, ale nabízí na internetu své služby?

V případových studiích jsme analyzovali dvě firmy s rozdílným byznys modelem:

- Firma E-commerce nabízí produkty na svém e-shopu.
- Firma Služby nabízí služby přes svůj web.

I přes tyto rozdíly v nabízených produktech/službách obě firmy ale dokázaly vykázat pozitivní výsledky na základě podnětů ze softwaru Roivenu.

Odpověď na druhou výzkumnou otázku zní: Ano, z atribučního modelování dokáže profitovat i firma, která na internetu nabízí svoje služby. Druhou výzkumnou otázku vyvrátili během konzultací praktické části i zaměstnanci Roivenu. Podle nich je atribuční modelování sice vhodnější pro firmy pohybující se v e-commerce prostředí, jelikož tyto firmy atribuční problém potřebují řešit více než ostatní společnosti. Atribuční modelování ale dokáže pomoci i firmám s jiným byznysovým modelem a dokazují to rovněž i tím, že ve svém klientském portfoliu má Roivenu firmy s *lead based* nebo *subscription* modelem. Zodpovězením na druhou výzkumnou otázku jsme také rozšířili práci Kakalejčika et al. (2018), jelikož z atribučního modelování dokážou profitovat nejen Slovenské společnosti.

S ohledem na první výzkumnou otázku. Obě firmy využíváním služeb společnosti Roivenu vnesly do svých dat:

- Transparentnost. Firmy každý den věděly, kde a kolik utrací peněz v jaké marketingové platformě.
- Integrace všech dat do jednoho systému uvedlo celý marketingový mix do kontextu.
- Manažeři byli schopni na pár kliků v komponentách Roivenu vidět trendovost jejich dat, a dokonce jaké vykazují výsledky jednotlivé.
- A díky *Performance exploreru* byli schopni na pár kliknutí myši vidět, jak se zákazníci chovají před konverzí, vědí jasně, kdy se konverze stane a jsou schopni sledovat i fázi po nákupu.

V číslech obě firmy vyrostly o jednotky až desítky procent meziměsíčně. Konkrétní způsoby, jak firmy v případových studiích pracovali s jejich daty v Roivenu a přišly k výsledkům, jsou následující:

- Vypínání platforem a kampaní, které mají nízký nebo žádný efekt na metriky pomocí Atribuční analýzy nebo *Dimension exploreru*.
- Podpoření kampaní, které s AI modelem firmy Roivenu oproti last klikovému atribučnímu kliku měly generovat větší růst. Také pomocí Atribuční analýzy.
- Výběr kampaní s nevyužitým potenciálem například sledováním metriky PNO anebo zvyšování profitu snižováním investic do kampaní s nízkým PNO. To vše například v porovnání s průměrným PNO celé organizace.

- Sledování výkonnostních metrik v čase pomocí *Performance exploreru*.

Konzultanti společnosti Roivenuie ale uvedli několik dalších způsobů, které by firmy mohly provést pro zlepšení výsledků. Například:

- Přerušování marketingové podpory prodeje produktům, kde je záporný marketingový profit.
- Sledování dalších reportů po napojení objednávkového systému. Například zmínili vytvoření RFM analýzy, užívání exportů zdrojových dat nebo kohortní analýzy.
- Sledování ziskovosti při slevových kampaních. Roivenuie uvedlo, že firmy často provádí kupónové slevy, vidí nárůst objednávek, ale ve finále během kupónových slev kvůli slevám vykazaly záporný profit.

Možnou limitací byl výběr dat. Jelikož vybranými obdobími pro analýzu bylo pro obě firmy v období sezóny, mohly výsledky atribučního modelování být trochu pokřivené. Na druhou stranu, analýza probíhala na období měsíců případně negativní výsledky by se na tomto delším období ukázaly.

Ačkoliv je možné říci, že marketingové výsledky mohly být ovlivněné externími vlivy jako třeba:

- mikro a makroekonomické faktory,
- konkurenční firmy polevily v marketingu anebo úplně změnily svojí strategii,
- roli mohla hrát i trendovost a sezonalita prodávaného zboží/služeb.

Tyto faktory by ale byly viditelné na datech v rozmezí celého sledovaného období. V obou případech lze spatřit dostavení se výsledků ihned po změnách, které provedly díky podnětům ze softwaru Roivenuie. Systém Roivenuie manažerům poskytl perfektní prostředí pro každodenní operativní rozhodování.

Tyto změny by firmy nemohly provést bez využití svých dat v systému Roivenuie, anebo jakéhokoli jiného systému. Vyvrácení první výzkumné otázky je tedy na místě. Aplikace atribučního modelování vede firmy k zvýšení prodejů firem.

# Závěr

Práce předložila analýzu internetového prostředí dvou firem, které za pomoci multikanálového atribučního modelování marketingových dat dokázaly zlepšit své marketingové a byznysové výsledky. Díky osobní zkušenosti autora práce byla pro analýzu zvolena firma Roivenu. Firma Roivenu vyvíjí vlastní aplikaci a atribuční model, který její klienti používají při analýze dat. Přínosem práce je empirický materiál pro operativní rozhodování manažera e-shopu který by mohl využít jako návod, jak svoje marketingová data využívat a pomocí vhodné vizualizace využít ve svůj prospěch. Cílem práce bylo předložit analýzu internetového prostředí firem v odvětví služeb (E-Commerce), která bude dávat do kontextu (vizualizovat) cesty online zákazníka na e-shopu skrze software.

V rámci teoretické části jsme si vysvětlili témata důležitá pro pochopení atribučních modelů. Tato pasáž konkrétně popisovala online marketing a jeho reklamní platformy, dále zákaznické cesty a atribuční modely a v neposlední řadě důležitost dat pro každodenní rozhodování.

V první polovině praktické části jsme si představili firmu Roivenu. Rozebrali jsme si proces získání dat z různých zdrojů do jednoho systému, nastínili zpracování těchto dat a popsali, ve kterých komponentách systému s daty můžeme pracovat.

V druhé půlce praktické části jsme si stanovili výzkumné otázky, metodiku zpracování praktické části a představili případovou studii 2 firem se zaměřením na český a slovenský trh. Případové studie analyzovaly internetové prostředí těchto firem a za použití služeb firmy Roivenu se snažily o optimalizaci a následný růst jejich marketingových a byznysových výsledků. Na případových studiích jsme si vysvětlili různé způsoby, které lze využít k růstu výsledků organizace. Například šlo:

- o odhalení silných a slabých kanálů,
- porovnání modelů v Atribuční analýze
- nebo sledování trendů metrik v *Process exploreru*.

Díky výsledkům obou případových studií jsme si odpověděli na obě výzkumné otázky. Konkrétně jsme si dokázali, že atribuční modelování firmám pomohlo v meziměsíčním růstu až o desítky procent a také ukázaly, že atribuční modelování není vhodné jen pro firmy pohybující se v e-commerce prostředí.

Tedy jakákoliv firma s dostatečným množstvím návštěv a konverzí na webu, která by chtěla pochopit chování zákazníků ve vztahu k jejímu marketingovému mixu, by měla zvážít způsob operativního rozhodování pomocí aplikace multikanálového atribučního modelování za použití Roivenu, či podobného řešení.



# Seznam použité literatury

- ABHISHEK, Vibhanshu, Stylianos DESPOTAKIS a R. RAVI, 2017. *Multi-Channel Attribution: The Blind Spot of Online Advertising* [online]. SSRN Scholarly Paper. 27. duben 2017. [vid. 2023-01-28]. Dostupné z: doi:10.2139/ssrn.2959778
- AMIN OMIDVAR, Mohammad, Vahid REZA MIRABI a Narjes SHOKRY, 2011. Analyzing the Impact of Visitors on Page Views with Google Analytics. *International journal of Web & Semantic Technology* [online]. 2(1), 14–32. ISSN 09762280. Dostupné z: doi:10.5121/ijwest.2011.2102
- ANAND, Nitin, 2014. ETL and its impact on Business Intelligence [online]. 4(2) [vid. 2023-01-28]. ISSN 2250-3153. Dostupné z: [https://www.academia.edu/11434594/ETL\\_and\\_its\\_impact\\_on\\_Business\\_Intelligence](https://www.academia.edu/11434594/ETL_and_its_impact_on_Business_Intelligence)
- ANGHEL, Alexandra, Elena NOVĂCESCU a Mădălina CUC, 2022. BIG DATA AND ITS SECRETS: TYPES OF BIG DATA. *Romanian Intelligence Studies Review*. (27), 53–73. ISSN 2393-1450, 2783-9826.
- APEK, 2022. Number of online stores in Czechia by turnover value 2021. *Statista* [online] [vid. 2023-01-22]. Dostupné z: <https://www.statista.com/statistics/1240687/number-of-online-stores-in-czechia-by-turnover-value/>
- ASPLEN-TAYLOR, Simon, 2022. *Data and Analytics Strategy for Business: Unlock Data Assets and Increase Innovation with a Results-Driven Data Strategy*. B.m.: Kogan Page Publishers. ISBN 978-1-398-60606-7.
- BANSAL, Srividya K. a Sebastian KAGEMANN, 2015. Integrating Big Data: A Semantic Extract-Transform-Load Framework. *Computer* [online]. 48(3), 42–50. ISSN 1558-0814. Dostupné z: doi:10.1109/MC.2015.76
- BHATTA, Ishwor, 2022. *Optimizing Marketing Channel Attribution for B2B and B2C with Machine Learning Based Lead Scoring Model* [online]. United States -- Maryland [vid. 2023-01-22]. Ph.D. Capitol Technology University. Dostupné z: <https://www.proquest.com/docview/2716520342/abstract/5717FA52A0204E8CPQ/1>
- BORDEN, Neil H, 1964. The Concept of the Marketing Mix'. *Journal of Advertising Research*.
- BOUFIM, Meryem a Hafid BARKA, 2021. Digital Marketing: Five Stages Maturity Model for Digital Marketing Strategy Implementation. *International Journal of Business and Technology Studies and Research IJBTSR* [online]. 3(3), 15 pages. Dostupné z: doi:10.5281/zenodo.5578706
- BUREŠOVÁ, Jitka, 2022. *Online marketing: Od webových stránek k sociálním sítím*. B.m.: Grada Publishing a.s. ISBN 978-80-271-4928-5.
- CLIFTON, Brian, 2012. *Advanced Web Metrics with Google Analytics*. B.m.: John Wiley & Sons. ISBN 978-1-118-23958-2.
- CZECH STATISTICAL OFFICE, 2022. Czechia: people shopping online 2022. *Statista* [online] [vid. 2023-01-22]. Dostupné z: <https://www.statista.com/statistics/1282069/czechia-people-shopping-online/>
- DARWEN, Hugh, 2009. *An Introduction to Relational Database Theory*. B.m.: Bookboon. ISBN 978-87-7681-500-4.
- DAS, Rushali, 2022. How To Track Social Media Campaigns With UTM Parameters | Statusbrew. *Statusbrew Blog* [online] [vid. 2023-01-22]. Dostupné z: <https://statusbrew.com/insights/utm-parameters/>

- DATALICIOUS, 2016. Marketing attribution models used in the U.S. 2016. *Statista* [online] [vid. 2023-03-25]. Dostupné z: <https://www.statista.com/statistics/685099/models-marketing-attribution-usa/?locale=en>
- DATANYZE, 2022. Global web analytics software market share 2022. *Statista* [online] [vid. 2023-01-22]. Dostupné z: <https://www.statista.com/statistics/1258557/web-analytics-market-share-technology-worldwide/>
- DE MAURO, Andrea, Marco GRECO a Michele GRIMALDI, 2016. A formal definition of Big Data based on its essential features. *Library Review* [online]. **65**(3), 122–135. ISSN 0024-2535. Dostupné z: doi:10.1108/LR-06-2015-0061
- FOLEY, Éric a Manon G. GUILLEMETTE, 2010. What is Business Intelligence? *International Journal of Business Intelligence Research (IJBIR)* [online]. **1**(4), 1–28. ISSN 1947-3591. Dostupné z: doi:10.4018/jbir.2010100101
- GERRING, John, 2006. *Case Study Research: Principles and Practices*. B.m.: Cambridge University Press. ISBN 978-1-139-46038-5.
- GHOSE, Anindya a Vilma TODRI-ADAMOPOULOS, 2016. Toward a Digital Attribution Model: Measuring the Impact of Display Advertising on Online Consumer Behavior. *MIS Quarterly*. **40**(4), 889–910. ISSN 0276-7783.
- HANLON, Annmarie, 2021. *Digital Marketing: Strategic Planning & Integration*. B.m.: SAGE. ISBN 978-1-5297-8444-2.
- HENDL, Jan, 2005. *Kvalitativní výzkum : základní metody a aplikace*. 1. vyd. Praha: Portál. ISBN 80-7367-040-2.
- CHAFFEY, Dave a P. R. SMITH, 2017. *Digital Marketing Excellence: Planning, Optimizing and Integrating Online Marketing* [online]. 5. vyd. London: Routledge. ISBN 978-1-315-64034-1. Dostupné z: doi:10.4324/9781315640341
- CHRASTINA, Jan, 2019. *Případová studie - metoda kvalitativní výzkumné strategie a designování výzkumu: Case Study - a Method of Qualitative Research Strategy and Research Design* [online]. ISBN 978-80-244-5373-6. Dostupné z: doi:10.5507/pdf.19.24453736
- IDC a STATISTA, 2022. Total data volume worldwide 2010-2025. *Statista* [online] [vid. 2023-01-22]. Dostupné z: <https://www.statista.com/statistics/871513/worldwide-data-created/>
- JANOUC, Viktor, 2020. *Internetový marketing*. 3. aktualizované vydání. Brno: Computer Press. Book, Whole. ISBN 978-80-251-5016-0.
- KAKALEJČÍK, Lukáš, Martina FERENCOVA, Paulo RESENDE a Jozef BUCKO, 2018. Multichannel Marketing Attribution Using Markov Chains. *Statistika: Statistics and Economy Journal*. **101**.
- KAPE, Sanel, 2016. DIGITAL MARKETING MATURITY: THE RESULTS ARE IN [online]. [vid. 2023-01-28]. Dostupné z: [https://www.academia.edu/36928524/DIGITAL\\_MARKETING\\_MATURITY\\_THE\\_RESULTS\\_ARE\\_IN](https://www.academia.edu/36928524/DIGITAL_MARKETING_MATURITY_THE_RESULTS_ARE_IN)
- KELSEY, Todd, 2017. *Introduction to Google Analytics* [online]. Berkeley, CA: Apress [vid. 2023-01-22]. ISBN 978-1-4842-2828-9. Dostupné z: doi:10.1007/978-1-4842-2829-6
- KLAUS, Helmut, Michael ROSEMANN a Guy G. GABLE, 2000. What is ERP? *Information Systems Frontiers* [online]. **2**(2), 141–162. ISSN 1572-9419. Dostupné z: doi:10.1023/A:1026543906354
- KOLEKTIV AUTORŮ, 2014. *Online marketing*. Brno: Computer Press. ISBN 978-80-251-4155-7.

- KORULA, Nitish, Vahab MIRROKNI a Hamid NAZERZADEH, 2016. Optimizing Display Advertising Markets: Challenges and Directions. *IEEE Internet Computing* [online]. **20**(1), 28–35. ISSN 1941-0131. Dostupné z: doi:10.1109/MIC.2015.137
- KRUTIŠ, Michal, 2007. Co je to internetový marketing. *Michal Krutiš* [online] [vid. 2023-01-22]. Dostupné z: <https://www.krutis.com/co-je-to-internetovy-marketing/>
- KURZY.CZ, 2023. Roivenu s.r.o., Praha IČO 06812279 - Obchodní rejstřík firem | Kurzy.cz [online] [vid. 2023-01-16]. Dostupné z: <https://rejstrik-firem.kurzy.cz/06812279/roivenu-sro/>
- LEMON, Katherine N. a Peter C. VERHOEF, 2016. Understanding Customer Experience Throughout the Customer Journey. *Journal of Marketing* [online]. **80**(6), 69–96. ISSN 0022-2429. Dostupné z: doi:10.1509/jm.15.0420
- MARR, Bernard, 2015. *Big Data: Using SMART Big Data, Analytics and Metrics to Make Better Decisions and Improve Performance* [online]. New York, UNITED KINGDOM: John Wiley & Sons, Incorporated [vid. 2023-01-22]. ISBN 978-1-118-96578-8. Dostupné z: <http://ebookcentral.proquest.com/lib/techlib-ebooks/detail.action?docID=1895824>
- MARR, Bernard, 2021. *Data Strategy: How to Profit from a World of Big Data, Analytics and Artificial Intelligence*. B.m.: Kogan Page Publishers. ISBN 978-1-398-60259-5.
- NICHIFOR, Eliza, Radu Constantin LIXĂNDROIU, Ioana Bianca CHIȚU, Gabriel BRĂTUCU, Silvia SUMEDREA, Cătălin Ioan MAICAN a Alina Simona TECĂU, 2021. Eye Tracking and an A/B Split Test for Social Media Marketing Optimisation: The Connection between the User Profile and Ad Creative Components. *Journal of Theoretical and Applied Electronic Commerce Research* [online]. **16**(6), 2319–2340. ISSN 0718-1876. Dostupné z: doi:10.3390/jtaer16060128
- OFOEDA, Joshua, Richard BOATENG a John EFFAH, 2019. Application Programming Interface (API) Research: A Review of the Past to Inform the Future. *International Journal of Enterprise Information Systems (IJEIS)* [online]. **15**(3), 76–95. ISSN 1548-1115. Dostupné z: doi:10.4018/IJEIS.2019070105
- PAKKALA, H., K. PRESSER a T. CHRISTENSEN, 2012. Using Google Analytics to measure visitor statistics: The case of food composition websites. *International Journal of Information Management* [online]. **32**(6), 504–512. ISSN 0268-4012. Dostupné z: doi:10.1016/j.ijinfomgt.2012.04.008
- PICK, Tom, 2021. Webbiquity: B2B vs. B2C Influencer Marketing: The Single Biggest Difference. *Webbiquity [BLOG]* [online]. [vid. 2023-03-04]. Dostupné z: <https://www.proquest.com/docview/2501456444/citation/E484238FOA5F45E7PQ/1>
- QUEMY, Alexandre, 2020. Two-stage optimization for machine learning workflow. *Information Systems* [online]. **92**, 101483. ISSN 0306-4379. Dostupné z: doi:10.1016/j.is.2019.101483
- ROIVENU, 2022a. Aplikace Roivenu. *Dashboard - Roivenu 2.0*.
- ROIVENU, 2022b. *Interní dokumentace Roivenu*. 2022. B.m.: Roivenu.
- ROIVENU, 2022c. Webové stránky Roivenu. *Roivenu* [online] [vid. 2023-01-22]. Dostupné z: <https://roivenu.com/>
- ROMERO LEGUINA, Jesús, Ángel CUEVAS RUMÍN a Rubén CUEVAS RUMÍN, 2020. Digital Marketing Attribution: Understanding the User Path. *Electronics* [online]. **9**(11), 1822. ISSN 2079-9292. Dostupné z: doi:10.3390/electronics9111822
- SACCO, Robert, 2020. Another Great Step Towards Solving the Attribution Problem: Machine Learning RNNs. *Roivenu* [online]. [vid. 2023-01-22]. Dostupné

z: <https://library.roivenu.com/another-great-step-towards-solving-the-attribution-problem-machine-learning-rnns/>

SAWYER, Tom Y., 2015. Cost of Sales and Marketing Model: Calculate the Cost of Doing Business. In: Tom Y. SAWYER, ed. *Financial Modeling for Business Owners and Entrepreneurs: Developing Excel Models to Raise Capital, Increase Cash Flow, Improve Operations, Plan Projects, and Make Decisions* [online]. Berkeley, CA: Apress, s. 127–155 [vid. 2023-01-22]. ISBN 978-1-4842-0370-5. Dostupné z: doi:10.1007/978-1-4842-0370-5\_7

STAKE, Robert E., 1995. *The Art of Case Study Research*. B.m.: SAGE. ISBN 978-0-8039-5767-1.

TIETZ, Wendy, Tracie MILLER-NOBLES a Jennifer CAINAS, 2022. Teaching the Etl Process. *Strategic Finance*. **104**(2), 34–41. ISSN 1524833X.

TRUSKOWSKI, Wojciech, Rafał KLEWEK a Maria SKUBLEWSKA-PASZKOWSKA, 2020. Comparison of MySQL, MSSQL, PostgreSQL, Oracle databases performance, including virtualization. *Journal of Computer Sciences Institute* [online]. **16**, 279–284. ISSN 2544-0764. Dostupné z: doi:10.35784/jcsi.2026

