

UNIVERZA V LJUBLJANI  
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**IZBIRA USTREZNEGA ATRIBUCIJSKEGA MODELA PRI  
VEČKANALNEM SPLETNEM OGLAŠEVANJU**

Ljubljana, september 2021

MARKO NOVAK

## IZJAVA O AVTORSTVU

Podpisani Marko Novak, študent Ekonomske fakultete Univerze v Ljubljani, avtor predloženega dela z naslovom Izbira ustreznega atribucijskega modela pri večkanalnem spletnem oglaševanju, pripravljenega v sodelovanju s svetovalko izr. prof. dr. Matejo Kos Koklič

### IZJAVLJAM

1. da sem predloženo delo pripravil samostojno;
2. da je tiskana oblika predloženega dela istovetna njegovi elektronski obliki;
3. da je besedilo predloženega dela jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem poskrbel, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam oziroma navajam v besedilu, citirana oziroma povzeta v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani;
4. da se zavedam, da je plagiatorstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku Republike Slovenije;
5. da se zavedam posledic, ki bi jih na osnovi predloženega dela dokazano plagiatorstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom;
6. da sem pridobil vsa potrebna dovoljenja za uporabo podatkov in avtorskih del v predloženem delu in jih v njem jasno označil;
7. da sem pri pripravi predloženega dela ravnal v skladu z etičnimi načeli in, kjer je to potrebno, za raziskavo pridobil soglasje etične komisije;
8. da soglašam, da se elektronska oblika predloženega dela uporabi za preverjanje podobnosti vsebine z drugimi deli s programsko opremo za preverjanje podobnosti vsebine, ki je povezana s študijskim informacijskim sistemom članice;
9. da na Univerzo v Ljubljani neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve predloženega dela v elektronski obliki, pravico reproduciranja ter pravico dajanja predloženega dela na voljo javnosti na svetovnem spletu preko Repozitorija Univerze v Ljubljani;
10. da hkrati z objavo predloženega dela dovoljujem objavo svojih osebnih podatkov, ki so navedeni v njem in v tej izjavi.

V Ljubljani, dne 10.9.2021

Podpis študenta: \_\_\_\_\_

# KAZALO

<b>UVOD</b> .....	<b>1</b>
<b>1 POMEN PODATKOV V SPLETNEM OGLAŠEVANJU</b> .....	<b>3</b>
<b>1.1 Opredelitev spletnega oglaševanja</b> .....	<b>4</b>
<b>1.2 Podatkovno usmerjeno trženje</b> .....	<b>6</b>
1.2.1 Masovni podatki .....	6
1.2.2 Vrste podatkov o porabnikih .....	7
<b>1.3 Vpliv tehnološkega napredka na oglaševanje</b> .....	<b>8</b>
<b>2 ZBIRANJE PODATKOV O PORABNIKIH</b> .....	<b>9</b>
<b>2.1 Sledenje porabnikom znotraj naprav</b> .....	<b>9</b>
<b>2.2 Sledenje porabnikom med napravami</b> .....	<b>10</b>
2.2.1 Deterministične metode .....	11
2.2.2 Verjetnostne metode .....	11
<b>2.3 Zakonodaja in smernice pri zbiranju podatkov</b> .....	<b>12</b>
2.3.1 Uredba GDPR.....	12
2.3.2 Temeljne spremembe za podjetja .....	13
2.3.3 Vpliv privolitve na zbiranje in obdelavo podatkov .....	14
<b>3 OBDELAVA PODATKOV IN ATRIBUCIJA</b> .....	<b>14</b>
<b>3.1 Pristop k oblikovanju modela atribucije</b> .....	<b>15</b>
<b>3.2 Opredelitev atribucijskih modelov</b> .....	<b>16</b>
3.2.1 Poenostavljeni modeli .....	16
3.2.2 Modeli atribucije na podlagi pravil .....	17
3.2.3 Algoritemski modeli.....	19
<b>3.3 Omejitve in izzivi atribucijskih modelov</b> .....	<b>21</b>
<b>4 OBLIKOVANJE NAKUPNE POTI</b> .....	<b>22</b>
<b>4.1 Opredelitev nakupne poti</b> .....	<b>23</b>
<b>4.2 Sinergija med kanali</b> .....	<b>24</b>
<b>4.3 Napovedovanje korakov na nakupni poti</b> .....	<b>26</b>
<b>5 EMPIRIČNA RAZISKAVA ZBIRANJA PODATKOV IN IZBIRE MODELOV ATRIBUCIJE V SLOVENSКИH PODJETJIH</b> .....	<b>27</b>
<b>5.1 Namen in cilji raziskave</b> .....	<b>28</b>
<b>5.2 Raziskovalne hipoteze</b> .....	<b>28</b>

<b>5.3</b>	<b>Metodologija</b> .....	<b>30</b>
<b>5.4</b>	<b>Analiza rezultatov</b> .....	<b>32</b>
5.4.1	Značilnosti vzorca .....	33
5.4.2	Analiza po posameznih vprašanjih.....	33
5.4.3	Analiza hipotez.....	43
5.4.4	Interpretacija rezultatov hipotez.....	49
5.4.5	Ugotovitve raziskave.....	51
5.4.6	Implikacije za podjetja .....	52
5.4.7	Omejitve raziskave in priporočila .....	53
	<b>SKLEP</b> .....	<b>54</b>
	<b>LITERATURA IN VIRI</b> .....	<b>55</b>
	<b>PRILOGE</b> .....	<b>63</b>

## KAZALO TABEL

Tabela 1:	Vrste podatkov porabnikov .....	7
Tabela 2:	Opredelitev atribucijskih modelov .....	16
Tabela 3:	Velikost podjetij glede na število zaposlenih.....	33
Tabela 4:	Frekvence za test enake verjetnosti za H1a.....	44
Tabela 5:	Rezultati testa enake verjetnosti za H1a.....	44
Tabela 6:	Opisna statistika za T-test za en vzorec za H1b .....	45
Tabela 7:	Rezultati T-testa za en vzorec za H1b .....	45
Tabela 8:	Navzkrižna tabela: Atribucijski model in zbiranje podatkov.....	46
Tabela 9:	Rezultati za Hi-kvadrat test za H2.....	46
Tabela 10:	Opisna statistika T-test za neodvisna vzorca za H3 .....	47
Tabela 11:	Rezultati za T-test za neodvisna vzorca za H3.....	47
Tabela 12:	Opisna statistika T-test za neodvisna vzorca za H4 .....	48
Tabela 13:	Rezultati za T-test za neodvisna vzorca za H4.....	48
Tabela 14:	Rezultati za test deležev za H5 .....	49
Tabela 15:	Pregled ugotovitev preverjanja raziskovalnih hipotez .....	49

## KAZALO SLIK

Slika 1:	Poenostavljen primer Markovskega grafa .....	20
Slika 2:	Primer korakov v nakupni poti stranke .....	23
Slika 3:	Postopek odločanja o konverziji .....	27

Slika 4: Glavni nameni uporabe spletnega oglaševanja (v %) .....	34
Slika 5: Vrste plačljivih spletnih oglaševalskih kanalov (v %).....	35
Slika 6: Spremljanje uspešnosti oglaševalskih kanalov (v %) .....	35
Slika 7: Spremljanje uspešnosti in ovrednotenja oglaševalskih kanalov (v %) .....	36
Slika 8: Vrste trženjskih orodij (v %).....	37
Slika 9: Tehnologije zbiranja podatkov o porabnikih na spletem mestu (v %).....	38
Slika 10: Povezovanje porabnikov, ki obiščejo spletno mesto prek več naprav (v %) .....	39
Slika 11: Atribucijski modeli pri ovrednotenju doprinosov oglaševalskih kanalov (v %)....	40
Slika 12: Razlogi uporabe atribucijskih modelov (v %) .....	41
Slika 13: Glavni dejavnik pri izbiri modela atribucije (v %) .....	41
Slika 14: Mnenja podjetij o trenutnem načinu ovrednotenja oglaševalskih kanalov (v %) 42	
Slika 15: Razlogi, da podjetja ne vzpostavijo bolj dovršenega modela atribucije (v %) ....	43

## KAZALO PRILOG

Priloga 1: Vprašalnik .....	1
Priloga 2: Tabela hipotez in spremenljivk.....	7

## SEZNAM KRATIC

angl. – angleško

**AI** – (angl. Artificial intelligence); Umetna inteligenca

**CRM** – (angl. Customer Relationship Management); Upravljanje odnosov s strankami

**GDPR** – (angl. General Data Protection Regulation); Splošna uredba o varstvu podatkov

**IT** – (angl. Information Technology); Informacijska tehnologija

**ML** – (angl. Machine Learning); Strojno učenje

**MTA** – (angl. Multi-Touch Attribution); Atribucija z več dotiki

**SEO** – (angl. Search Engine Optimization); Optimizacija spletnih mest

**URL** – (angl. – (angl. Uniform Resource Locator); Enotni lokator virov



## UVOD

Digitalna oglaševalska revolucija, ki jo je povzročil prihod svetovnega spleta je močno zaznamovala način prikazovanja oglasov in zbiranja podatkov. Citat, pripisan Johnu Wanamakerju: »Vem, da je polovica mojega oglaševanja izgubljena, ne vem pa, katera polovica.«, ponazarja težave tradicionalnih tržnikov, ki se zavedajo, da je oglaševanje pomembno, vendar ne vedo, kateri del prinaša rezultate. Do teh zapletov prihaja predvsem pri ovrednotenju doprinosa oglaševalskih medijev zunaj spleta, kjer je zelo zahtevno spremljati izpostavljenost oglasom, ki jih vidijo posamezniki. Tržniki v teh primerih težko odkrijejo, ali je izdelek kupila ista oseba, ki je bila izpostavljena oglasom, ter nazadnje tudi, če lahko opazijo, da je nekdo videl oglas in nato kupil izdelek, ni jasno, da obstaja vzročna povezava med njima (Tucker, 2012).

Za tržnike digitalno okolje oziroma spletno oglaševanje prinaša mnoge prednosti. V spletnem oglaševanju se je uveljavila vrsta kanalov (družbena omrežja, pasice, spletni iskalniki, e-pošta), ki so sposobni učinkovitejšega dosega širšega ciljnega segmenta in natančnejšega merjenja uspešnosti kot tradicionalni mediji zunaj spleta. Obenem predhodne raziskave na področju oglaševanja nakazujejo, da s tem, ko so porabniki izpostavljeni oglasnim vsebinam preko različnih oglaševalskih kanalov, podjetjem prinašajo večjo vrednost, saj raznoliki kanali ponujajo edinstvene možnosti za prikaz vsebin. Iz tega razloga tržniki vedno več pozornosti namenjajo oglaševalskim strategijam, ki zajemajo kombinacijo spletnih kanalov (Jayawardane, Halgamuge & Kayande, 2015).

Vendar je uporaba več kanalov hkrati pri predstavitvi na spletu ustvarila nove izzive za tržnike. S tem, ko prikazovanje oglasnih vsebin podjetij praviloma poteka sočasno na več kanalih, je ovrednotenje prispevka posameznega kanala veliko težje (Nisar & Yeung, 2018). To predstavlja oviro za tržnike, ki potrebujejo podatke o pravi vrednosti kanalov za načrtovanje spletnih oglaševalskih kampanj, ki uspešno vodijo porabnika po nakupni poti. Porabniki pred konverzijo (tj. kupi izdelek, se prijavi na storitev ali izpolni obrazec) s podjetji komunicirajo prek nešteto stičnih točk v več kanalih, kar ima za posledico bolj zapletena potovanja strank. Vsaka interakcija porabnikov z večkanalno oglaševalsko kampanjo povzroča spremembe v vedenju in zaznavanju izdelka in/ali storitve. Tržniki želijo ob opravljeni konverziji vedeti, kateri kanali so vplivali na njihovo odločitev (Kaushik, 2012).

Razvoj tehnologije je podjetjem omogočil možnost za merjenje odziva porabnikov na vsakem koraku na nakupni poti (Li & Kannan, 2014). Spremljanje odzivov na izpostavljene oglasne vsebine in aktivnosti na spletnem mestu poteka s pomočjo spletnih analitičnih orodij in orodij za sledenje (Abhishek & Hosanagar, 2013). Spletna orodja za sledenje omogočajo neposreden vpogled v uspešnost posameznih kanalov še tekom aktivnosti oglaševalskih kampanj (Wiesel, Pauwels & Arts, 2011). Tržniki na podlagi zbranih podatkov o porabnikih

ustvarijo celoten tok zgodovine premikov med kanali. Te zbirke podatkov o nakupnih poteh porabnikov se analizirajo z uporabo spletnih orodij za merjenje in atribucijo ter omogočajo vpogled v natančnejše ocene učinkov oglaševalskih kanalov in tudi napovedovanje verjetnosti konverzije (Abhishek & Hosanagar, 2013).

Tržniki z namenom učinkovitejšega ovrednotenja oglaševalskih kanalov uporabljajo raznolike atribucijske modele (Wiesel, Pauwels & Arts, 2011). V oglaševanju je atribucija opredeljena kot merjenje vrednosti enemu ali več digitalnim kanalom, ki prispevajo k želenemu rezultatu/konverziji, kot npr. nakup, prenos, registracija (Jayawardane, Halgamuge & Kayande, 2015). Termin »atribucija« v povezavi z digitalnim oglaševanjem izvira iz zgodnjih dni ponudnikov spletne analitike, ko so tržniki dodelili prispevek za konverzijo z uporabo modela zadnjega klika. Za ta model atribucije velja, da dodeli prispevek zgolj enemu kanalu, kar v večkanalnem oglaševanju vodi k prekomerni uporabi spletnih kanalov, ki so uspešni zgolj zato, ker so na koncu porabnikove poti (Bowman, 2018).

Z zbiranjem vedno večjega števila podatkov o porabnikih tržniki izbirajo med bolj dovršenimi modeli atribucije, ki prepoznajo vlogo kombinacije oglaševalskih kanalov na porabnikovi nakupni poti (Jayawardane, Halgamuge & Kayande, 2015). Ti modeli predstavljajo konverzijo na spletnem mestu kot rezultat akumulacijskih učinkov vseh prejšnjih klikov ter tako tržnikom ponudijo bolj nepristranski pogled na učinkovitost, v primerih, ko usklajeno uporabljajo več oglaševalskih kanalov. Kljub temu pa raziskave nakazujejo, da le peščica tržnikov izkorišča ogromen potencial tehnologij za zbiranje podatkov o porabnikih in naprednih atribucijskih modelov za izboljšanje oglaševalskih aktivnosti v večkanalnem okolju (Chaffey & Patron, 2012).

**Namen** magistrskega dela je teoretično in empirično preučiti pomen izbire ustreznega atribucijskega modela za objektivno ovrednotenje relativnega prispevka enega ali več oglaševalskih kanalov, ki so vplivali na končno odločitev porabnika za konverzijo. **Cilj** magistrskega dela je s pomočjo podatkov empirične analize predstaviti pomen izbire ustreznega atribucijskega modela pri odkrivanju učinkovitosti posameznih oglaševalskih kanalov, vpogledu v vedenja porabnikov in oblikovanju nakupnih poti ter sprejemanja odločitev pri dodeljevanju finančnih sredstev med kanali.

Na podlagi teoretičnih izhodišč ter primarne kvantitativne raziskave v drugem delu magistrskega dela želim odgovoriti na zastavljena **raziskovalna vprašanja**:

- Kako mora podjetje pristopiti k zbiranju podatkov o porabnikih, da lahko izbere ustrezen atribucijski model?
- Kateri so najbolj učinkoviti modeli atribucije, ki ustrezno ovrednotijo prispevek posameznih oglaševalskih kanalov?
- Kateri podatki o porabnikih omogočajo podjetju natančnost modela atribucije in odkrivanje ključnih korakov na porabnikovi nakupni poti?



Magistrsko delo je razdeljeno na teoretični in empirični del. V teoretičnem delu bom s pomočjo deskriptivne metode in metode kompilacije opravil teoretično-analitični pregled vseh relevantnih sekundarnih podatkov, ki jih bom pridobil iz knjig, strokovnih revij, znanstvenih člankov, spletnih mest in statističnih portalov. Empirični del magistrskega dela temelji na kvantitativni raziskavi, ki sem jo izvedel s pomočjo spletnega anketnega vprašalnika, s katerim bom analiziral pomembne razlike med slovenskimi podjetji, ki oglašujejo na spletu, v načinu zbiranja podatkov in izbire atribucijskih modelov za merjenje učinkovitosti spletnih oglaševalskih kampanj.

Magistrsko delo je sestavljeno iz petih poglavij. V prvem poglavju so predstavljeni pomen podatkov v spletnem oglaševanju, podatkovno usmerjeno trženje in vpliv tehnološkega napredka na oglaševanje. V drugem poglavju se osredotočam na zbiranje podatkov o porabnikih, predvsem na tehnike zbiranja podatkov znotraj in med napravami, ter zakonodajo in smernice pri zbiranju podatkov. Tretje poglavje zajema opredelitev in pregled atribucijskih modelov ter njihovih omejitev. Četrto poglavje se osredotoča na oblikovanje nakupne poti in dinamiko med oglaševalskimi kanali. Peto poglavje vsebuje empirično raziskavo o zbiranju podatkov in izbiri atribucijskih modelov, v sklopu katere so predstavljeni problematika, namen in cilji raziskave, analiza rezultatov ter končne ugotovitve in predlogi za nadaljnje raziskave. Sklepno poglavje poda zaključno misel magistrskega dela.

## **1 POMEN PODATKOV V SPLETNEM OGLAŠEVANJU**

V današnji digitalni dobi je mogoče vsako aktivnost ljudi pretvoriti v podatke. Tehnologije prinašajo digitalno sled v najbolj vsakdanje dele življenja, kot so nakupi in komuniciranje na spletu. Dnevno se tako ustvari preko 2,5 kvintilijona bajtov podatkov, nepredstavlljivo velika količina, ki se bo v prihodnosti zgolj še povečala (West, 2019). Zbiranje podatkov o porabnikih v oglaševanju spreminja način, kako tržniki oblikujejo oglaševalske kampanje, raziskujejo ciljne segmente in odkrivajo potrebe svojih strank. Tržniki dnevno beležijo podatke o obiskih spletnih mest, zgodovini nakupov, poizvedbah v iskalnikih in aktivnostih v družbenih omrežjih. Na podlagi zbranih podatkov v nadaljevanju z obdelavo in analizo pridobijo koristne vpoglede v profil posameznega porabnika, vedenja strank na nakupni poti ter ocenijo učinkovitost oglaševalskih kanalov (Fitzgerald, 2019).

Oglaševalska industrija se je hitro odzvala na povečan doprinos zbiranja podatkov. S pomočjo tehnologij za sledenje porabnikovega premikanja med spletnimi mesti so tržniki pridobili veliko natančnejše podatke o uspešnosti oglaševalskih kampanj. Razvila se je vrsta analitičnih orodij, ki omogoča tržnikom, specializiranim za merjenje in atribucijo oglaševalske uspešnosti, da ocenijo in primerjajo relativno uspešnost različnih oglaševalskih kanalov na spletu ter občasno tudi zunaj njih (Tucker, 2012). Pridobljeni podatki porabnikov na spletu se hkrati zbirajo, združujejo in vnašajo v algoritme za napovedovanje vedenja

strank za različne trženjske namene, kot na primer za prikazovanje oglasov, avtomatizacijo trženjskih tehnologij, izboljšanje rezultatov iskanja in raziskave o porabnikih (West, 2019).

To poglavje se osredotoča na pomen digitalizacije podatkov v spletnem okolju za tržnike in prednosti, ki jih prinašajo podjetjem pri zbiranju, shranjevanju in analizi. V nadaljevanju bom v podpoglavjih opredelil spletno oglaševanje, v katerem bom podrobneje predstavil delitev oglaševalskih kanalov in njihovih medsebojnih vplivov na nakupni poti porabnika. Sledi predstavitev podatkovno usmerjenega trženja in vpliv področja masovnih podatkov ter napredka trženjskih tehnologij na dejavnost oddelka za trženje.

## **1.1 Opredelitev spletnega oglaševanja**

Spletno oglaševanje, znano tudi kot internetno oglaševanje ali digitalno oglaševanje, je trženjska strategija, ki vključuje uporabo interneta kot medija za pridobivanje prometa na spletnem mestu in omogoča ciljanje ter prikazovanje tržnih sporočil pravih strankam (Technopedia, 2018). Začetek spletnega oglaševanja zaznamuje objava prvega komercialnega spletnega oglasa v obliki pasice (angl. banner ad) leta 1994, naslovljenega na obiskovalce spletnega medija Hot Wired (Berthon, Pitt & Watson, 1996). Postopoma se z razvojem interneta veča tudi število kanalov za spletno oglaševanje, ki znatno razširijo prvotno omejeno zmožnost oglasnih pasic. Uveljavijo se novi kanali, kot npr. oglasi v iskalnikih, oglasi v pojavnih oknih in elektronska pošta. Tovrstne oblike omogočijo tržnikom, da začnejo učinkoviteje dosegati širši ciljni segment ob deležu stroškov, ki so povezani s tradicionalnimi mediji (Cho & Khang, 2006; Rappaport, 2007).

Naslednji mejnik v spletnem oglaševanju je danes prepoznan kot prihod t.i. spleta 2.0, ki uveljavi novo generacijo oglaševalskih kanalov. Inovativna spletna mesta omogočijo tržnikom enostavno interakcijo in deljenje vsebin s porabniki. Med njimi so ustanovljena tudi prva družbena omrežja, kot so Facebook, Twitter in YouTube, prek katerih se danes zaradi velikosti in učinkovitosti dosega širšega občinstva odvija spletno oglaševanje (Mariani, 2020; Tucker, 2012). Rast družbenih omrežij v povezavi z razvojem trženjskih tehnologij privede do številnih inovacij in priložnosti predvsem na področju spremljanja izpostavljenosti spletnemu oglaševanju in merjenja učinkovitosti oglaševalskih kanalov v realnem času za izboljšanje donosnosti naložb tržnikov (Todri, 2016).

Danes spletno oglaševanje velja za medij, ki raste najhitreje v zgodovini in je priljubljen zaradi svoje udobnosti in interaktivnosti. Združuje ga več komunikacijskih oblik, vključno s statičnimi ali animiranimi slikami, video posnetki in interaktivnimi animacijami, ki omogočajo globlje sodelovanje s porabniki. Oglasne vsebine temeljijo na osebnem pristopu in se prikazujejo na podlagi preferenc porabnikov ter so posledično bolj informativne in imajo večjo vrednost za porabnike. Struktura komunikacije v digitalnem svetu tržnikom omogoča, da izvedo veliko več o porabnikih, njihovih interesih in preferencah (Todri, 2016). Obenem podatki o porabnikih s strani oglaševalskih platform tržnikom omogočajo pomembne informacije o ciljnih segmentih kot tudi vpoglede v odzive na oglasne vsebine

za nadaljnjo optimizacijo oglaševalskih kampanj (Jayawardane, Halgamuge & Kayande, 2015).

Porabniki lahko spletna mesta podjetij obiskujejo bodisi neposredno bodisi posredno prek različnih spletnih kanalov. Med neposredni promet spadajo obiskovalci, ki samoiniciativno obiščejo spletno mesto podjetja. Ti po kliku pristanejo na spletnem mestu podjetja zaradi vnosa URL-ja v brskalnik, organskega iskanja na spletnih iskalnikih (npr. Google, Bing, Yahoo), napotitvene povezave ali shranjenega zaznamka. Med tem tržniki s prikazi oglasnih vsebin na spletnih kanalih posredno usmerjajo porabnike na spletna mesta podjetij. S porabniki na oglaševalskih platformah vzpostavijo komunikacijo, ki vodi do morebitne konverzije po kliku, na npr.: oglase v družbenih omrežjih, oglase v iskalnih omrežjih ali e-poštne povezave (Martin, 2009; Mulpuru, VanBoskirk, Evans & Roberge, 2011).

Spletno oglaševanje zaradi svoje učinkovitosti v zadnjem desetletju beleži izjemno rast. Leta 2019 je svetovna poraba za spletno oglaševanje dosegla 242 milijard EUR, kar predstavlja 46 % vseh izdatkov za oglaševanje (Raconteur, 2020). Vse večji oglaševalski proračuni za spletno oglaševanje nakazujejo na priljubljenost doseganja strank preko sodobnih oglaševalskih kanalov, ki se delijo na (Kakalejčik, Bucko, Resende & Ferencova, 2019):

- **Družbena omrežja** predstavljajo obiske porabnikov, ki so kliknili povezave, prikazane na družbenih omrežjih, kot npr: Facebook, Instagram, Twitter, YouTube, LinkedIn itd.
- **Iskalno oglaševanje** (angl. Search advertising) predstavljajo obiske porabnikov, ki so kliknili oglase v spletnem iskalniku na strani z rezultati iskanja (navadno z uporabo Google AdWords).
- **Prikazno oglaševanje** (angl. Display advertising) predstavlja obiske porabnikov, ki so na spletu videli oglasno pasico in s klikom nanje pristali na spletnem mestu podjetja (navadno z uporabo Google Display Network).
- **E-poštno oglaševanje** predstavlja obiske porabnikov, ki so s klikom na poziv k dejanju v prejeti pošti pristali na spletnem mestu podjetja.
- **Partnerske povezave** (angl. Affiliate links) predstavljajo obiske porabnikov, ki so s klikom na partnerjevo spletno povezavo (URL) obiskali spletno mesto podjetja.

Digitalna predstavitev izdelkov ali storitev na spletu omogoča tržnikom privabljanje ustreznih ciljnih segmentov preko različnih kanalov. V mnogih kategorijah stranke pred konverzijo večkrat obiščejo spletno mesto. Obisk spletnega mesta podjetja po posameznem kanalu (npr. spletno iskanje) strankam omogoči dodatne informacije o izdelku in/ali storitvi v primerjavi s konkurenčnimi ponudbami. Ta izkušnja z obiskom lahko vpliva na nadaljnje obiske spletnega mesta prek istega kanala pa tudi na morebitne konverzije po tem kanalu (tj. učinke prenosa v fazi obiska in nakupa). Podobno lahko vodi do obiskov in konverzij po drugih kanalih, na primer obisk preko družbenega omrežja lahko privede do poznejšega klikanja na oglasno pasico in morda do konverzije (tj. učinki prelivanja na stopnjah obiska in nakupa). Ti učinki se pogosto razlikujejo med kupcih, ki uporabljajo različne kanale in se

različno odzivajo na intervencije spletnega trženja (Mulpuru, VanBoskirk, Evans & Roberge, 2011).

## 1.2 Podatkovno usmerjeno trženje

Razvoj tehnologije ter sama številčnost podatkov porabnikov sta povzročila pomembne premike na področju trženja. Podatki so postali temeljni del trženjske in poslovne strategije podjetij. Čeprav obstaja več razlogov, zakaj se tržniki odločijo za podatkovno usmerjen pristop, je pogosto njihov glavni namen prilagoditi nakupno potovanje strank. Podatkovno usmerjeno trženje (angl. data-driven marketing) se nanaša na trženjske strategije, ki temeljijo na vpogledih, pridobljenih iz analize masovnih podatkov. Ti inteligentno pridobljeni podatki so zbrani s pomočjo interakcij s porabniki in oblikujejo napovedi o prihodnjem vedenju. Na podlagi tega pristopa tržniki pridobijo ključne informacije o potovanju strank, ki pomagajo oblikovati oglaševalske strategije, ki se nanašajo na posamezen ciljni segment (Cioffi, 2019).

Ustrezna uporaba podatkov lahko za podjetja, ki uporabljajo podatkovno usmerjeno trženje, predstavlja veliko konkurenčno prednost. To nakazuje tudi študija McKinsey, ki je razkrila, da ima 81 % hitro rastočih podjetij nadpovprečne ocene pri zbiranju in analizi podatkov (McKinsey, 2017). Navkljub temu da je mogoče trženje, ki temelji na podatkih, izvajati ločeno od širše organizacije ali te podatke deliti kasneje v procesu, bodo z operativnega stališča največji premiki vidni, v kolikor bo podjetje celostno pristopilo k digitalni preobrazbi. Zato je smiselno, da podjetja omogočijo dostop do podatkov tudi preostalim oddelkom v podjetju, ki bi želela uporabiti podobne podatke za druge namene (Taffs, 2018).

V nadaljevanju podpoglavja bom v okviru podatkovno usmerjenega trženja predstavil področje masovnih podatkov (angl. Big Data), ki ponujajo številne priložnosti pri zbiranju, shranjevanju in obdelavi podatkov. Temu sledi opredelitev vrst podatkov po viru pridobitve, ki so ključni za vodenje trženja na podlagi podatkov ter pripomorejo k boljšemu poznavanju porabnikov in oblikovanju nakupne poti.

### 1.2.1 Masovni podatki

Masovni podatki so obsežno in hitro razvijajoče se področje, ki ga tvori eksplozija priložnosti na področju tehnologij za zbiranje, shranjevanje in analizo obsežnih količin podatkov o porabnikih, podjetjih in drugih subjektih. Medtem ko analiza masovnih podatkov zahteva obvladovanje izzivov, povezanih s številnimi področji, kot sta obdelava podatkov in hiter dostop do podatkov, je razumevanje nastajajočega napredka in tehnologij na teh področjih ključnega pomena za doseg potenciala masovnih podatkov. Pri tem je mogoče področje masovnih podatkov v okviru trženja opredeliti na sledeče sklope (Ansari & Li, 2018):

- **Velikost** se nanaša na dejstvo, da številni tržni konteksti ustvarjajo velike zbirke podatkov, iz katerih si tržniki prizadevajo pridobiti uporabne vpoglede in napovedi.
- **Hitrost** generiranja podatkov v sodobnem svetu je izjemno hitra. Vsaka seja brskanja za tržnike pomeni nove informacije, tako o posameznem porabniku kot o celotnem segmentu.
- **Raznolikost** se nanaša na vrste zbranih podatkov, ki niso vedno zgolj v obliki števil. Tržniki morajo tako na primer razbrati uporabne informacije iz mnenj o izdelkih ali vedenj na družbenih omrežjih in jih v obdelavi pretvoriti v ustrezne zbirke podatkov.
- **Verodostojnost** se nanaša na izzive, ki izhajajo iz načina združevanja masovnih podatkov iz različnih virov. Podatke morajo tržniki v analizi ustrezno združiti glede na načine zbiranja in kakovost, da pridobijo pomembne vpoglede.

Tržnikom v raznolikih panogah digitalizacija podatkov ponuja vse več priložnosti za rast poslovanja in avtomatizacijo. Zaradi same obsežnosti intelektualnega področja masovnih podatkov je mogoče skozi posamezno panogo pridobiti le omejeno razumevanje (Ansari & Li, 2018). Na podlagi masovnih podatkov in njihove analize se spreminja, kako podjetja pristopajo k pridobivanju znanj o porabnikih in oblikovanju nakupne poti. Drastičen napredek na področju informacijske tehnologije (IT) z naprednimi algoritmi, ki jih poganja umetna inteligenca (AI), in sistemi strojnega učenja (ML) izboljšuje načine za hitrejšo in natančnejšo uporabo zbranih podatkov (Iafrate, 2018). Tržniki lahko z razumevanjem zbranih podatkov in njihovega pomena za podjetje ustvarijo dodeljeno področje za inovativne rešitve, ki bodo izboljševale uporabniške izkušanje s pomočjo analitičnih metod (Hurstinen, 2020).

## 1.2.2 Vrste podatkov o porabnikih

Podatki so postali temeljni del sodobnega trženja, vendar ker se vedno več podatkov zbira iz različnih virov, postaja upravljanje teh podatkov bolj zapleteno (Cioffi, 2019). Hkrati so podatki o porabnikih pogosto različnih oblik, velikosti in se razlikujejo po kakovosti. Zato morajo tržniki razlikovati med ustreznostjo podatkov in preveriti njihovo kakovost ter se nanje zanašati premišljeno (Taffs, 2018). V tabeli 1 so prikazane vrste podatkov porabnikov glede na vir pridobitve, ki jih je mogoče ločiti na: lastne, deljene in tuje podatke.

*Tabela 1: Vrste podatkov porabnikov*

Vrsta	Opredelitev	Vir pridobitve
1. oseba	Lastni	CRM, piškotki
2. oseba	Deljeni	Partnerski podatki
3. oseba	Tuji	Podatki analitičnih podjetij

*Prirejeno po Taffs (2018).*

Tržniki praviloma namenijo največjo vrednost lastnim virom, ti so lahko iz CRM-aktivnosti, kot npr. podatki iz programov zvestobe ter klicnih centrov. Medtem lahko podjetje pridobi

podatke tudi s pomočjo sledilne tehnologije na spletnem mestu, kot npr. z uporabo piškotkov in sledilnih oznak. Ker je v nekaterih primerih obseg lastnih podatkov majhen in zahteva povečanje, se podjetja odločijo za pridobivanje podatkov s strani druge ali tretje osebe. To najpogosteje velja za podjetja, ki nimajo neposredne prodaje porabnikom, in tista, ki delujejo v kategorijah z majhnim zanimanjem. V primeru druge osebe gre za pridobivanje podatkov s strani partnerskega podjetja, medtem ko gre v primeru tretje osebe običajno za analitična podjetja, ki prodajajo informacije o strankah in podjetjih. Pri slednjih je pomemben tudi vpogled v kakovost in ustreznost podatkov ter skladnost z zakonodajo na področju varstva podatkov o porabnikih (Taffs, 2018).

### **1.3 Vpliv tehnološkega napredka na oglaševanje**

Spletno oglaševanje je prešlo v novo dimenzijo, ki temelji na trženjskih tehnologijah (angl. Marketing technology), ki vključuje strategije, rešitve in tehnološka orodja za doseganje trženjskih ciljev. Dejavnosti trženjskih oddelkov tako so bolj kot kdaj koli prej odvisne od vpeljave tehnoloških platform in orodij, namenjenih doseganju porabnikov na zelo dinamičnem in konkurenčnem trgu. Trženjska tehnologija temelji na konceptu avtomatizacije trženja in umetne inteligence ter je predstavljena kot priložnost za rast vsakega podjetja, ki jo uporablja (Baltes, 2017).

Uporaba tehnoloških orodij za trženje bistveno spreminja dejavnost oddelka za trženje in tudi način, kako se nanaša na stranke ter vodi poslovanje. Podjetjem omogoča, da enostavneje prepoznajo svoje potencialne porabnike, preučijo njihovo vedenje in jim v nadaljevanju zagotovijo prilagojeno vsebino in storitve. Sodobna orodja za trženje med drugim tržnikom omogočajo (Baltes, 2017):

- analizo vedenja obiskovalcev, kot npr. z vpogledom v Google Analytics;
- orodja za spremljanje vedenj obiskovalcev na spletnem mestu podjetja in prilagajanje vsebine spletnega mesta glede na iskanja ali zanimanja;
- upravljanje e-poštnih kampanj s samodejnim prilagajanjem vsebine na podlagi vedenj obiskovalcev;
- inteligentne spletne obrazce, ki bodo samodejno izpolnjevani z že znanimi informacijami o obiskovalcih;
- samodejno obveščanje tržne ekipe v primeru priložnosti;
- samodejno posodobitev seznama stikov v podatkovnih zbirkah.

Tehnološka orodja za trženje so zelo raznolika in napredna ter zajemajo vse večji del trženjskih aktivnosti. Pogosto je širok nabor orodij s trženjsko tehnologijo integrirano v eno samo platformo, kar omogoča zelo dobro organizacijo in preglednost nad različnimi trženjskimi aktivnostmi (Wright, 2016). To bistveno povečuje učinkovitost dela tržnikov in prispeva k bolj opredeljeni in ciljno usmerjeni dejavnosti, ki se neposredno odziva na potrebe in zanimanja porabnika. Uporaba trženjskih tehnologij se med podjetji zelo razlikuje in je

odvisna tako od finančnih sredstev ter velikosti podjetja kot tudi od sposobnosti strokovnjakov za vpeljavo trženjskih tehnologij v podjetja (Baltes, 2017).

## 2 ZBIRANJE PODATKOV O PORABNIKIH

Zbiranje osebnih podatkov o porabnikih bi lahko v današnjem digitalnem gospodarstvu označili za ekonomsko sredstvo oziroma celo za novo obliko plačilnega sredstva v razmerju do ponudnikov digitalnih vsebin ali storitev (Renko, 2019). Vedno več spletnih vsebin temelji na zbiranju in obdelavi osebnih podatkov, ki jih na primer porabnik zagotovi ob registraciji v spletni aplikaciji, nakupu v spletni trgovini ter tekom uporabe drugih digitalnih storitev (Hoofnagle & Whittington, 2014). Tržniki zbrane podatke pogosto uporabljajo kot orodje za izboljšanje storitev in proizvodov, za izdelavo profila porabnika, prepoznavanje vedenjskih vzorcev in ovrednotenje učinkovitosti oglaševalskih kanalov v večkanalnem okolju (Anderl, Becker, Wangenheim & Schumann, 2013).

Poznavanje premikanja porabnikov na podlagi zbranih podatkov je bistvenega pomena za optimalno delovanje atribucijskega modela in merjenje učinkovitosti kanalov spletnega oglaševanja. S tem namenom je v prvem delu poglavja predstavljen pregled metod sledenja porabnikom znotraj naprav ter med napravami, ki tržnikom omogočajo vpogled v vedenja na ravni porabnika. Drugi del poglavja opisuje ključne vidike splošne uredbe o varstvu podatkov – GDPR, ki je bila sprejeta zaradi vse večjega poseganja v zasebnost osebnih podatkov porabnikov.

### 2.1 Sledenje porabnikom znotraj naprav

Spletni oglaševalski kanali skupaj z napredkom tehnologij za sledenje in razvojem oglaševalskih orodij ponujajo edinstvene zmožnosti za reševanje spletne atribucije (Li & Kannan, 2014). Z beleženjem in združevanjem obiskov porabnikov na spletnem mestu podjetja je mogoče ustvariti pot klikov, ki se približa posameznikovi spletni prisotnosti (Nottorf & Funk, 2013). Najpogostejše metode sledenja porabnikov pri tem vključujejo (Tucker, 2012):

- **Piškotek** (angl. Cookie): to je edinstven identifikator, ki se shrani v spletnemu brskalniku, ko porabnik prvič obišče spletno mesto. Vsebuje podrobnosti o vedenju in zgodovini spletnega brskanja, kot npr. shranjeni podatki za prijavo ali izdelki v nakupovalnem vozičku.
- **Sledilne oznake** (angl. Tracking tags): to so delčki kode, dodani spletnemu mestu, ki informacije o porabniku pošljejo neposredno strežniku. Omogočajo zbiranje podatkov o porabnikih, ki obiščejo spletno mesto, kot npr.: sledenje porabnikovih aktivnosti med sejo, beleženje značilnosti naprav itd.

Sledenje porabnikom na spletnem mestu omogoča tržnikom, da z unikatnim identifikatorjem zabeležijo celotno zgodovino obiskov porabnika ter morebitni končni dogodek konverzije. Podatki za vsak obisk spletnega mesta podjetja v opazovanem obdobju vključujejo pomembne informacije o: porabnikovem ID-ju, viru klika in času obiska. Viri klikov predstavljajo premik s kanalov spletnega oglaševanja na spletno mesto ali rezultat neposrednega prihoda na spletno mesto, kot npr. vnos URL-ja v spletni brskalnik. Te premike med kanali tržniki obravnavajo pri oblikovanju potovanj strank s tem, ko opisujejo pot klikov porabnikov oz. njihovo nakupno vedenje. Tržniki pri tem sledijo tako uspešnim potovanjem, ki se končajo s konverzijo, kot tudi potovanjem, ki nikoli ne vodijo do konverzije (Danaher & Dagger, 2013).

Zbiranje podatkov tradicionalno poteka na ravni piškotkov, kar omogoča, da tržniki prepoznajo posamezne porabnike – ali natančneje posamezne naprave. Piškotek se v brskalniku shrani kot besedni niz in se ob zaporednih obiskih spletnega mesta pošlje nazaj strežniku. Zbirke podatkov o porabnikovih piškotkih omogočajo združevanje zgodovin obiskov opazovanega spletnega mesta. Čeprav piškotki veljajo za najpogostejšo metodo združevanja zgodovin obiskov, imajo več slabosti. Med drugim onemogočanje s strani porabnikov in brskalnikov, nezmožnost sledenja uporabe med napravami in pristranskost zaradi brisanja piškotkov. S tem ko se piškotki v brskalniku izbrišejo, spletna mesta prepoznajo porabnike, ki se vračajo, kot nove porabnike (Flosi, Fulgoni & Vollman, 2013). Obenem piškotkov ni mogoče enostavno razlikovati med več porabniki, v kolikor si delijo isto napravo ali v primeru, ko več naprav pripada istemu porabniku (Jayawardane, 2019).

Z namenom, da bi se preprečile omejitve piškotkov, se predlaga novejša metoda sledenja, poznana tudi kot »zbiranje prstnih odtisov naprave« (angl. device fingerprinting). Tržniki na ta način na spletno mesto podjetja vstavijo majhen delček kode, ki zajame prstni odtis naprave. Ta metoda omogoča identifikacijo posameznih naprav porabnikov na podlagi edinstvenih lastnosti naprav, kot npr. operacijski sistem, različico spletnega brskalnika, velikost zaslona, IP-naslov, jezik itd. (Eckersley, 2010). Prstnih odtisov v napravi v nasprotju s piškotki ni mogoče izbrisati, ker so podatki shranjeni na strežniku. Vendar morebitne spremembe v brskalniku (npr. namestitve, posodobitev ali odstranitev vtičnikov) ustvarijo povsem drugačen prstni odtis brskalnika. Obenem podobno kot piškotki tudi s »prstnim odtisom« ne moremo razlikovati med več porabniki, ki si delijo isto napravo in več naprav, ki pripadajo istemu porabniku (Jayawardane, 2019).

## **2.2 Sledenje porabnikom med napravami**

V času digitalizacije so se navade porabnikov s hitrim razvojem prenosnih digitalnih naprav močno spremenile. Porabniki se za izvajanje spletnih aktivnosti premikajo med več napravami, kot so npr. prenosniki, pametni telefoni in tablični računalniki. Tako so ogledi oglasov in obiski spletnih mest istega porabnika razdrobljeni med več naprav. Ker več naprav, ki pripadajo istemu porabniku, nimajo trajnega identifikatorja, se le-te šteje za ločene



porabnike (Jayawardane, 2019). To je trenutno pomemben tehnološki izziv, ker so lahko te informacije izjemno dragocene za tržnike zaradi možnosti prikazovanja ciljanega oglaševanja porabnikom ne glede na napravo. Hkrati je identifikacija porabnika med napravami bistvenega pomena za pridobivanje verodostojnih podatkov o premikih porabnika na nakupni poti, ki so ključni za natančne ocene modelov atribucije (Morales, 2015).

Cilj sledenja med napravami je s pomočjo skupnega identifikatorja odkriti, ali je bila npr. oseba, ki vidi prikazni oglas na izbranem računalnik, hkrati ista oseba, ki je uporabljala opazovani mobilni telefon ali tablični računalnik, ko je s klikom na oglas v iskalnem omrežju obiskala spletno mesto. Tržniki na podlagi skupnega identifikatorja v različnih napravah pridobijo vpogled v nakupno pot porabnika kot tudi v njihova pogosta vedenja in lastnosti. Metode, ki se uporabljajo za združevanje več naprav v skupni identifikator porabnika, se delijo na deterministični in verjetnostni pristop. Deterministične metode pri združevanju naprav uporabljajo osebno določljive podatke, medtem ko verjetnostne metode uporabljajo anonimne informacije o lastnostih naprav porabnika, ki najverjetneje pripadajo istemu porabniku (Morales, 2015). V nadaljevanju predstavljam trenutne rešitve za obravnavo identifikacije porabnikov med napravami na podlagi determinističnega in verjetnostnega pristopa.

### 2.2.1 Deterministične metode

Deterministične metode (angl. Deterministic methods) uporabljajo osebne identifikatorje (npr. ime, e-poštni naslov, telefonska številka) za povezovanje porabnikov s specifičnimi identifikatorji naprav, kot npr. ID-mobilne naprave (IAB, 2016). V primeru, ko se porabnik z e-poštnim naslovom najprej prijavi v spletno trgovino s prenosnika in nato z mobilne naprave, se v zbirki podatkov osebni identifikator poveže z ID-jem naprave v skupno identiteto porabnika. Deterministične metode veljajo za zelo učinkovite predvsem v podjetjih, ki imajo dostop do velike količine podatkov, ki jih najpogosteje zahtevajo od porabnikov ob dostopu do svojih uporabniških računov. Čeprav veljajo deterministične zbirke podatkov za zelo natančne, lahko v nekaterih primerih, ko se porabnik prijavi v račun s tujega računalnika, vsebujejo pretekle ali napačne informacije. Hkrati je mogoče do ID-jev mobilnih naprav dostopati samo prek mobilnih aplikacij in jih ni mogoče dobiti z mobilnega spleta. Obenem lahko porabniki zaradi pomislekov glede svoje zasebnosti ponastavijo ID-je ali se ob prijavi v aplikacijo odločijo, ali izrecno dovoljujejo sledenje oglaševalcem (Jayawardane, 2019).

### 2.2.2 Verjetnostne metode

Verjetnostne metode (angl. Probabilistic methods) veljajo za naprednejše metode sledenja med napravami, ki z reševanjem zapletenih algoritmov sklepajo o napravah, ki najverjetneje pripadajo istemu porabniku. Na podlagi anonimnih informacij se tako na primer ugotavlja, ali

dve napravi, ki imata večkrat enak IP-naslov, pripadata istemu porabniku, saj do interneta dostopata prek istega usmerjevalnika. Za povečanje verjetnosti se uporabljajo tudi drugi podatki, kot npr. geolokacija za identifikacijo fizične lokacije obeh naprav. Vendar tudi povezava med naslovi IP in geolokacijo ne zagotavlja, da obe napravi pripadata istemu porabniku. Razlog za to je, da lahko več naprav, ki pripadajo različnim porabnikom, uporablja isto omrežje v kavarni. Zato verjetnostne metode uporabljajo številne informacije, kot sta npr. konfiguracija naprav in vzorci brskanja, za določanje povezanih naprav v zapletenih scenarijih (Jayawardane, 2019).

Verjetnostne metode pri identifikaciji porabnikov med več napravami temeljijo na podatkih z več spletnih mest, ki so pogosto na voljo zgolj analitičnim podjetjem. Za oblikovanje verjetnostnih modelov analitična podjetja uporabljajo že zbrane usklajene naprave ali pa temeljijo na determinističnih podatkih. Verjetnostne metode so v primerjavi z determinističnimi metodami bolj prilagodljive, vendar je njihova natančnost pogosto vprašljiva, ker analitična podjetja javno ne delijo podatkov o algoritmičnih združevanju naprav. Tako se lahko morebitne netočnosti verjetnostnih metod razširijo na poznejše atribucijske modele, ki temeljijo na njihovih podatkih. Hkrati so zaradi komercialne vrednosti in občutljive narave zgodovine obiskov akademske študije o identifikaciji porabnikov med napravami z uporabo verjetnostnih metod zelo redke, zato je razumevanje delovanja v praksi omejeno (Jayawardane, 2019).

## **2.3 Zakonodaja in smernice pri zbiranju podatkov**

Ob vedno širšem naboru digitalnih vsebin in storitev, s katerimi se dandanes sooča povprečni porabnik, in pri uporabi katerih pušča na spletu svoj »podatkovni odtis«, postaja varstvo osebnih podatkov porabnikov pred zlorabo pereč problem (Renko, 2019). Tržniki podatke, ki jih zagotovi porabnik, pogosto ali celo praviloma izrabljajo za oblikovanje profila strank in prepoznavanje vedenjskih vzorcev. Na podlagi zbranih podatkov nato s pomočjo algoritmov izvajajo personalizirano oglaševanje in tako vplivajo na odločitve porabnika v prihodnosti. To lahko postane sporno, ko je tovrstno profiliranje porabnikov uporabljeno npr. za personalizirano določanje cen digitalnih vsebin in storitev, kar vodi v cenovno diskriminacijo porabnika (Borgesius, 2016).

V nadaljevanju podpoglavja obravnavam uredbo GDPR in njen pomen pri varstvu osebnih podatkov. Sledi predstavitev ključnih sprememb za podjetja za zbiranje, shranjevanje in varovanje podatkov porabnikov ter vpliv privolitve na zbiranje in obdelavo podatkov.

### **2.3.1 Uredba GDPR**

Odraž vedno večjega poseganja v zasebnost osebnih podatkov porabnikov je ureditev jasnega pravnega okvirja in posledično instrumentov za spoštovanje pravil o zakoniti obdelavi in zbiranju osebnih podatkov porabnikom. To je ključno med drugim zaradi

zmanjšanja negotovosti porabnikov glede njihovih ključnih pogodbenih pravic v tovrstnih oblikah koriščenja digitalnih vsebin in storitev ter s tem tudi posledično povečanja njihovega zaupanja pri izvajanju raznolikih aktivnosti prek spleta (Janal, 2017). Na ravni primarnega prava EU obseg pravic do varstva osebnih podatkov natančneje ureja čl. 8 Listine o temeljnih pravicah EU, ki v drugem odstavku določa, da se morajo osebni podatki obdelovati pošteno, za določene namene in na podlagi privolitve prizadete osebe ali na drugi legitimni podlagi, določeni z zakonom. Nadalje določa, da ima vsakdo pravico dostopa do podatkov, zbranih o njem, in pravico zahtevati, da se ti podatki popravijo (Langhanke, 2015).

Na predpostavkah čl. 8 Listine gradi tudi Splošna uredba o varstvu podatkov – GDPR, ki je v veljavo stopila maja 2018. Gre za osrednji ter najpomembnejši pravni akt EU na področju varstva osebnih podatkov in ureja: mehanizme varstva osebnih podatkov, pogoje, pod katerimi je obdelava slednjih dopustna, ter ukrepe za izvrševanje teh mehanizmov. Njen cilj je omogočiti posameznikom nadzor nad njihovimi osebnimi podatki in poenotiti ter dvigniti raven varstva osebnih podatkov v EU (Loos in drugi, 2011).

### 2.3.2 Temeljne spremembe za podjetja

Ureditev varstva osebnih podatkov v Evropski uniji za zaščito zasebnosti porabnikov predstavlja resne izzive in omejitve za tržnike. GDPR daje porabnikom pravico, da preprečijo neovirano deljenje in prodajo informacij o njih, vključno s piškotki, zgodovino brskanja po spletu, naslovi IP in zgodovino iskanja. Veliko od teh podatkov je ključnih za tržnike in raziskovalno industrijo za načrtovanje in uporabo učinkovitih strategij oglaševanja na ravni porabnikov (Fulgoni, 2018).

Uredba GDPR je osredotočena na to, kako tržniki zbirajo, shranjujejo in varujejo osebne podatke o strankah. V nadaljevanju so predstavljena ključna pooblastila za skladnost z GDPR, ki jih morajo podjetja upoštevati (Cioffi, 2019):

- **Odgovornost in upravljanje:** vodenje ustrezne dokumentacije o dejavnostih obdelave podatkov in izvajanje ukrepov, ki dokazujejo skladnost, npr. revizije.
- **Omejitev hrambe:** osebnih podatkov ni dovoljeno hraniti dlje, kot je potrebno za namene, za katere so bili prvotno pridobljeni.
- **Obvestila o zlorabi:** pomembne kršitve je treba prijaviti pristojnemu nadzornemu organu v 72 urah po tem, ko je podjetje za njo izvedelo.
- **Individualne pravice:** posameznik lahko zahteva izbris ali odstranitev osebnih podatkov, če ni nobenega prepričljivega razloga za nadaljnji obstoj.

Sprejem uredbe GDPR vpliva na zmanjšanje števila piškotkov na spletnih mestih in natančnejšo opredelitev zbiranja, saj so tržniki zaradi zahtev po skladnosti bolj omejeni pri zbiranju in uporabi podatkov o porabnikih. Na to kažejo tudi rezultati raziskave, ki potrjuje, da se je od uveljavitve uredbe GDPR število piškotkov tretjih oseb, najdenih na spletnih mestih z novicami, zmanjšalo za 22 % (Libert, Graves & Nielsen, 2018).

### 2.3.3 Vpliv privolitve na zbiranje in obdelavo podatkov

Eden pomembnejših vidikov uredbe GDPR daje prebivalcem EU pravico do odločitve, v kolikor želijo privoliti v delitev podatkov. To soglasje lahko kasneje prekličejo in odredijo uničenje svojih osebnih podatkov, ki ga morajo podjetja upoštevati. V preteklosti so se osebni podatki pogosto zbirali brez privolitve, ko so posamezniki npr. obiskali spletno mesto, izpolnjevali obrazce ali sodelovali v nagradni igri. Predvsem uporaba družbenih omrežij in mobilnih aplikacij je tržnikom omogočila, da osebne podatke pridobijo na veliko bolj posredne načine brez vednosti porabnika. Vedno večji problem prikritega zbiranja osebnih podatkov je navsezadnje pripeljal do uredbe GDPR in pomembnejših sprememb na področju privolitev, sprejemljivosti profiliranja in avtomatiziranega odločanja (Cioffi, 2019).

Posamezniki pred sprejetjem uredbe GDPR velikokrat niso imeli vpogleda v obseg in širino zbiranja, analiziranja in rabe njihovih podatkov. Spremembe, ki jih prinaša uredba, zahtevajo od podjetij, da z osebnimi podatki strank ravna veliko bolj profesionalno in izpolnjujejo zakonite pogoje za skladnost. Tržniki morajo med drugim posameznike obveščati o politiki zasebnosti na spletnem mestu in evidentirati zbirke podatkov, ki se uporabljajo na področju trženja. To močno vpliva na način razmišljanja tržnikov o pridobivanju in ravnanju s podatki. Tržniki lahko odslej zakonito uporabijo zgolj podatke za namene, v katere privolijo porabniki, kot npr. privolitev izbranih piškotkov na spletnem mestu ali sodelovanje v nagradni igri. To za tržnike predstavlja kar nekaj preglavic, saj je bila običajna praksa, da se podatkovne zbirke uporabljajo za več namenov (Cioffi, 2019).

## 3 OBDELAVA PODATKOV IN ATRIBUCIJA

Podjetja za doseganje poslovnih ciljev praviloma usklajeno uporabljajo več oglaševalskih kanalov. Za objektivno dodelitev prispevka za konverzije vsakemu od teh kanalov je potrebno ovrednotenje njihove relativne vloge na nakupni poti porabnika. Uporaba tradicionalne metode, kot npr. ponakupne ankete strank, so pogosto neustrezne, saj stranke težko prepoznajo vse tržne poti, ki so jih uporabljale na nakupni poti (Clifton, 2015; Shao & Li, 2011). Razvoj dovršenih modelov atribucije je omogočil tržnikom, da natančneje ocenijo uspešnost nakupnih poti ter da se prispevek za konverzijo dodeli ustreznim oglaševalskim kanalom (Ferencova, Jelenova & Kakalejčik, 2015). Uporaba modelov atribucije tržnikom pomaga optimizirati dodelitev tržnega proračuna, zagotovi natančnejše načrtovanje tržnih kampanj in poveča natančnost izračuna cene oglasnega prostora (Kakalejčik, Bucko, Resende & Ferencova, 2019).

Tržnikom atribucijski modeli pri večkanalnem spletnem oglaševanju prinašajo številne prednosti. Z uporabo modelov atribucije tržniki dostopajo do podatkov o uspešnosti oglaševalski kanalov kot tudi do medsebojnih učinkov med kanali (npr., kako prikazno oglaševanje vpliva na iskalna omrežja). S temi informacijami tržniki pridobijo boljše

razumevanje in vpoglede, ki jih lahko izkoristijo za podatkovno usmerjeno prilagajanje strategij oglaševanja in odločanje o dodelitvi proračunov. Obenem tržniki na podlagi rezultatov atribucije spreminjajo oglaševalske strategije, kot so zaporedja kanalov ali oblike in umestitve oglaševalskih kampanj. Pri tem lahko tržniki izkoristijo storitve različnih partnerjev, od strokovnjakov za atribucijo in ponudnikov spletnih analiz do oglaševalskih agencij, ponudnikov trženjskih storitev kot tudi ponudnikov spletnih platform za upravljanje podatkov (IAB, 2012).

To poglavje se osredotoča na pomen izbire ustreznega atribucijskega modela, s pomočjo katerega tržniki pridobijo pomembne vpoglede o uspešnosti posameznih oglaševalskih kanalov. V nadaljevanju poglavja bom predstavil splošen pristop k oblikovanju modela atribucije, ki omogoča tržnikom, da analizirajo podatke in pridobijo koristne vpoglede. Sledi opredelitev kategorij atribucijskih modelov. Slednji se v akademski literaturi delijo na poenostavljene, delne, ki temeljijo na pravilih, in delne algoritemske. V samem zaključku poglavja bom predstavil trenutne omejitve atribucijskih modelov in izzive, s katerimi se soočajo tržniki.

### **3.1 Pristop k oblikovanju modela atribucije**

Cilj vzpostavitve modela atribucije je slediti, kako porabnik komunicira z različnimi oglaševalskimi kanali in kakšna dejanja izvede po vsaki izpostavljenosti oglasu. V idealnem primeru zbiranje podatkov poteka na ravni obiskovalca. Pri podatkih na spletnem mestu podjetja se to zbiranje običajno opravi z orodji za sledenje na osnovi sledilnih oznak in piškotkov. Vsak obisk spletnega mesta podjetja v obdobju opazovanja vključuje informacije o viru klika, času prihoda ter osebni identifikator (IAB, 2012). Ti podatki se uporabljajo za oblikovanje nakupnih potovanj strank, ki opisujejo vzorec klikov porabnikov v vseh kanalih spletnega trženja in njihovo nakupno vedenje. Pri tem se podatki beležijo tako za uspešna potovanja, ki se končajo s konverzijo, kot tudi za potovanja, ki nikoli ne vodijo do konverzije, v izbranem časovnem obdobju, kot npr. 30 dni od zadnje izpostavljenosti (Anderl, Becker, Wangenheim & Schumann, 2013).

Podatki o tržni uspešnosti kanalov in konverzijah se zbirajo, očistijo in razvrstijo v orodjih za spletno analitiko, kot npr. Google Analytics. Organizirajo se tako, da sestavijo pregled nad zgodovino potovanj vseh obiskovalcev. Tržniki v nadaljevanju s ponudniki spletne tržne analitične tehnologije ali programske opreme za analitiko oblikujejo ali izberejo enega ali več obstoječih modelov atribucije. Podatkovna zbirka potovanj obiskovalcev se nato obdela z izbranim atribucijskim modelom. Na podlagi sklopa pravil izbranega atribucijskega modela se prispevek za konverzijo dodeliti na ravni kanalov ali na ravni posameznih oglaševalskih kampanj. Tržniki nato s pomočjo vpogledov in podatkov iz analiz atribucije pristopijo k odločanju in služijo kot dodatni viri v operativne procese, kot je npr. prilagoditev oglaševalskega proračuna v realnem času (IAB, 2012).

## 3.2 Opredelitev atribucijskih modelov

Atribucijski modeli omogočajo tržnikom ovrednotenje relativnega prispevka na enega ali več oglaševalskih kanalov, ki so vplivali na končno odločitev porabnika za nakup. Tako oglaševalska industrija kot akademska literatura sta skozi čas razvili vse bolj natančne modele, ki prepoznajo kombinacijo spletnih oglaševalskih aktivnosti, ki vodijo do visokih stopenj konverzij na spletnih mestih (Manchanda, Dubé, Goh & Chintagunta, 2006; Moe & Fader 2004). Ti modeli predstavljajo celoten tok zgodovine klikov posameznih obiskovalcev kot rezultat akumulacijskih učinkov vseh prejšnjih klikov, ki lahko natančneje ocenijo učinke oglaševalskih kanalov in napovejo verjetnost konverzije (Xu & Whinston, 2014).

Kot je razvidno iz tabele 2, so atribucijski modeli v literaturi razvrščeni v 3 kategorije. Modeli se delijo na: poenostavljene (angl. Simplistic), ki dodelijo celoten prispevek konverzije enemu kanalu; delne – na podlagi pravil (angl. Rule-based), ki dodelijo ovrednoteni prispevek za konverzije več kanalom na podlagi intuitivnih pravil; in delne – algoritemске (angl. Algorithmic), ki dodelijo ovrednoteni prispevek na podlagi pristopov modeliranja podatkov (Jayawardane, 2019).

*Tabela 2: Opredelitev atribucijskih modelov*

<b>Atribucijski modeli</b>	<b>Pristop</b>
Poenostavljeni modeli	Statičen, splošen, enostavno razločljiv
Modeli na podlagi pravil	Pregleden, enostavno razločljiv, prilagodljiv
Algoritemski modeli	Statistična načela, objektivnost in nepristranskost

*Prerejeno po Jayawardane (2019).*

Modeli atribucij se osredotočajo na analizo vpliva oglaševalskih kanalov na vedenje kupcev. V zadnjih letih je bilo predlaganih in uporabljenih več naprednih modelov atribucije. Večina obstoječih modelov atribucije, ki se pogosto uporabljajo v praksi, temelji na pravilih, njihova učinkovitost pa je omejena z njihovimi predpostavkami. V nadaljevanju so podrobno predstavljeni modeli po kategorijah, vključno s poenostavljenimi modeli, ki kljub očitnim omejitvam med tržniki še vedno veljajo za najpogosteje uporabljene modele atribucije in se pogosto štejejo za izhodišče za primerjavo s preostalimi modeli atribucije (Jayawardane, Halgamuge & Kayande, 2015).

### 3.2.1 Poenostavljeni modeli

Poenostavljeni modeli veljajo za najbolj enostavno obliko atribucije. Popolno zaslugo za konverzijo dodelijo eni sami dotični točki, vpliv preostalih na poti stranke pa se prezre. Takšne metode so primerne za merjenje atribucije dobro usmerjenih oglaševalskih kampanj,

kot sta prepoznavnost blagovne znamke in ponovno ciljanje, predvsem zaradi enostavnosti razlage (Lee, 2010). Pri tem sta »Zadnji dotik« in »Prvi dotik« najpogosteje uporabljeni obliki poenostavljene atribucije. Kot je razvidno iz njunih imen se celotni prispevek za konverzijo dodeli prvemu ali zadnjemu dotiku usmeritve na poti stranke (Jayawardane, Halgamuge & Kayande, 2015). V nadaljevanju so predstavljeni štiri splošno sprejeti poenostavljeni atribucijski modeli:

**Zadnji dotik.** Model zadnjega dotika (angl. Last touch) velja za enega prvih in najpreprostejših modelov atribucije. Model domneva, da je konverzijo porabnika povzročil ravno zadnji oglas, ki ga je kliknil ali si ga ogledal pred nakupom. V oglaševalski industriji se ga uporablja kot standardni model atribucije. Uporaba je smiselna, če je cilj oglaševanja spodbuditi porabnike za nakup ali ko gre za izdelke s sorazmerno kratko fazo nakupnega cikla. Kljub svoji prednosti, preprostosti in enostavnosti izvedbe ta model očitno precenjuje prispevek zadnjega oglasa. Zanesljiv model atribucije bi razkril in ovrednotil prispevke vseh oglasov, ki jih je porabnik kliknil ali si jih ogledal na nakupni poti do končne konverzije (Ji, Wang & Zhang, 2016).

**Prvi dotik.** Prvi dotik (angl. First touch) nasprotno od zadnjega dotika celotno zaslugo za konverzijo dodeli prvi točki dotika na nakupni poti strank. Ta model je primeren za merjenje uspešnosti kampanj, namenjenih za povečanje ozaveščenosti blagovne znamke (Jayawardane, Halgamuge & Kayande, 2015).

**Zadnji posredni dotik.** Zadnji posredni dotik (angl. Last non-Direct touch) v celoti dodeli konverzijo zadnji stični točki, ki ne predstavlja neposrednega obiska spletnega mesta. Neposredne obiske spletnega mesta se prezre ob predpostavki, da se je porabnik v tem primeru že odločil za konverzijo zaradi vpliva predhodnega kanala. Ta predpostavka je do neke mere upravičena z dejstvom, da si porabnik zapomni URL-spletnega mesta za neposreden obisk spletnega mesta podjetja (Jayawardane, Halgamuge & Kayande, 2015).

**Zadnji Google Ads klik.** Oglaševalsko orodje »Google Ads« dodeli 100 % zaslug za konverzijo zadnjemu oglasu v iskalnem omrežju, ki ga je stranka kliknila pred konverzijo. Namen tega modela je, da identificira konverzije specifično za oglaševalsko orodje »Google Ads« v plačljivem iskalnem omrežju Google (Jayawardane, Halgamuge & Kayande, 2015).

### 3.2.2 Modeli atribucije na podlagi pravil

Ta kategorija je znana tudi kot hevristični modeli. Za te modele velja, da temeljijo na praktičnih metodah in so namenjeni enostavni pridobitvi zadovoljivih rezultatov. Njihova uporaba je smiselna, kadar je iskanje optimalne rešitve nepraktično ali nemogoče. Te metode naslovijo glavne omejitve poenostavljenih modelov z opredelitvijo fiksnih pravil, ki zasluge za konverzijo porazdelijo na več stičnih točk (atribucija z več dotiki – MTA). Ker pa opredeljeni nabor pravil ni izpeljan z uporabo podatkov, specifičnih za izbrano podjetje, je

ustreznost metod pogosto dvomljiva. V nadaljevanju so predstavljeni delni modeli na podlagi pravil (Jayawardane, Halgamuge & Kayande, 2015):

**Linearni model.** Linearni model (angl. Linear model) – vsaki stični točki na poti do konverzije se dodeli enak prispevek. Uporablja se predvsem za oceno učinkovitosti kampanje, namenjene krepitvi ozaveščenosti strank oz. prepoznavanju blagovne znamke. Za model velja predpostavka, da vsak stik porabnika s kanalom enako prispeva k odločitvi za konverzijo, saj vsaka dotična točka deluje kot opomin na zadnjega (Jayawardane, Halgamuge & Kayande, 2015).

**Model na podlagi položaja.** Model na podlagi položaja (angl. Position Based Model) dodeli prvi in zadnji stični točki fiksni odstotek prispevka, npr. po 40 %, s tem postavi večjo utež na kanale, ki so kupca »ujeli« in »pretvorili«. Preostalih 20 % je enakomerno razdeljenih med ostale stične točke, ki dajo modelu obliko U razporeditve prispevka (Jayawardane, Halgamuge & Kayande, 2015).

**Model upada v času.** Atribucijski model upada časa (angl. Time Decay Model) dodeli prispevek za konverzijo stičnim točkam, ki so časovno najbližje konverziji. Temelji na konceptu eksponentnega upadanja, katerega namen je odkriti kupčevo moč zadržanja. Privzeti razpolovni čas modela časovnega upada je 7 dni. To pomeni, da bo stična točka, ki se zgodi v času konverzije, prejela dvakrat večji prispevek kot točka dotika, ki se zgodi 7 dni pred konverzijo. Vendar v primerih, ko nakupna pot strank traja sorazmerno kratek časovni okvir, ta model ne daje točnih rezultatov, saj preteče premalo časa, da bi se pojavili učinki upadanja (Jayawardane, Halgamuge & Kayande, 2015).

**Model uteži časa.** Model uteži časa (angl. Time Weightage Model) predlaga naivno metodo za razporeditev oglaševalskih sredstev na podlagi časa, ki ga je stranka preživela na ciljnem spletnem mestu, glede na izbrani kanal prihoda (Woof & Anderson, 2015). Na podlagi heuristike modelov atribucije prvega in zadnjega dotika se večji pomen pripisuje začetnim ter zadnjim stičnim točkam, največji pomen pa je dodeljen najnovejši stični točki. Utež se izračuna za vsako točko dotika z uporabo zgornje porazdelitve ter v povezavi s porabljenim časom na spletnem mestu (Jayawardane, Halgamuge & Kayande, 2015).

**Model prilagojenih uteži.** Model prilagojenih uteži (angl. Customized Weights Model) upošteva, da kombinacija oglaševalskih dejavnikov vpliva na konverzijo (npr. pogostost, nedavnost, velikost, čas interakcije). Domnevana pomembnost vsakega posameznega dejavnika je ovrednotena z dodeljenimi utežmi. Ker pa so dodeljene uteži predmet posameznega primera in subjektivne ocene, merila za dodelitev atribucije nemalokrat postanejo pristranska in neprimerljiva (Jayawardane, Halgamuge & Kayande, 2015).



### 3.2.3 Algoritemski modeli

Algoritemski modeli predstavljajo prefinjen razred tehnik, ki z opisnimi pristopi modeliranja bolje zajamejo dinamiko med oglaševalskimi kanali. Da tržniki ugotovijo povečanje ali zmanjšanje vrednosti, ki jo doprinese vsak posamezen kanal, te metode ponazorijo posamezne izpostavljenosti, ne glede na to, ali so zaželeno za obravnavano podjetje (IAB, 2012). Poleg tega algoritemski modeli omogočajo razlikovanje med segmenti kupcev z vključevanjem njihovih heterogenih vedenj. Algoritemske modele se razvršča na podlagi metod, ki se uporabljajo za oceno parametrov modela in ugotavljanje doprinosa, ki ga ustvari vsak kanal (Jayawardane, Halgamuge & Kayande, 2015).

Na področju algoritemskih modelov obstaja več akademskih študij, ki ponujajo raznolike analitične pristope k atribuciji v večkanalnem oglaševanju, z namenom, da bi premagale slabosti hevrističnih modelov. Akademiki predlagajo različne analitične pristope k atribuciji, vključno z logističnimi regresijskimi modeli (Shao & Li, 2011), pristopi, ki temeljijo na teoriji iger (Berman, 2015; Dalessandro, Perlich, Stitelman & Provost, 2012), Bayesovi modeli (Li & Kannan, 2014), vzajemnimi modeli točkovnih procesov (Xu, Duan, & Whinston, 2014), vektorski avtoregresivni modeli (Kireyev, Pauweli & Gupta, 2016) in skriti Markovski modeli ali modeli Markovskih verig (Abhishek, Fader & Hosanagar, 2015). Poleg tega so tudi oglaševalske platforme v industriji, kot so Adometry (Google), Convertro (AOL) ali VisualIQ, uvedle vrsto metodologij atribucije (Moffett, 2014). Čeprav so sofisticirane metode atribucije dostopne širši publiki in vodje trženja zahtevajo takšne meritve uspešnosti, se v praksi celotna zgodovina brskanja porabnika pri izračunu učinkovitosti kanala v večkanalnem oglaševanju redko upošteva (Anderl, Becker, Wangenheim & Schumann, 2016).

V obstoječi akademski literaturi torej vidimo veliko različnih analitičnih pristopov k atribuciji, ki se razlikujejo po parametrih, ki ovrednotijo posamezne oglaševalske kanale. Med njimi velja za enega najbolj znanih in dovršenih načinov merjenja atribucije t.i. model Markovskih verig (angl. Markov Chains), ki ga predlagajo Anderl, Becker, Wangenheim in Schumann (2013). Markovski model atribucije dovoljuje ovrednotenje učinkovitosti posameznih trženjskih kanalov in pridobivanje vpogledov v medsebojno delovanje kanalov v večkanalnem spletnem okolju. Avtorji v delu uporabljajo model Markovskih verig višjega reda za bolj enakomerno porazdelitev vrednosti kanalov. Obenem Markovski model izpolnjuje naslednja merila: objektivnost, napovedna natančnost, robustnost, razumljivost, vsestranskost in algoritemska učinkovitost (Anderl, Becker, Wangenheim & Schumann 2013).

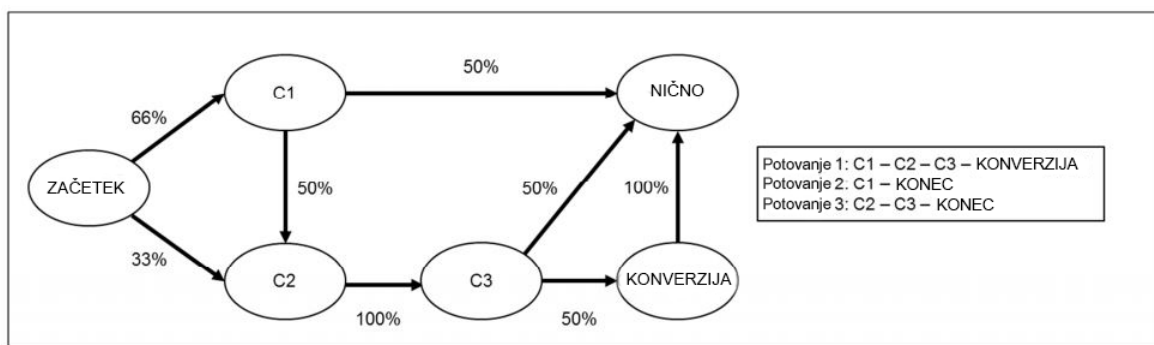
Analizo atribucije z uporabo Markovskih verig je mogoče enostavno izvesti tako s spletnimi analitičnimi orodji kot tudi programsko opremo, kot je npr. »R-Project«. Slednji tržnikom z enostavnim izvozom zbirk podatkov potovanj strank iz analitičnih orodij, kot je npr. Google Analytics, omogoča ovrednotenje prispevka tržnih kanalov. Obenem je mogoče rezultate Markovskih verig znotraj programa primerjati tudi z rezultati standardnih hevrističnih

modelov (Kakalejčik, Bucko, Resende & Ferencova, 2018). Enostavnost aplikacije Markovskih verig v praksi zagotavlja, da lahko analizo izvajajo podjetja vseh velikosti in proračuna. V nadaljevanju podrobneje obravnavam delovanje atribucijskega modela z metodo Markovskih verig višjega reda, predstavljenim v delu avtorjev Anderl, Becker, Wangenheim in Schumann (2013).

Markovske verige so verjetnostni modeli, ki lahko predstavljajo odvisnosti med zaporedji opazovanj naključne spremenljivke. Modeli imajo v trženju dolgo zgodovino uporabe in so bili pogosto uporabljeni za modeliranje odnosov s strankami (Homburg, Steiner & Totzek, 2009; Pfeifer & Carraway, 2000). Hkrati pa se pogosto uporabljajo pri odločitvah o strategiji oglaševanja in merjenju zvestobe blagovni znamki (Anderl, Becker, Wangenheim & Schumann, 2013).

Model predstavlja potovanja strank kot verige v Markovskih grafih. Uporaba grafičnega pristopa omogoča prikaz analize potovanj strank, ki vključuje stanja (oglaševalske kanale) in robove (verjetnost prehoda). Kot je razvidno v sliki 1 nakupna pot strank vsebuje enega ali več stikov po različnih kanalih. Če tržnik v svojem spletnem oglaševanju uporablja tri različne kanale C1, C2 in C3, bi model vključeval tri stanja: C1, C2 in C3. Poleg tega slika vsebuje tudi tri dodatna stanja: ZAČETEK, ki predstavlja izhodišče nakupne poti, stanje KONVERZIJE, ki predstavlja uspešne konverzije, in absorpcijsko NIČNO stanje za nakupne poti strank, ki v obdobju opazovanja niso končale s konverzijo (Anderl, Becker, Wangenheim & Schumann, 2013).

Slika 1: Poenostavljen primer Markovskega grafa



Vir: Anderl, Becker, Wangenheim & Schumann (2013).

Večkratna izpostavljenost porabnika oglasu sproži spremembo v porabnikovem zaznavanju storitve ali izdelka, vse od začetnega nezanimanja, vmesnih korakov aktivnosti (iskanja in razprave) do končne konverzije. Analiziranje vsakega potencialnega koraka in uporaba verjetnosti teh poti omogoča, da se dodeli vrednost določenim trženjskim kanalom glede na njihovo verjetnost, da bodo privedli do konverzije. Za izračun inkrementalnega učinka vsake posamezne izpostavljenosti model upošteva razliko v pričakovanih konverzijah, merjeno z

izključitvijo in vključitvijo vmesnih izpostavljenosti. Učinek odstranjevanja je ocena prispevka in se izračuna za vsak oglaševalski kanal v Markovskem grafu (Jayawardane, Halgamuge & Kayande, 2015).

Markovski model namesto, da bi vse interakcije s strankami pretvoril v linearni model, ki je nagnjen k napakam, na atribucijo gleda kot na mrežo interakcij med kanali. Grafična struktura modela omogoča vpogled v medsebojno delovanje kanalov in naravo potovanj strank. Tak pogled na atribucijo omogoča, da se odpravi pristranskosti tradicionalnih modelov ter upošteva vse možne interakcije porabnika s podjetjem z namenom boljšega razumevanja dinamike med kanali in izračuna najverjetnejše poti, ki vodi do konverzije (Anderl, Becker, Wangenheim & Schumann, 2016).

Model Markovskih verig omogoča izpeljavo atribucijskih ocen z uporabo verjetnosti prehoda med stanji oz. kanali. Markovske verige prvega reda predpostavljajo, da je verjetnost prehoda na naslednji korak odvisna samo od trenutnega položaja. Vendar na stranke pogosto vplivajo tudi prejšnje stične točke s podjetjem. Te stranke lahko ustrezno ovrednotijo Markovske verige višjega reda, ki gledajo več korakov nazaj. Tako avtorji Anderl, Becker, Wangenheim in Schumann (2013) ugotavljajo, da so iz praktičnih razlogov najustreznejše verige tretjega reda, kar pomeni, da je verjetnost prehoda v naslednje stanje odvisno od trenutnega in dveh prejšnjih stanj. V praksi se redko uporabljajo Markovske verige višje od četrtega reda, saj zgolj malo izboljšajo natančnost modela (Jayawardane, Halgamuge & Kayande, 2015).

### **3.3 Omejitve in izzivi atribucijskih modelov**

Oblikovanje atribucijskih modelov je v poslovnem svetu brez objektivne resnice, ki velja v vsakem primeru. Primerjava modelov atribucije je med podjetji izjemno zahtevna, saj razumljivost praktične uporabnosti v posameznem scenariju onemogoča vrednotenje, ki meri katero koli vrsto natančnosti (Shao & Li, 2011). Zaradi nezmožnosti presojanja o izbiri »najboljše« atribucije za tržnike ovrednotenje prispevka kanalov ostaja zelo subjektivno (Dalessandro, Perlich, Stitelman & Provost, 2012). Kljub temu velja, da je zaradi številnih pomanjkljivosti vprašljiva uporaba poenostavljenih modelov atribucije, kot npr. model zadnjega dotika. Ta model kljub premajhni natančnosti in pomanjkanju primerjalnih metod ostaja zaradi enostavnosti široko sprejet v oglaševalski industriji (Jayawardane, Halgamuge & Kayande, 2015).

Cilj atribucije je opredeliti vzročne učinke oglaševanja, vendar se posamezni vidiki oglasov (npr. velikost in lokacija), za katere je bilo dokazano, da vplivajo na verjetnost klikov, redko upoštevajo (Bhargava & Feng, 2002). Čeprav Dalessandro, Perlich, Stitelman in Provost (2012) predlagajo vzročni okvir, ki opredeljuje pomen teh dejavnikov, njihove metode ni mogoče razlagati neposredno in zahteva približek. Poleg tega, čeprav tehnologije spletnega sledenja poenostavljajo povezovanje izpostavljenosti oglasov in nakupov, njihov odnos morda ni vzročen. Na primer stranka, ki je izpostavljena oglasu, bo verjetno izvedla

konverzijo ne glede na dodaten vpliv. To je klasična težava endogenosti oglaševanja (Li & Kannan, 2014), ki je v nasprotju z uporabo strategije ciljanja, kjer so ocene prispevkov vedno pristranske s trženjskimi strategijami, ki jih uporablja podjetje (Jayawardane, Halgamuge & Kayande, 2015).

Piškotki kljub številnim pomanjkljivostim tvorijo večino zbirk podatkov, ki se uporabljajo za izdelavo nakupne poti strank (Jayawardane, Halgamuge & Kayande, 2015). Stranke ob vse večji zaskrbljenosti glede zasebnosti onemogočajo piškotke brskalnika, kar vodi k temu, da se zgodovina brskanja strank izgubi. Obenem nakupna pot strank vedno pogosteje prečka več kot eno napravo, zato je beleženje vedenj zahtevno združiti v en sam podatkovni zapis posameznika. Ob pomanjkanju zanesljivejših načinov za sledenje in merjenje izpostavljenosti trženju med več napravami je tako atribucija na ravni porabnika zelo otežena. Iz navedenih razlogov je natančnost atribucijskih modelov pogosto manjša, saj velikokrat dovoljuje prepoznavanje zgolj ene od naprav na poti porabnika, kot npr. mobilni telefon ali osebni računalnik (IAB, 2012).

Veliko število algoritemskih modelov atribucije združuje zgodovine konverzijskih in nekonverzijskih poti za empirično analizo, kjer je vsak kanal ocenjen kot spodbuda, ki potencialno vodi do konverzije ali nekonverzije v vnaprej določenem časovnem okviru (Woof & Anderson, 2015). Vendar Woof in Anderson (2015) poudarjata možnost spletne spodbude, ki porabnika vodi do konverzije zunaj spleta (Kitts, Wei, Au, Powter & Burdick, 2010). Pri tem fizičnega obiska kupca v prodajalni ni mogoče neposredno povezati s spletnim vplivom. Drug primer brez končne konverzije predstavljajo razdrobljena potovanja, ki se končajo s konverzijo na spletnem mestu konkurence. Pri tem nastane negativen vpliv na oceno atribucije, ki ni povezan z dejanji obravnavanega podjetja (Li & Kannan, 2014).

## **4 OBLIKOVANJE NAKUPNE POTI**

Tržniki za uspešno izvajanje oglaševalskih nalog potrebujejo dva sklopa spretnosti, in sicer: sposobnost boljšega razumevanja potreb strank kot njihovi konkurenti in izkoriščanje virov podjetja za boljše izpolnjevanje prepoznanih potreb (George Day, 1994). Iz tega sledi, da tržniki potrebujejo orodja, ki jim pomagajo razumeti, kaj porabniki cenijo, in njihove odločitve, ki jih bodo sprejeli na podlagi teh vrednot, pa tudi, kako se bodo porabniki odzvali na različne dražljaje, ki so posledica notranjih dejanj podjetja in zunanjih sprememb v okolju. Tržniki potrebujejo tako orodja za napovedovanje, torej za predvidevanje, kako se bo porabnik odzval na prikazane oglase, kot diagnostična, ki podjetju omogočajo, da oblikuje nakupno pot strank, tako da vpliva na odzive porabnikov v smeri, ki ustreza ciljem podjetja in ustvarja vrednost za porabnika (Mizik & Hanssens, 2018).

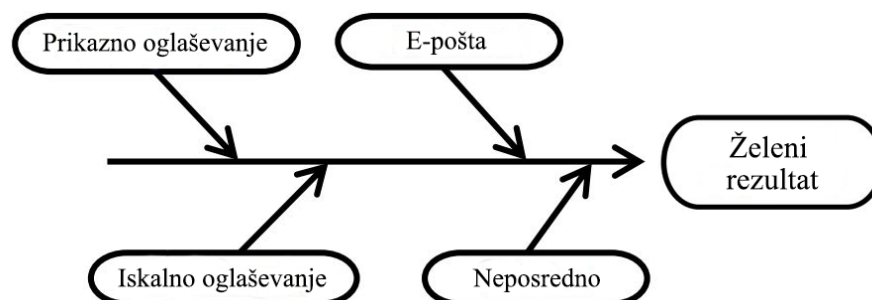
To poglavje opisuje pomen oblikovanja nakupne poti, ki poudarja uporabo ustreznega vrstnega reda oglaševalskih kanalov za usmerjanje vedenj strank. Pri tem oblikovanje nakupne poti temelji na zbranih podatkih o porabnikih med nakupnim procesom na spletnem mestu podjetja. V nadaljevanju poglavja bom s tem namenom opredelil nakupne korake porabnika v spletnem oglaševanju, poznane tudi kot dotike na nakupni poti strank. Sledi predstavitev raziskave in teorij o dinamiki med več oglaševalskimi kanali, ključnimi za tržnike, ki želijo ustrezno oblikovati nakupno pot porabnikov in povečati učinkovitost oglaševalskih kampanj. V zadnjem delu sledi opis problematike pri prepoznavanju korakov v nakupni poti porabnikov ter predstavitev modela napovedovanja premikov.

#### 4.1 Opredelitev nakupne poti

V strokovni literaturi najdemo vrsto različnih modelov, ki prikazujejo nakupno pot strank. Ta je praviloma razdeljena na več korakov, na podlagi katerih tržniki določajo cilje in vrste komunikacijskih kanalov. Glede na to, na katerem koraku se nahaja stranka, tržniki v nadaljevanju izberejo takšno kombinacijo spletnih kanalov in vsebin, ki bo za stranke predstavljala največjo vrednost, s tem ko bodo v pravem trenutku dobile informacije, ki jih želijo ali potrebujejo. Pri tem je pomembno, da tržniki oblikujejo korake, ki tem bolj poenostavijo nakupno pot strank in temu primerno prilagodijo tudi trženjske aktivnosti (Batra & Keller, 2016).

Velika večina obiskovalcev spletnega mesta med prvim obiskom ni pripravljena opraviti konverzije. Od prvega obiska se obiskovalci premikajo skozi nakupno pot strank, pogosto poznano tudi kot pot do konverzije, ki vključuje več dotikov, v več raznolikih zaporedjih. Ta postopek predstavlja zaporedje korakov, ki jih stranke storijo med premiki v fazah ozaveščanja, odločanja in konverzije (Kakalejšćik, Bucko, Resende & Ferencova, 2018). Kot je prikazano v sliki 2, porabnik pred zelenim rezultatom uporabi več vrst komunikacijskih kanalov. Zmožnost zbiranja podatkov o dotikih na nakupni poti in končnih konverzijah omogoča tržnikom, da izmerijo vpliv oglaševalskih aktivnosti na posameznega porabnika.

Slika 2: Primer korakov v nakupni poti stranke



Vir: Jayawardane, Halgamuge & Kayande (2015).

Višja kot je kompleksnost izdelka/storitve ali cena, višje je povprečno število stičnih točk. Med najpogostejšimi viri digitalnih dotikov, ki jih beležijo tržniki v obliki prikazov in klikov, spadajo: iskalna omrežja, organsko iskanje, družbena omrežja, e-pošta, prikazno oglaševanje in neposredni promet (Windsor, 2020). Poznavanje dotikov strank omogoča analizo in optimiziranje nakupnega procesa na podlagi npr.: povprečnega časa potovanja strank, časovnega zamika med dotiki, povprečnega števila kanalov s podjetjem itd. (Chugh, 2020).

## 4.2 Sinergija med kanali

Tržniki uporabljajo vrsto oglaševalskih kanalov za postopno nagovarjanje strank h konverziji. Učinki zaporedja med kombinacijami spletnih oglaševalskih kanalov povečajo ali zmanjšajo posamezne učinke kanalov glede na njihov vrstni red pojavljanja. Vendar ena kombinacija kanalov morda ne bo imela podobnega učinka, če bo predstavljena strankam v drugačnem zaporedju. Na primer, ko je promocijsko e-poštno sporočilo poslano po tem, ko stranka izvede organsko iskanje, je vpliv e-poštnega sporočila večji, ker stranka že pozna izdelek in je izkazala zanimanje. Manj verjetno je, da bo imelo njegovo obratno zaporedje enak učinek (Jayawardane, 2019).

Razumevanje zaporedne sinergije med spletnimi kanali predstavlja odlično priložnost za tržnike, da povečajo učinkovitost spletnih oglaševalskih kampanj. Čeprav so študije o dinamiki spletnih kanalov redke, obstaja podpora vpliva zaporedja med spletnimi kanali. Raziskave kažejo, da oglaševalske kampanje z več kanali ustvarjajo sinergijski učinek na vedenje kupcev v primerjavi s ponavljajočimi se oglaševalskimi kampanjami s posameznimi kanali. Razlog za to je, da izpostavljenost več kanalom, ki so kategorizirani kot sočasni ali zaporedni, povečuje kombinirane učinke kanalov v primerjavi z vsoto učinkov posameznega kanala (Naik & Raman, 2003). Hkrati je bilo na podlagi raziskav potrjeno, da obstaja podpora sinergiji med prikaznim oglaševanjem in iskalnim oglaševanjem, s tem ko prikazno oglaševanje privede do povečanja števila iskanj v iskalnem omrežju (Kireyev, Pauwels & Gupta, 2016).

Za opis sinergij in zaporedij kanalov je v nadaljevanju predstavljenih več teorij. Prvič, spremenljivost prikazov nakazuje, da različni oglaševalski konteksti olajšajo priklic iz spomina. Drugič, variacije ponavljanja kažejo, da ponavljanje poveča učinkovitost v primeru, da se ohranja pozornost porabnika. Tretjič, selektivna pozornost nakazuje, da se pozornost poveča s kompleksnostjo in prepoznavnostjo ali preprostostjo in novostjo. Zadnja teorija preučuje možnost uporabe teorije priklica naprej in iskanje nazaj za opis dinamike med več kanal (Jayawardane, 2019).

**Teorija kodiranja variabilnosti.** Teorija kodiranja variabilnosti (angl. Encoding variability theory) nakazuje, da je priklic spomina boljši, kadar je isto sporočilo dostavljeno iz več trženjskih kanalov (Stammerjohan, Wood, Chang & Thorson, 2005). Razlog za to je, da različni konteksti, v katerih porabnik pridobi informacije, ustvarjajo več poti iskanja

informacij in prispevajo k boljšemu priklicu. Nasprotno pa ponavljajoče se informacije v istem kontekstu ustvarijo eno samo pot iskanja. Spreminjanje konteksta oglasa za iskanje informacij bistveno izboljša priklic blagovne znamke kot ponavljajoči se kontekst (Unnava & Burnkrant, 1991).

**Teorija variacije ponavljanja.** Teorija variacije ponavljanja (angl. Repetition variation theory) nakazuje, da več kanalov poveča učinkovitost v primeru, da se z variacijami ohranja pozornost porabnika (Schumann, Petty & Clemons, 1990). Ponavljanje vključuje dve stopnji: začetna izpostavljenost, ki ustvarja pozitivne učinke, in dodatna pretirana izpostavljenost, ki povzroča negativne učinke (Pechmann & Stewart, 1988). Variacije sporočil so bile proučene v dveh oblikah: kozmetične in vsebinske razlike (Schumann, Petty & Clemons, 1990). Pri kozmetičnih različicah je osnovno sporočilo enako in lastnosti izdelka niso spremenjene (tj. spremembe barve, grafike, pisave in postavitve). V vsebinski različici se vsebina sporočil (npr. atributi in argumenti) spremenijo, medtem ko se kozmetična variacija ohranja razmeroma konstantna (tj. spremembe razlogov za uporabo izdelka z enakimi ilustracijami in naslovi). Ugotovljeno je bilo, da kozmetične razlike povečajo pozornost v pogojih z nizko motivacijo, medtem ko so imele vsebinske razlike večji vpliv pod pogoji visoke motivacije (Schumann, Petty & Clemons, 1990).

**Selektivna pozornost.** Selektivna pozornost (angl. Selective attention) nakazuje, da se največ pozornosti namenja sporočilom, ki so hkrati zapletena in znana ali preprosta in nova (Kahneman, 1973). Manj pozornosti porabniki namenjajo zapletenim in novim ter znanim in preprostim sporočilom (Stammerjohan, Wood, Chang & Thorson, 2005). Tržniki povečajo zaznavanje s ponavljanjem teme v več kanalih in zapletenost z izražanjem iste teme na več načinov. Na ta način se lahko večkanalne oglaševalske kampanje prebijejo skozi medijsko nasičenost in pridobijo večjo pozornost (Jayawardane, 2019).

**Kodiranje naprej in iskanje nazaj.** Za opis dinamike med zaporedji oglasov v literaturi obstajata dve teoriji. Kodiranje naprej in iskanje nazaj (angl. Forward encoding and backward retrieval) sta dva psihološka procesa, ki se zgodita, ko je stranka izpostavljena kombinaciji kanalov. Kodiranje najprej nakazuje, da oglas iz prvega kanala poveča zanimanje in pozornost za podoben oglas iz drugega kanala. To je zato, ker bi lahko prvi oglas deloval kot dražljaj, motivacija iz prvega oglasa pa bi olajšala obravnavo drugega oglasa. Obravnava teorije iskanja nazaj nakazuje, da se predhodni oglas mentalno predvaja, ko je porabnik izpostavljen naslednjemu. Razlog za to je, da lahko prekrivajoča se vsebina v oglasih deluje kot dražljaj za iskanje elementov, shranjenih v spominu iz predhodnega oglasa. Odvisno od vrste kanala lahko na priklic vplivata vizualna ali slušna kombinacija (Dijkstra, 2002).

### 4.3 Napovedovanje korakov na nakupni poti

Tržniki se soočajo z izzivom, kako v večkanalni oglaševalski kampanji pridobiti tem boljši vpogled v najbolj uspešno zaporedje kanalov. Z vidika tržnika so koraki do konverzije rezultat kolektivnega učinka več kanalov, kot npr. e-pošte, prikaznih oglasov ter oglasov v družbenih omrežjih (Berman, 2014). Pri napovedovanju teh korakov je ena izmed ovir pomanjkanje popolnih in/ali natančnih podatkov. Težave se lahko pojavijo v primerih, ko se prikazni oglasi, ki jih ciljne stranke na spletnem mestu ne vidijo, beležijo kot stična točka s podjetjem. Podobno je, ko obiskovalci spletnega mesta izbrišejo piškotke v brskalniku in s tem potencialno izgubijo druge stične točke strank. Prav tako med porabniki narašča trend blokiranja oglasov predvsem na mobilnih napravah, ki onemogočajo prikazne oglase na spletnem mestu. Takšne napake na ravni porabnikov, ki jih tržniki ne zaznajo ter ne odstranijo iz zbirke podatkov, negativno vplivajo na vpogled v porabnikove premike (Kannan, Reinartz & Verhoef, 2016).

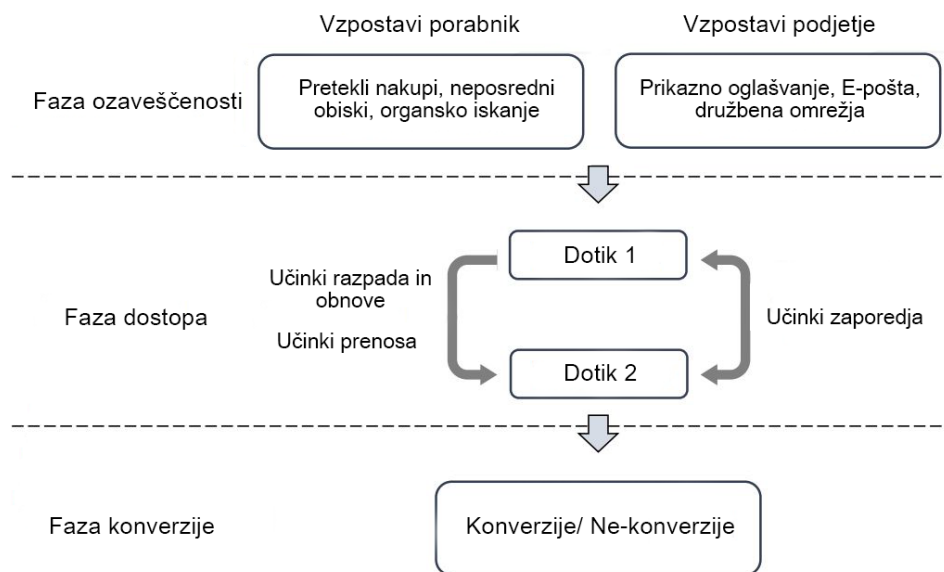
Osrednji del napovedovanja korakov v nakupni poti je prepoznavanje, kako se porabniki odzivajo na dejanja trženjskega oddelka. Ob tem se tržniki tradicionalno osredotočajo na vzročno sklepanje. Na primer, ali bo sprememba zaporedja kanalov povzročila več konverzij? Z namenom pridobivanja natančnejših napovedi so pomembni tudi drugi podatki o porabnikih. Na primer, na katere segmente ciljati, za kateri izdelek se bo porabnik najverjetneje odločil, katera različica oglaševalske pasice bo ustvarila več klikov. Vse to so težave s predvidevanjem, za katere večja podjetja uporabljajo zapletene modele strojnega učenja. Ti omogočajo predvidevanje vedenja porabnikov, na podlagi katerega tržniki merijo učinkovitost oglaševalskih kampanj ter napovedujejo korake kupcev, ki bodo z večjo verjetnostjo izvedli konverzijo (Dzyabura & Yoganarasimhan, 2018).

V nadaljevanju je predstavljen model vedenja kupcev avtorice Jayawardane (2019), ki poudarja pomen medsebojnega vpliva ter vrstnega reda oglaševalskih kanalov pri odkrivanju premikov kupcev na nakupni poti. Spletni kanali so v modelu razdeljeni na kanale, prek katerih komunikacijo sprožijo stranke, ki samostojno iščejo informacije (npr. neposredni obiski, organsko iskanje) in na kanale podjetij, kjer podjetja vzpostavijo trženjsko komuniciranje s strankami (npr. prikazno oglaševanje, partnerske povezave). Med zaporednimi dotiki kanalov stranke so upoštevani tudi učinki razpada in obnove (angl. Decay and Restoration effect), učinki prenosa (angl. Carryover effect) ter učinki zaporedja (angl. Sequence effect). Učinki razpada zmanjšujejo vrednost informacij, pridobljenih tekom časa, medtem ko učinki obnove delujejo nasprotno in povečujejo informacijsko vrednost. Učinki prenosa zajemajo tako takojšnje kot prihodnje vplive na odločitve porabnika na podlagi oglaševanja. Navedeni učinki znotraj modela povzamejo dinamiko med oglaševalskimi kanali, ki jih lahko tržniki na podlagi zbranih podatkov o premikih med kanali tudi ovrednotijo (Jayawardane, 2019).



Model odkrivanja vedenj kupcev predlaga postopek simulacije zbirke podatkov o preteklih premikih med kanali in nakupih porabnikov, za iskanje najpogostejših zaporedij kanalov, ki privedejo do konverzije (Jayawardane, 2019). Na sliki 3 je predstavljen postopek napredovanja do konverzije prek sledečih faz: (1) Ozaveščenost – porabnik upošteva različne kanale za iskanje informacij, (2) Dostop – porabnik uporablja izbrane kanale za iskanje in vrednotenje informacij ter (3) Konverzija - predstavlja odziv porabnikov na ponujeno ponudbo.

Slika 3: Postopek odločanja o konverziji



Vir: Jayawardane (2019).

## 5 EMPIRIČNA RAZISKAVA ZBIRANJA PODATKOV IN IZBIRE MODELOV ATRIBUCIJE V SLOVENSKIH PODJETJIH

Teoretičnemu delu magistrskega dela, v katerem sem poglobljeno raziskal področje zbiranja podatkov o porabnikih in obstoječe atribucijske modele s pomočjo različnih znanstvenih člankov in knjig, sledi empirična raziskava področja atribucijskih modelov in izbiro le-teh za ustreznost ovrednotenja posameznih oglaševalskih kanalov. V tem delu magistrskega dela bom raziskal, kako podjetja v Sloveniji, ki prodajajo prek spleta, pristopajo k izbiri atribucijskih modelov, zbiranju podatkov o porabnikih in kateri so glavni dejavniki, ki vplivajo na izbiro.

## 5.1 Namen in cilji raziskave

**Namen empirične raziskave** je preučiti izbiro atribucijskih modelov v slovenskih podjetjih pri večkanalnem spletnem oglaševanju, na podlagi katere bo mogoče oblikovati smernice za uporabo učinkovitejših modelov za boljši vpogled v uspešnost posameznih oglaševalskih kanalov.

**Cilj empirične raziskave** v magistrskem delu je s pomočjo anketnega vprašalnika preučiti posamezne dejavnike, ki vplivajo na izbiro atribucijskega modela. Dejavnikov, ki vplivajo na izbiro modelov, je več, v raziskavi pa se osredotočam predvsem na tri, to so: število kanalov oglaševanja, pristop k zbiranju podatkov o porabnikih in pregled nad spletno analitiko. S pomočjo analize anketnega vprašalnika želim ugotoviti, kako je izbira atribucijskega modela povezana s pristopom k zbiranju in analiziranju podatkov o porabnikih. Prav tako želim ugotoviti, kakšna je povezava med zahtevnostjo atribucijskega modela in tehnologijami zbiranja podatkov. Hkrati bi rad preučil zadovoljstvo tržnikov z uporabo trenutnih modelov atribucije v podjetju. Iz obstoječe literature in raziskav je razvidno, da večja natančnost modelov atribucije za tržnike ni vedno najpomembnejši dejavnik pri izbiri atribucijskega modela ampak enostavnost in prilagodljivost.

## 5.2 Raziskovalne hipoteze

Podjetjem je danes na voljo vrsta različnih atribucijskih modelov in analitičnih orodij, ki omogočajo natančnejše pripisovanje zaslug posameznim oglaševalskim kanalom (Baltes, 2017). Motivi pri izbiri načina ovrednotenja kanalov in pripisovanja konverzij se med podjetji zelo razlikujejo. O izbiri atribucijskih modelov v podjetjih odločajo predvsem vodje trženja. Slednji so pri izbiri atribucijskega modela odvisni od številnih dejavnikov, kot npr. velikost podjetja, številčnost podatkov, znanja na področju atribucije, uporaba ustreznih orodij za spletno analitiko itd. (Jayawardane, Halgamuge & Kayande, 2015). Poznavanje glavnih motivacijskih dejavnikov pri ocenjevanju uspešnosti oglaševalskih kanalov je ključno za oblikovanje ustreznih izhodišč, kako naj podjetja pristopajo k izbiri atribucijskega modela. Na podlagi strokovne literature, ki se osredotoča na zbiranje podatkov o porabnikih ter raziskav obstoječih atribucijskih modelov, v nadaljevanju magistrskega dela zastavljam naslednje hipoteze, ki jih bom poskušal dokazati z izvedbo lastne raziskave in analize:

v digitalnem oglaševanju je pomembno imeti pravi model atribucije, saj ta poganja metriko uspešnosti, vpoglede v oglaševanje in strategijo optimizacije (Shao & Li, 2011). Navkljub temu, da so tržniki nezadovoljni s poenostavljenimi modeli atribucije, velja, da velika večina podjetij še vedno uporablja model zadnjega dotika. Ti pogosto povzročajo prekomerno vlaganje v kanale zgolj zato, ker so na koncu nakupnih poti. Izbira poenostavljenih modelov atribucije omogoča tržnikom enostavnost uporabe in vodi do intuitivnega razumevanja, vendar gre za kompromis z natančnostjo modela, ki so ga tržniki v manjših podjetjih pogosto pripravljene sprejeti (Jayawardane, Halgamuge & Kayande, 2015). To nakazuje, da tržniki v naprednejših modelih trenutno ne vidijo dovolj dodane vrednosti, da bi bili pripravljene preiti

na bolj dovršene modele, ki dovoljujejo natančnejše ovrednotenje oglaševalskih kanalov (Criteo, 2013). Na podlagi teh argumentov postavljam hipotezo 1a:

**Hipoteza 1a:** Podjetjem je pri izbiri atribucijskega modela najpomembnejša enostavnost uporabe.

Tržniki so pri analizi podatkov porabnikov vedno bolj opolnomočeni, povezani in pod digitalnim vplivom kot kdaj koli prej. V prizadevanjih po pridobivanju natančnega ovrednotenja doprinos oglaševalskih kanalov tržniki uporabljajo dovršene atribucijske modele. Ključne koristi uporabe atribucije so tako na strani ponudnikov medijskega prostora kot na strani tržnikov, s tem ko le-ti pridobijo dostop do večjega števila podatkov med potovanjem kupca. Zbrani podatki so uporabljeni za prepoznavanje vrednosti oglaševalskih kanalov v prodajnem lijaku in na koncu koristijo tudi pri zakupu medijskega prostora. Uporaba atribucijskih modelov za vpogled v učinkovitost kanalov torej omogoča ustrezno ovrednotenje posameznih kanalov, še posebej tistih, za katere tržniki menijo, da prekomerno pripisujejo zasluge za konverzije (IAB, 2012). Na podlagi teh argumentov postavljam hipotezo 1b:

**Hipoteza 1b:** Podjetja se strinjajo, da njihov atribucijski model ustrezno ovrednoti vse oglaševalske kanale.

Napredek trženjske tehnologije na področju sledenja obiskovalcem spletnega mesta omogoča tržnikom, da pridobijo pomembne informacije o klikih na oglase, premikih na spletnem mestu, zgodovini nakupov itd. Združevanje teh informacij v vedno večjih zbirkah podatkov in zmogljiva analitična orodja zmanjšujejo ovire pri spreminjanju surovih podatkov v koristne vpoglede o njih. Tega se zavedajo predvsem podatkovno usmerjena podjetja, ki želijo na podlagi analize podatkov v atribucijskih modelih pridobiti pregled nad vplivom oglaševalskih kanalov na nakupni poti. Podjetja tako od tržnikov pričakujejo vedno bolj natančne podatke, zaradi česar so ti primorani uporabljati bolj dovršene modele atribucije, ki jim dovoljujejo objektivno dodeljevanje prispevka med kanali (IAB, 2012). Na podlagi teh argumentov postavljam drugo hipotezo:

**Hipoteza 2:** Natančnejše zbiranje podatkov o porabnikih vodi v izbiro bolj dovršenega modela atribucije.

Eno ključnih vprašanj v digitalnem oglaševanju je, kako učinkovito razporejati sredstva pri uporabi različnih oglaševalskih kanalov (Yuvaraj, Chandavarkar, Kumar & Sandeep, 2018). Z namenom učinkovitejšega dodeljevanja oglaševalskega proračuna tržniki uporabljajo vedno bolj analitičen pristop, ki temelji na poznavanju uspešnosti kanalov (Wiesel, Pauwels & Arts, 2011). Atribucijski modeli, ki dodelijo prispevek zgolj enemu kanalu, kot npr. model zadnjega dotika, pogosto povzročajo prekomerno vlaganje v izbrane kanale. Na drugi strani uporaba atribucijskih modelov z več dotiki tržnikom prinaša natančnejše vpoglede v uspešnost kanalov na nakupni poti. Te vpoglede lahko izkoristijo za prilagajanje strategij

oglaševanja in odločanje o učinkoviti porabi oglaševalskega proračuna med kanali (Shao & Li, 2011). Na podlagi teh argumentov postavljam tretjo hipotezo:

**Hipoteza 3: Podjetja, ki uporabljajo model z več dotiki, se bolj strinjajo, da učinkoviteje porabljajo oglaševalski proračun med kanali kot podjetja, ki uporabljajo model z enim dotikom.**

Običajno podjetja znotraj posamezne oglaševalske kampanje uporabljajo več kanalov. Ko porabnik sprejme odločitev o nakupu ali se prijavi na storitev, želijo tržniki ugotoviti, kateri oglasi so prispevali k odločitvi porabnika. Ta korak je ključnega pomena pri dokončanju povratne zanke, da se lahko večkanalna oglaševalska kampanja analizira in optimizira (Shao & Li, 2011). Uporaba modelov atribucije z več dotiki je ena najpomembnejših rešitev za podjetja, ki pri spletnem oglaševanju uporabljajo več kanalov. Dovršeni modeli omogočajo dostop do poročil o uspešnosti in delovanju posameznih kanalov, ki pri analizi izolirajo učinke enega kanala na drugega. Na podlagi modelov atribucije z več dotiki tržniki izoblikujejo oglaševalske strategije, v katerih spremenijo vrstni red kanalov ter oblike in umestitve oglaševalskih kampanj (IAB, 2012). Na podlagi teh argumentov postavljam četrto hipotezo:

**Hipoteza 4: Podjetja, ki uporabljajo večje število oglaševalskih kanalov, izbirajo bolj dovršene atribucijske modele.**

Privlačnost spletnega oglaševanja ni le v zmožnosti sledenja odzivom porabnikov skoraj v trenutku, ampak verjetno še pomembneje v nadaljnji zmožnosti uporabi podatkov za natančnejše ciljanje izbranih segmentov porabnikov s prilagojenimi oglasnimi sporočili in umestitvami oglasov. Struktura komunikacije v spletnem okolju omogoča tržnikom, da izvedo veliko več o porabnikih, njihovih interesih in preferencah, kot je bilo mogoče kadar koli prej v svetu zunaj spleta. Na podlagi zbranih podatkov o porabnikih tržniki prilagajajo nakupne poti strank z namenom izboljšanja interakcij ter povečanja števila konverzij. Ob tem imajo koristi tudi porabniki, ki se jim prikazujejo oglasi na podlagi zanimanj in so zato zanje bolj informativni ter imajo s tem večjo vrednost (Todri, 2016). Na podlagi teh argumentov postavljam peto hipotezo:

**Hipoteza 5: Tržniki uporabljajo zbrane podatke o porabnikih pri oblikovanju nakupne poti kupca.**

### **5.3 Metodologija**

Empirični del temelji na kvantitativni raziskavi, v okviru katere bom izvedel spletno anketo. Spletna anketa se uvršča med računalniško podprto samoizpolnjevanje, ki predpostavlja dostop do interneta in zahteva uporabo spletnega brskalnika. Velja za enega najbolj pogostih načinov za neposredno zbiranje podatkov v družboslovju. Pri spletnih anketah anketiranec sam izpolnjuje vprašalnik, zato je potrebno nameniti posebno pozornost oblikovanju

vprašalnika, saj morajo biti vprašanja enostavna in jasno razumljiva. Tak način zbiranja anket omogoča hitro pridobivanje odgovorov, enostaven dostop do podatkov, velikost vzorca in nizke stroške izvedbe. Med tem pa med slabosti spletnega vprašalnika prištevamo: nizko stopnjo odgovorov, omejeno možnost pokritja populacije ter majhen nadzor nad izborom anketirancev in posledično težje doseganje reprezentativnosti vzorca (Bregar, Ograjenšek & Bavdaž, 2005).

Za izvedbo raziskave sem uporabil dostop do baze podatkov AJPES. S tem sem pridobil e-poštne naslove podjetij, ki predstavljajo enote ciljne populacije. Pri tem sem za izbor enot uporabil tehnike verjetnostnega vzorčenja, in sicer tehnike enostavnega slučajnega vzorčenja (angl. simple random sampling). Vzorčni okvir v raziskavi sestavljajo vsa podjetja, ki so registrirana v Sloveniji pod standardno klasifikacijo dejavnosti »Trgovine na drobno po pošti ali po internetu« (razred G47.91). Enote so bile v vzorec izbrane slučajno. Izbrana tehnika mi je omogočila najpreprostejše zbiranje podatkov, s tem ko iz vzorčnega okvirja sam naključno izberem enote oziroma anketirance.

Raziskavo sem izvedel s pomočjo spletnega anketnega vprašalnika, ki sem ga oblikoval s pomočjo spletnega orodja za anketiranje IKA. Spletna anketa je bila anonimna in je bila naslovljena na vodje trženja v naključno izbranih podjetjih. Vprašalnik, predstavljen v prilogi 1, sestavlja vnaprej pripravljena vprašanja, pri katerih je predvidena tudi oblika odgovorov. Strukturiral sem ga na podlagi predpostavljenih hipotez in po zgledu raziskav, opravljenih na obravnavanem področju. Anketni vprašalnik je sestavljen iz 20 vprašanj, od tega je 11 vprašanj odprtega tipa z izbiro »Drugo«. Prvih 16 vprašanj je vsebinskih, zadnja 4 vprašanja pa so demografska.

Anketni vprašalnik v samem začetku vsebuje nagovor, ki predstavi anketirancem, zakaj je njihovo sodelovanje pomembno, kako bodo rezultati uporabljeni in anketirancem zagotavlja anonimnost. Nagovoru sledita dva filter vprašanja, ki ločita respondente na tiste, ki večinski del dejavnosti predstavlja prodaja in oglaševanje prek spleta, in na tiste, ki ne. Če na omenjena vprašanja odgovorijo z da, lahko vprašalnik rešujejo naprej, v nasprotnem primeru pa jih anketa avtomatsko usmeri na konec vprašalnika in na zahvalo. Namen teh vprašanj je narediti selekcijo med respondenti in pridobiti odgovore zgolj od tistih, ki prodajajo in oglašujejo prek spleta. Tretje in četrto vprašanje se nanašata na glavne namene uporabe spletnega oglaševanja ter kanale, ki jih podjetja uporabljajo pri predstavitvi na spletu. S četrtem vprašanjem želim hkrati preveriti četrto hipotezo, s katero želim ugotoviti, ali število kanalov oglaševanja vpliva na izbiro atribucijskega modela.

Peto vprašanje se navezuje na načine spremljanja uspešnosti oglaševalskih kanalov. Šesto vprašanje se nanaša na pristojnost pri spremljanju uspešnosti oglaševalskih kanalov. Sedmo vprašanje se nanaša na trženjska orodja, ki jih podjetja uporabljajo pri spremljanju oglaševalske uspešnosti. Pri omenjenem vprašanju sem spremenljivke povzel po viru IAB (2012), za katere sem uporabil nominalno mersko lestvico. Osmo, deveto, deseto in enajsto vprašanje se navezujejo na zbiranje podatkov na spletem mestu. Osmo vprašanje se nanaša

na beleženje oglaševalskega kanala prihoda na spletno mesto. Pri devetem vprašanju sem želel preveriti, katere tehnologije uporabljajo podjetja pri zbiranju podatkov o obiskovalcih. Z devetim vprašanjem sem preveril tudi drugo hipotezo, ki se nanaša na povezanost med tehnologijami zbiranja podatkov in izbiro atribucijskega modela. Deseto vprašanje je namenjeno preverjanju, ali podjetja na podlagi zbranih podatkov oblikujejo nakupno pot kupcev. Vprašanje se navezuje na peto hipotezo, s katero želim preveriti, ali podjetja zbrane podatke uporabljajo za oblikovanje nakupne poti. Enajsto vprašanje se nanaša na metode povezovanja različnih naprav istega obiskovalca spletnega mesta v en podatkovni zapis preko skupnih identifikatorjev. Spremenljivke pri navedenih vprašanjih sem izbral na podlagi strokovne literature Jayawardane (2019). Z omenjenimi vprašanji, ki se navezujejo na zbiranje podatkov, sem želel neposredno preveriti, kako podjetja pristopajo k zbiranju podatkov ter vpliv na izbiro atribucijskega modela. Dvanajsto vprašanje se nanaša na modele atribucije, ki jih podjetja uporabljajo pri ovrednotenju prispevka oglaševalskih kanalov. Vprašanje se navezuje na tretjo hipotezo, ki primerja učinkovitost modelov z več dotiki v primerjavi s preprostimi modeli z enim dotikom.

Trinajsto vprašanje se nanaša na razloge za uporabo atribucijskega modela. Spremenljivke sem povzel po IAB (2012), za katere sem uporabil nominalno lestvico. Štirinajsto vprašanje se nanaša na kriterije pri izbiri atribucijskega modela. Mnenja o izbranem atribucijskem modelu podjetij sem preverjal s petnajstim vprašanjem. Z omenjenim vprašanjem sem želel preveriti: zadovoljstvo s trenutnim modelom, zmožnost ustreznega ovrednotenja oglaševalskih kanalov, učinkovitost porabe oglaševalskega proračuna med kanali in natančnost modela. Za vprašanje sem uporabil petstopenjsko Likertovo lestvico za preverjanje strinjanja s trditvijo. Šestnajsto vprašanje se nanaša na razloge, zaradi katerih se v podjetjih ne odločajo za vzpostavitev bolj dovršenega modela atribucije. Sedemnajsto in osemnajsto je namenjeno, da anketiranci opredelijo delovno mesto in število zaposlenih v podjetju. Devetnajsto vprašanje se nanaša na kategorijo poslovanja, v kateri deluje podjetje, medtem ko se dvajseto vprašanje nanaša na prihodke podjetja, ki so razdeljeni v sedem prihodkovnih razredov.

## **5.4 Analiza rezultatov**

V nadaljevanju poglavja so predstavljeni rezultati raziskave, ki je bila izvedena s pomočjo anketnega vprašalnika 1KA. Vprašalnik je bil poslan tisoč petsto slovenskim podjetjem, ki so registrirana pod dejavnostjo trgovina na spletu. Na uvodni nagovor je kliknilo 475 oseb, izmed katerih je dejansko pričelo z reševanjem ankete 191. V času, ko je bila spletna anketa aktivna, jo je ustrezno izpolnilo 107 anketirancev. Pri analizi rezultatov sem upošteval vse ustrezno izpolnjene anketne vprašalnike, zato je pri vprašanjih, ki se navezujejo na demografska vprašanja in atribucijski model, prišlo do manjšega odstopanja glede števila odgovorov.

#### 5.4.1 Značilnosti vzorca

Anketiranci v anketnem vprašalniku so bili v največjem deležu, to je 67,7 %, lastniki oz. direktorji podjetja, 17,2 % je bilo zaposlenih v trženju. Ostalih 15,1 % anketirancev se je opredelilo kot zaposleni v administraciji in managementu. Glede velikosti podjetij, sodelujočih v raziskavi, sem podjetja glede na število zaposlenih razdelil na mikro, majhna in srednja podjetja (velikih podjetij v raziskavi ni bilo). Na vprašanje o številu zaposlenih v podjetju je odgovorilo 96 anketirancev. Kot je razvidno v tabeli 3, večina anketirancev, kar 92 % (n = 80), prihaja iz mikro podjetij.

Tabela 3: Velikost podjetij glede na število zaposlenih

Velikost podjetja	Število zaposlenih	n	n (v%)
Mikro podjetje	0-10	80	92
Majhno podjetje	11-50	5	7
Srednje podjetje	51-250	1	1
Skupaj		96	100

*Vir: lastno delo.*

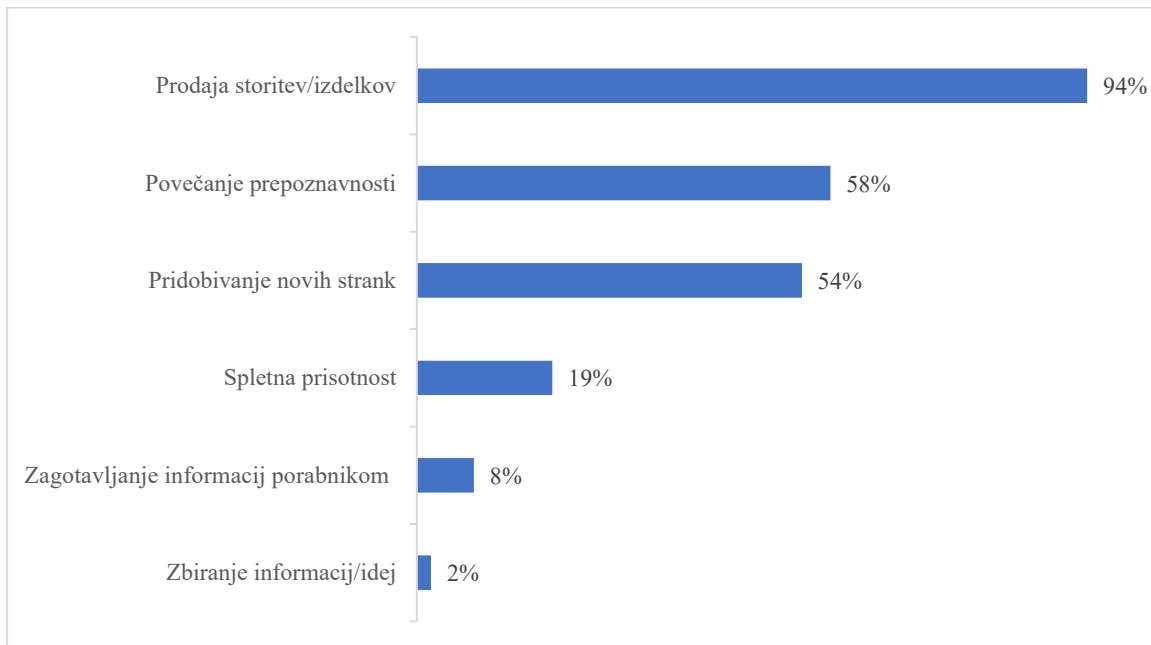
Večina podjetij, sodelujočih v raziskavi, je v preteklem letu ustvarila manj kot 50.000 € prihodkov. Respondenti, sodelujoči v raziskavi, so bili pri vprašanju devetnajst vprašani glede kategorije poslovanja. Pri tem je bila respondentom ponujena možnost, da izberejo enega ali več odgovorov. Največ, kar 81 % (n = 80), respondentov je navedlo, da prihodke ustvarijo s prodajo izdelkov ali storitev neposredno končnim kupcem (angl. business to customer), medtem ko 55 % (n = 54) respondentov ustvari prihodke s prodajo pravnim osebam (angl. business to business).

#### 5.4.2 Analiza po posameznih vprašanjih

Prvo in drugo vprašanje v vprašalniku sta bili filter vprašanji: »Ali večinski del dejavnosti vašega podjetja predstavlja prodaja prek spleta?« in »Ali se v vašem podjetju poslužujete spletnega oglaševanja?«. S tem sem želel ločiti respondente na tiste, ki prodajajo prek spleta ter oglašujejo na spletu, in na tiste, ki tega ne počnejo. Če so pri teh dveh vprašanjih odgovorili z da, so lahko anketo reševali naprej, v nasprotnem primeru jih je anketa usmerila na zahvalo oziroma zaključek. Ustrezno rešenih vprašalnikov je 191, izmed vseh anketirancev jih je 56 % (n = 107) odgovorilo z da na prvi dve vprašanji ter ustrezno izpolnilo celoten vprašalnik, 44 % respondentov (n = 84) pa je odgovorilo z ne in tam anketo zaključilo. Za nadaljnjo analizo sem zato upošteval velikost vzorca 107 respondentov.

Tretje vprašanje v vprašalniku se navezuje na namene uporabe spletnega oglaševanja. Respondentom je bila ponujena možnost, da izberejo enega ali več odgovorov. Podatki so prikazani v sliki 4. Izmed vseh respondentov jih je največ, kar 94 % (n = 101), odgovorilo, da uporabljajo spletno oglaševanje za namen povečanja prodaje storitev ali izdelkov. Sledi povečanje prepoznavnosti z 58 % (n = 62), pridobivanje novih strank z 54 % (n = 58), spletna prisotnost z 19 % (n = 20), zagotavljanje informacij porabnikom z 8 % (n = 9), 2 % (n = 2) respondentov pa je izbralo zbiranje informacij in idej.

*Slika 4: Glavni nameni uporabe spletnega oglaševanja (v %)*

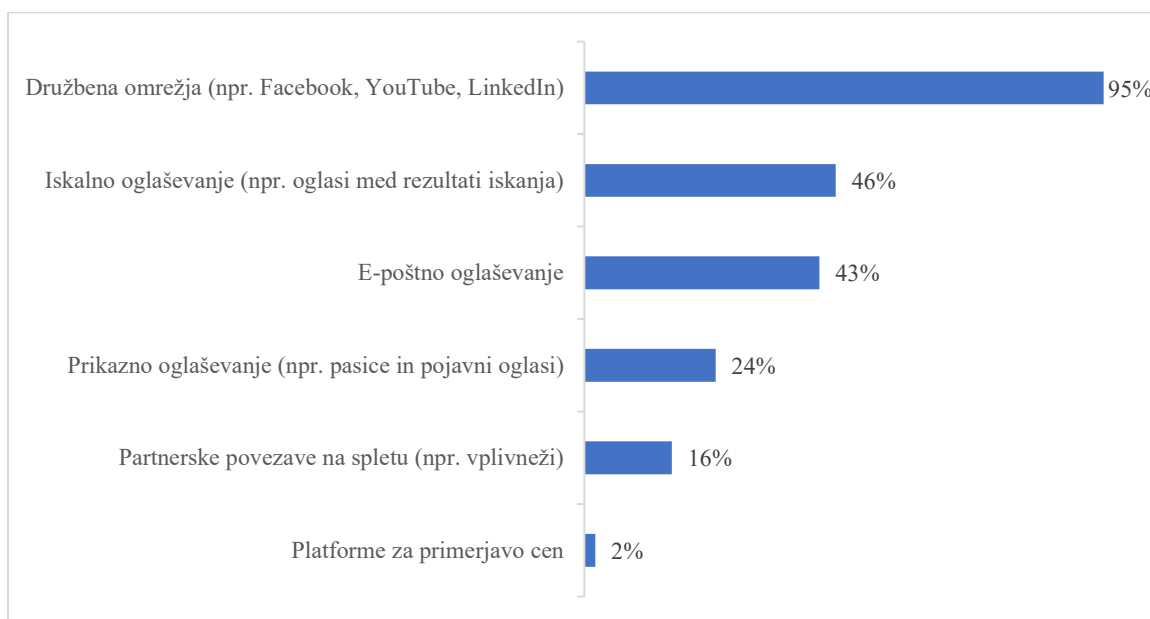


*Vir: lastno delo.*

Četrto vprašanje se nanaša na vrste plačljivih kanalov oglaševanja, ki jih podjetja uporabljajo pri predstavitvi na spletu. Respondentom je bila ponujena možnost, da izberejo enega ali več odgovorov. Na sliki 5 so prikazani rezultati. Največ respondentov, kar 95 % (n = 102), uporablja družbena omrežja, sledijo respondenti, ki uporabljajo iskalno oglaševanje, 43 % (n = 46) respondentov uporablja e-poštno oglaševanje, 24 % (n = 26) respondentov je takih, ki uporabljajo prikazno oglaševanje, sledi 16 % (n = 17) respondentov, ki uporabljajo partnerske povezave, in 2 % (n = 2) respondentov, ki uporablja platforme za primerjavo cen.




Slika 5: Vrste plačljivih spletnih oglaševalskih kanalov (v %)



Vir: lastno delo.

Peto vprašanje se nanaša na načine spremljanja uspešnosti oglaševalskih kanalov. Respondentom je bila ponujena možnost, da izberejo enega ali več odgovorov. Na sliki 6 so prikazani rezultati. Največ respondentov, kar 79 % (n = 86), za spremljanje uspešnosti oglaševanja uporablja analitiko znotraj kanalov oglaševanja, s 75 % (n = 80) sledijo respondenti, ki uporabljajo orodja za spletno analitiko, s 17 % (n = 18) sledijo respondenti, ki uporabljajo lastne prilagojene sisteme. Poročila s strani oglaševalske agencije ali zunanjih sodelavcev za spremljanje uspešnosti uporablja 10 % (n = 11) respondentov.


Slika 6: Spremljanje uspešnosti oglaševalskih kanalov (v %)



Vir: lastno delo.

Pri šestem vprašanju sem preverjal, kdo je zadolžen za spremljanje uspešnosti in ovrednotenja oglaševalskih kanalov. Podatki so prikazani v sliki 7. Izmed vseh respondentov jih največ, kar 86 % (n = 92), odgovorilo, da spremljajo uspešnost oglaševalskih kanalov zaposleni znotraj podjetja. Sledijo zunanji sodelavci s 7 % (n = 8), oglaševalska agencija s 6 % (n = 6) ter ponudnik spletne analitike z 1 % (n = 1) respondentov.


*Slika 7: Spremljanje uspešnosti in ovrednotenja oglaševalskih kanalov (v %)*



*Vir: lastno delo.*

Sedmo vprašanje se nanaša na vrste trženjskih orodij, ki jih uporabljajo podjetja pri avtomatizaciji in spremljanju uspešnosti oglaševalskih kanalov. Respondentom je bila ponujena možnost, da izberejo enega ali več odgovorov. Na sliki 8 so prikazani rezultati. Največ respondentov, kar 67 % (n = 72), uporablja spletna orodja za trženjsko analitiko, z 32 % (n = 34) sledijo respondenti, ki uporabljajo ponudnike e-poštnih storitev, 21 % (n = 22) respondentov uporablja platforme za upravljanje spletnih vsebin, 19 % (n = 20) respondentov uporablja CRM orodja, 18 % (n = 19) respondentov uporablja trženjska orodja za avtomatizacijo. Platforme za upravljanje vsebin družbene skupnosti uporablja 16 % (n = 17), sledi 10 % (n = 11) respondentov, ki uporabljajo platforme za upravljanje podatkov, med tem ko 16 % (n = 17) respondentov ne uporablja nič od naštetega.

Slika 8: Vrste trženjskih orodij (v %)

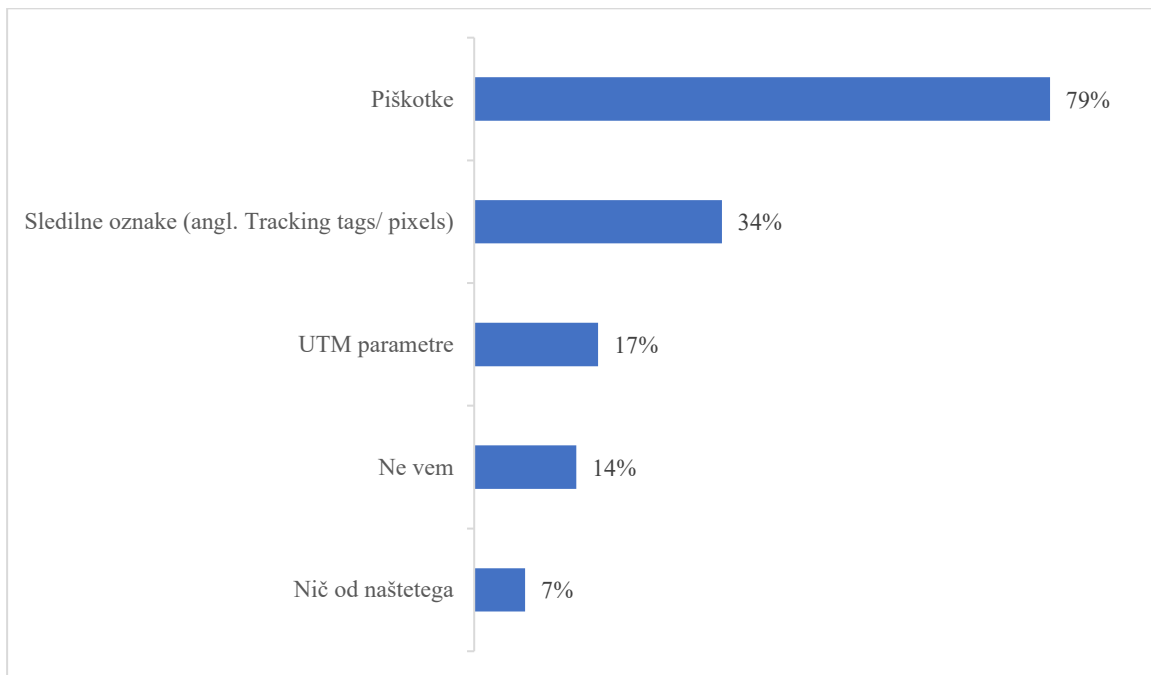


*Vir: lastno delo.*

Osmo vprašanje se nanaša na beleženje vira oz. oglaševalski kanal prihoda obiskovalcev na spletno mesto. Izmed vseh respondentov jih je 77 % (n = 82) odgovorilo, da beležijo vir prihoda obiskovalcev na spletno mesto. Nasprotno je 18 % (n = 19) respondentov odgovorilo, da ne beležijo vira prihoda obiskovalcev na spletno mesto. Preostalih 6 % (n = 6) respondentov ne ve, ali beležijo vir prihoda.

Deveto vprašanje se nanaša na tehnologije, ki jih podjetja uporabljajo pri zbiranju podatkov o porabnikih. Respondentom je bila ponujena možnost, da izberejo enega ali več odgovorov. Rezultati so prikazani na sliki 9. Največ, 79 % (n = 85), respondentov je odgovorilo, da zbirajo podatke o porabnikih s pomočjo piškotkov, s 34 % (n = 37) sledijo sledilne oznake in nato UTM parametri s 17 % (n = 18). Med tem je 14 % (n = 15) respondentov odgovorilo, da ne ve, ali zbirajo podatke o porabnikih ter 7 % (n = 7) respondentov, da ne uporabljajo nič od naštetega.

Slika 9: Tehnologije zbiranja podatkov o porabnikih na spletem mestu (v %)

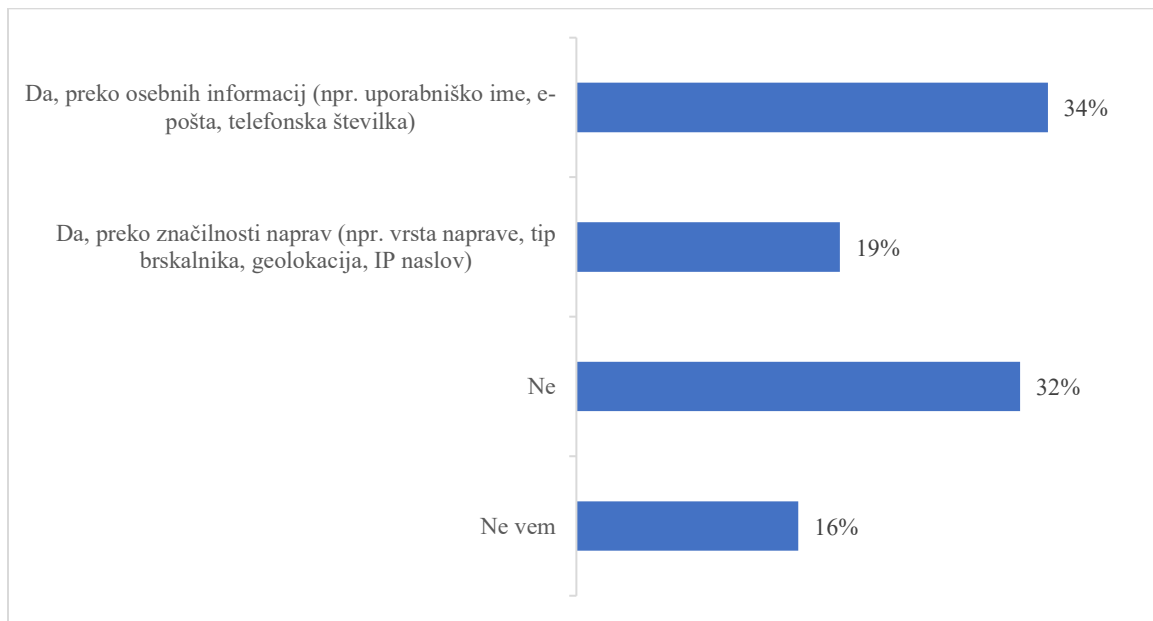


Vir: lastno delo.

Sledi deseto vprašanje, ki se nanaša na uporabo podatkov o porabnikih za oblikovanje nakupne poti. Izmed vseh respondentov jih je 51 % (n = 55) odgovorilo, da uporabljajo zbrane podatke za oblikovanje nakupne poti. Nasprotno je 36 % (n = 39) respondentov odgovorilo, da ne zbirajo podatkov o porabnikih za oblikovanje nakupne poti, 12 % (n = 13) respondentov pa ne ve, ali zbirajo podatke o porabnikih za oblikovanje nakupne poti.

Pri enajstem vprašanju sem preverjal, ali podjetja iste porabnike, ki obiščejo spletno mesto prek različnih naprav (npr. telefon, računalnik, tablica), povezujejo v en podatkovni zapis preko skupnih identifikatorjev. Podatki so prikazani v sliki 10. Izmed vseh respondentov jih je 32 % (n = 34) odgovorilo, da ne povezuje porabnikov med napravami. Respondenti, ki povezujejo porabnike med napravami, to delajo v 34 % (n = 36) preko osebnih informacij ter v 19 % (n = 20) prek značilnosti naprav. Ostalih 16 % (n = 17) respondentov ne ve, ali povezujejo podatke porabnikov.

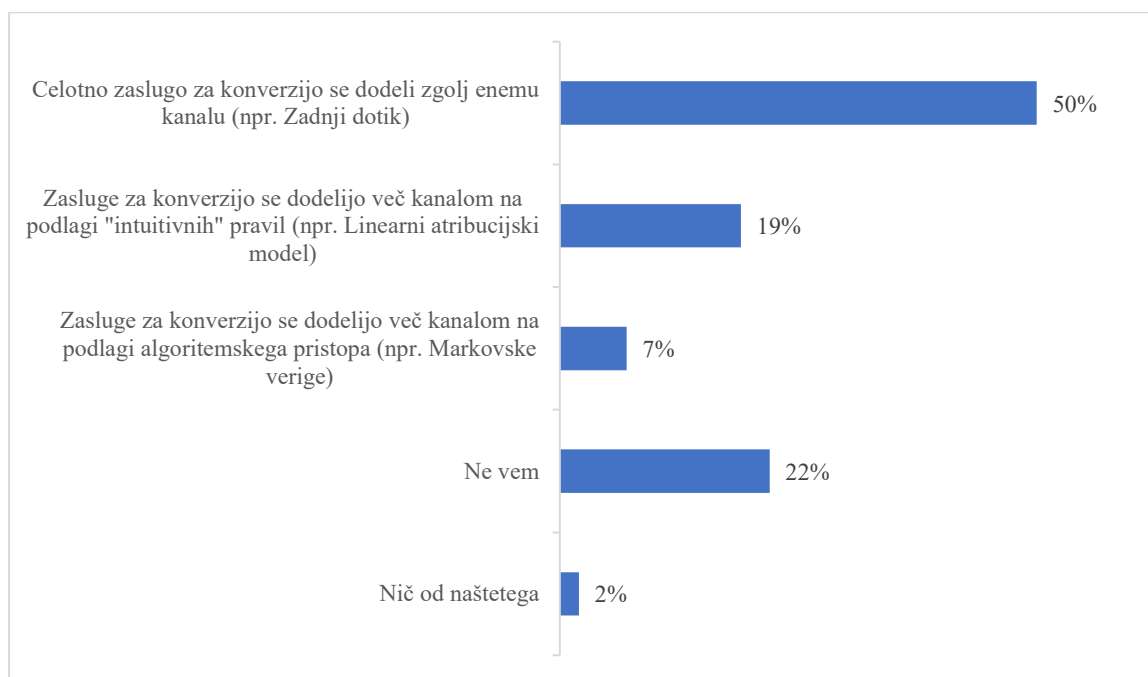
Slika 10: Povezovanje porabnikov, ki obišejo spletno mesto prek več naprav (v %)



Vir: lastno delo.

Dvanajsto vprašanje se nanaša na atribucijske modele, ki jih podjetja uporabljajo pri ovrednotenju doprinosa oglaševalskih kanalov. Na sliki 11 so prikazani rezultati. Največ respondentov, 50 % (n = 53), je odgovorilo, da celotno zaslugo za konverzijo dodelijo zgolj enemu kanalu, z 19 % (n = 20) sledijo respondenti, ki uporabljajo atribucijske modele, ki zasluge za konverzijo dodelijo več kanalom na podlagi »intuitivnih« pravil, med tem ko 7 % (n = 8) respondentov uporablja atribucijske modele, ki zasluge za konverzijo dodelijo več kanalom na podlagi algoritemskega pristopa. Ostali respondenti so v 22 % (n = 20) odgovorili z »Ne vem« ter v 2 % (n = 2) z »nič od naštetega«. Respondenti, ki so izbrali enega izmed navedenih atribucijskih modelov (n = 81), so bili v nadaljevanju vprašani po razlogih za uporabo, dejavnikih pri izbiri in mnenju o trenutnem atribucijskem modelu. Respondenti, ki so odgovorili na dvanajsto vprašanje z »Ne vem« ali »Nič od naštetega«, so prešli na sklop demografskih vprašanj.

Slika 11: Atribucijski modeli pri ovrednotenju doprinosa oglaševalskih kanalov (v %)



Vir: lastno delo.

Sledi trinajsto vprašanje, ki se nanaša na razloge za uporabo atribucijskih modelov. Rezultati so prikazani na sliki 12. Respondentom je bila ponujena možnost, da izberejo enega ali več odgovorov. Največ, 61 % (n = 65), respondentov je odgovorilo, da uporabljajo atribucijske modele za merjenje vrednosti in uspešnosti posameznih oglaševalskih kanalov, 31 % (n = 33) respondentov uporablja atribucijske modele za izboljšanje taktik trženjskih kampanj ter prav tako 31 % (n = 33) respondentov za izboljšanje trženjskih strategij. Za namene merjenja vpliva posameznih trženjskih aktivnosti atribucijske modele uporablja 26 % (n = 28) respondentov, 20 % (n = 21) respondentov uporablja atribucijske modele za merjenje medsebojnega vpliva oglaševalskih kanalov ter 9 % (n = 10) respondentov uporablja atribucijske modele za neposredno izvršitev nakupa oglaševalskega prostora.


Slika 12: Razlogi uporabe atribucijskih modelov (v %)



Vir: lastno delo.

Pri štirinajstem vprašanju sem preverjal, kateri je glavni dejavnik pri izbiri atribucijskega modela. Na sliki 13 so prikazani rezultati. Izmed vseh respondentov jih je največ, 61 % (n = 50), odgovorilo, da je glavni dejavnik pri izbiri enostavnost. 21 % (n = 17) respondentom je najpomembnejša natančnost. Ostalih 18 % (n = 14) respondentov je odgovorilo, da jim je pri modelu atribucije najpomembnejša prilagodljivost.

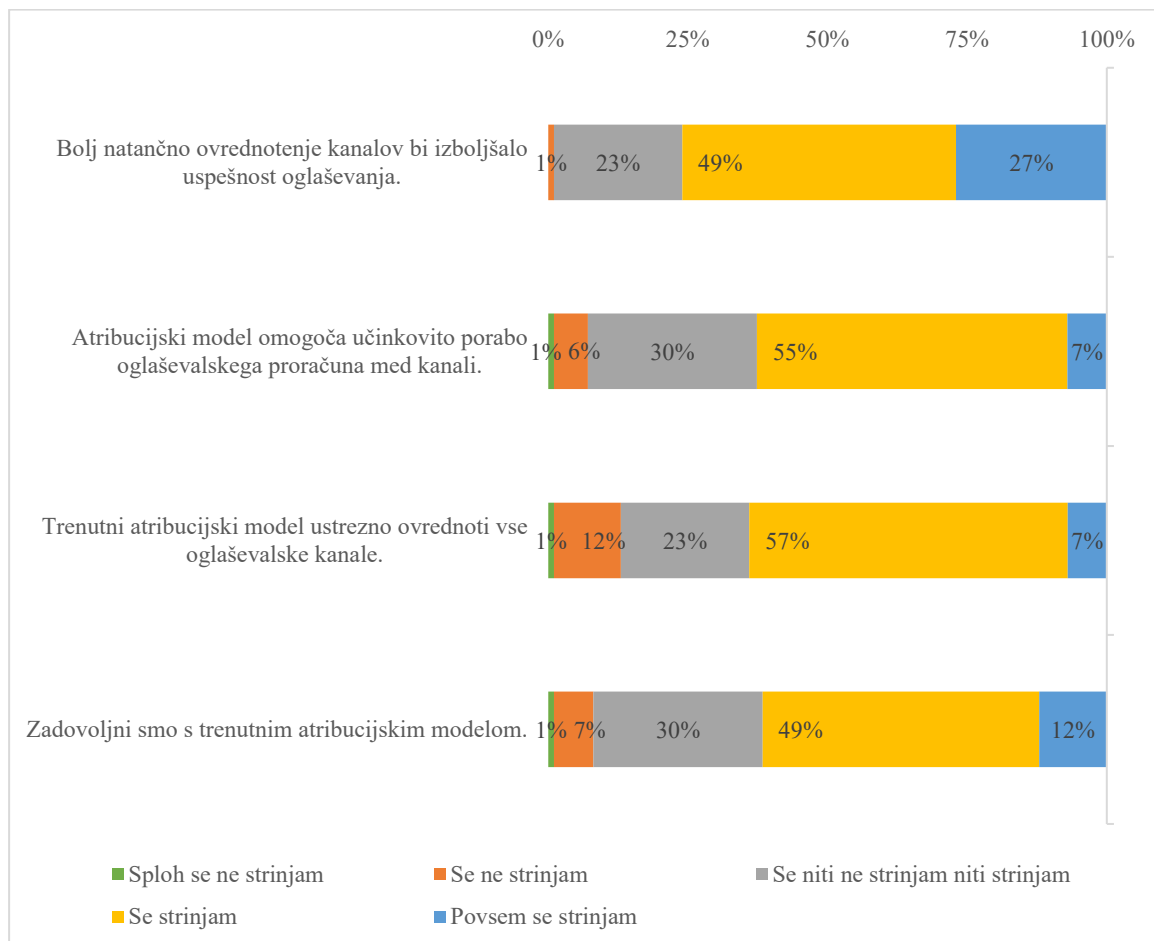
Slika 13: Glavni dejavnik pri izbiri modela atribucije (v %)



Vir: lastno delo.

Petnajsto vprašanje se nanaša na mnenja respondentov o podanih trditvah o trenutnem načinu ovrednotenja oglaševalskih kanalov, ki so jih na Likertovi lestvici ocenjevali z ocenami od 1 do 5, kjer 1 pomeni »sploh se ne strinjam« in 5 »popolnoma se strinjam«. Na sliki 14 so prikazani rezultati. V povprečju so se respondenti najbolj strinjali s trditvijo »Bolj natančno ovrednotenje bi izboljšalo uspešnost oglaševanja.« (AS = 4; SO = 0,75), kjer je kar 76 % respondentov na to vprašanje odgovorilo s popolnim strinjanjem oziroma strinjanjem. Sledi trditev »Zadovoljni smo s trenutnim atribucijskim modelom.« (AS = 3,7; SO = 0,79), kjer se je 61 % respondentov s trditvijo strinjalo ali popolnoma strinjalo. S trditvijo »Trenutni atribucijski model ustrezno ovrednoti vse oglaševalske kanale.« (AS = 3,6; SO = 0,80) so se respondenti v 64 % strinjali ali povsem strinjali. Prav tako so se strinjali s trditvijo »Atribucijski model omogoča učinkovito porabo oglaševalskega proračuna med kanali.« (AS = 3,6; SO = 0,71), kjer je 62 % respondentov odgovorilo s strinjanjem oziroma popolnim strinjanjem.

Slika 14: Mnenja podjetij o trenutnem načinu ovrednotenja oglaševalskih kanalov (v %)

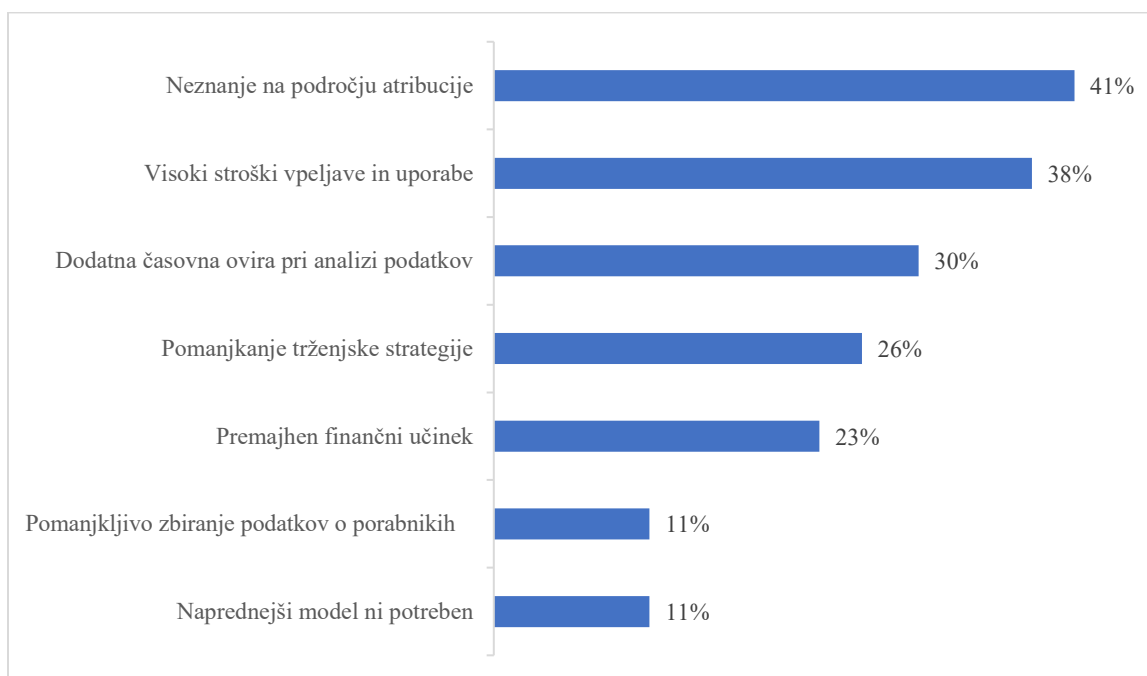


Vir: lastno delo.



Respondenti, ki pri vprašanju petnajst niso izrazili popolnega strinjanja z zadovoljstvom trenutnega atribucijskega modela, so bili v šestnajstem vprašanju vprašani po razlogih, zaradi katerih se ne odločijo za vzpostavitev bolj dovršenega atribucijskega modela. Respondentom je bila ponujena možnost, da izberejo enega ali več odgovorov. Rezultati so prikazani na sliki 15. Največ respondentov, 41 % (n = 30), za razlog navaja neznanje na področju atribucije, z 38 % (n = 28) sledijo respondenti, ki pričakujejo ob vzpostavitvi bolj dovršenega modela višje stroške, 30 % (n = 22) respondentov meni, da bo bolj dovršen model zahteval dodaten čas za analizo, 26 % (n = 19) respondentov za razlog navaja pomanjkanje trženjske strategije, 23 % (n = 19) respondentov za razlog navaja premajhen finančni učinek, 11% (n = 8) respondentov je odgovorilo, da je razlog v pomanjkljivem zbiranju podatkov o porabnikih, medtem ko prav tako 11 % (n = 8) respondentov meni, da naprednejši model ni potreben.

*Slika 15: Razlogi, da podjetja ne vzpostavijo bolj dovršenega modela atribucije (v %)*



*Vir: lastno delo.*

#### 5.4.3 Analiza hipotez

V nadaljevanju poglavja sledi analiza postavljenih hipotez, na osnovi katere podam odgovore na zastavljena raziskovalna vprašanja v magistrskem delu. Podrobnosti pri oblikovanju hipotez so predstavljene v prilogi 2 v pregledni tabeli hipotez in spremenljivk. V tabeli so navedene hipoteze, številke vprašanj v vprašalniku, ki so postavljene za preverjanje posamezne hipoteze, in statistični test, ki sem ga uporabil za obdelavo podatkov in pridobitev končnega statistično pomembnega rezultata.

**H1a: Podjetjem je pri izbiri atribucijskega modela najpomembnejša enostavnost uporabe.**

Postavljena hipoteza se navezuje na štirinajsto vprašanje v anketi, kjer me je zanimalo, kateri je glavni kriterij pri izbiri atribucijskega modela. Kot je razvidno iz tabele 4, je pri vprašanju največ, kar 61 % (n = 50), respondentov odgovorilo, da je glavni kriterij enostavnost uporabe. Le 21 % (n = 17) respondentov je odgovorilo, da je najpomembnejša natančnost atribucijskega modela. Ostalih 18 % (n = 14) respondentov je odgovorilo, da jim je pri modelu atribucije najpomembnejša prilagodljivost.

*Tabela 4: Frekvence za test enake verjetnosti za H1a*

	Opazovano št.	Pričakovano št.	Ostanek
Enostavnost	50	27	23
Prilagodljivost	14	27	-13
Natančnost	17	27	-10
Skupaj	81		

*Vir: lastno delo.*

Hipotezo sem preverjal s pomočjo testa enake verjetnosti. S testom sem želel preveriti, ali so vsi odgovori enako pogosti oz. ali kakšen odgovor prevladuje. Rezultati testa kažejo, da je p-vrednost pod 0,05 ( $p > 0,05$ ), kar pomeni, da ničelno domnevo zavrnamo in sprejmemo  $H_1$ , pri 5 % stopnji značilnosti. Na podlagi rezultatov analize v tabeli 5 lahko potrdim, da obstaja razlika med opazovanim in pričakovanim številom frekvenc. Med vsemi odgovori respondentov prevladuje kriterij enostavnost uporabe.

*Tabela 5: Rezultati testa enake verjetnosti za H1a*

Test enake verjetnosti	
Hi-kvadrat	29,556
Stopinji prostosti	2
P-vrednost	0,000

*Vir: lastno delo.*

**H1b: Podjetja se strinjajo, da njihov atribucijski model ustrezno ovrednoti vse oglaševalske kanale.**

Postavljena hipoteza se navezuje na petnajsto vprašanje v anketi, kjer so respondenti izrazili strinjanje oziroma nestrinjanje z drugo trditvijo »Trenutni atribucijski model ustrezno ovrednoti vse oglaševalske kanale.« Hipotezo sem preverjal s T-testom za en vzorec. Ta test sem uporabil zato, da sem lahko ugotovil, ali se povprečna vrednost strinjanja s to trditvijo statistično pomembno razlikuje od testne vrednosti. V tabeli 6 lahko vidimo, da je povprečje 3,6, standardni odklon je 0,80, standardna napaka pa je 0,09

Tabela 6: Opisna statistika za T-test za en vzorec za H1b

Opisna statistika T-test za en vzorec				
	n	Povprečje	Std. Odklon	Std. Napaka povprečij
<b>Atribucijski model ustrezno ovrednoti vse oglaševalske kanale.</b>	81	3,6	0,80	0,09

Vir: lastno delo.

Rezultati T-testa v tabeli 7 kažejo, da je t vrednost 6,644, stopnja prostosti je 80 in p-vrednost je 0,000. Vidimo, da je p-vrednost pod 0,05 ( $0,000 < 0,05$ ). Dejansko povprečje 3,6 je statistično značilno višje od testnega. To pomeni, da ničelno domnevo zavrnamo in sprejmemo  $H_1$  pri 5 % stopnji značilnosti.

Tabela 7: Rezultati T-testa za en vzorec za H1b

T-test za en vzorec						
	Testna vrednost = 3					
	t	g	P-vrednost	Razlika povprečij	95% Interval zaupanja	
					Nizki	Visoki
<b>Atribucijski model ustrezno ovrednoti vse oglaševalske kanale.</b>	6,644	80	0,000	0,59	0,42	0,77

Vir: lastno delo.

## H2: Natančnejše zbiranje podatkov o porabnikih vodi v izbiro bolj dovršenega modela atribucije.

Postavljena hipoteza se navezuje na deveto vprašanje v anketi, kjer sem respondente spraševal, katere tehnologije uporabljajo pri zbiranju podatkov o porabnikih na spletnem mestu: piškotke, sledilne oznake in/ali UTM-parametre. Za ugotavljanje povezanosti med atribucijskimi modeli (z enim ali več dotiki) in tehnologijami zbiranja podatkov sem uporabil Hi-kvadrat test za preizkus hipoteze neodvisnosti. Pričakoval sem, da bodo podjetja, ki uporabljajo tehnologije zbiranja podatkov, bolj verjetno uporabljala modele z več dotiki. Podatki za ugotavljanje povezanosti med atribucijskimi modeli in tehnologijami zbiranja podatkov so prikazani v navzkrižni tabeli. Iz tabele 8 je razvidno, da velika večina respondentov ( $n = 68$ ), ki uporablja atribucijske modele, hkrati uporablja tehnologije za zbiranje podatkov o porabnikih. Izjema je le pet respondentov, ki ne uporabljajo nobenih tehnologij za sledenje porabnikom na spletnem mestu. Sklepal sem, da bodo tista podjetja, ki uporabljajo tehnologije za sledenje, bolj verjetno uporabljala model z več dotiki.

Tabela 8: Navzkrižna tabela: Atribucijski model in zbiranje podatkov

			Tehnologije zbiranja podatkov		Skupaj
			Da	Ne	
<b>Atribucijski model</b>	En dotik	Število	44	4	48
		Pričakovano število	44,7	3,3	48,0
	Več dotikov	Število	24	1	25
		Pričakovano število	23,3	1,7	25,0
Skupaj		Število	68	5	73
		Pričakovano število	68,0	5,0	73,0

Vir: lastno delo.

Za kakovostne rezultate Pearsonovega Hi-kvadrata mora biti izpolnjen pogoj, da je 20 % najvišji dovoljeni delež pričakovanih frekvenc, manjših od 5, in nobena ne sme biti manjša od 1. Kot je razvidno iz tabele 9, pogoji za Pearsonov Hi-kvadrat niso bili izpolnjeni, zato sem upošteval Kullbackov preizkus. Rezultati Kullbackovega testa kažejo, da je p-vrednost nad 0,05 ( $p > 0,05$ ), kar pomeni, da ničelno domnevo sprejememo, pri 5 % stopnji značilnosti. Na podlagi rezultatov analize ne moremo trditi, da uporaba tehnologij sledenja vodi v izbiro bolj dovršenega modela.

Tabela 9: Rezultati za Hi-kvadrat test za H2

	Vrednost	Stopnja prostosti	P-vrednost
Pearsonov hi-kvadrat	0,484	1	0,487
Kullbackov preizkus	0,526	1	0,468
Linearna povezanost	0,477	1	0,490
n	73		

a. 2 celice (50%) imata manj kot 5 pričakovanih frekvenc.

Vir: lastno delo.

**H3: Podjetja, ki uporabljajo model z več dotiki, se bolj strinjajo, da učinkoviteje porabljajo oglaševalski proračun med kanali kot podjetja, ki uporabljajo model z enim dotikom.**

Postavljena hipoteza se navezuje na petnajsto vprašanje v anketi, kjer so respondenti izrazili (ne)strinjanje s tretjo trditvijo »Atribucijski model omogoča učinkovito porabo oglaševalskega proračuna med kanali.« Hipotezo sem preverjal s pomočjo T-testa za dva neodvisna vzorca. Želel sem preveriti, ali obstajajo statistično značilne razlike v učinkovitosti porabe oglaševalskega proračuna med podjetji, ki uporabljajo atribucijski model z enim dotikom, in podjetji, ki uporabljajo model z več dotiki.

Tabela 10: Opisna statistika T-test za neodvisna vzorca za H3

Opisna statistika T-test za neodvisna vzorca					
	Modeli	n	Aritmetična sredina	Standardni odklon	Standardna napaka
Učinkovita poraba oglaševalskega proračuna	En dotik	53	3,5	0,80	0,11
	Več dotikov	28	3,9	0,42	0,08

Vir: lastno delo.

Iz rezultatov T-testa za dva neodvisna vzorca v tabeli 11 je razvidno, da je ob predpostavki o heterogenosti varianc ( $F = 24,765$  ;  $\alpha = 0,001$ ) T-test za neodvisne spremenljivke pokazal statistično značilne razlike ( $t = -2,839$  ;  $g = 78,9$  ;  $\alpha = 0,006$ ) med modeli z enim dotikom in modeli z več dotiki. To pomeni, da ničelno domnevo zavrnamo in sprejmemo  $H_1$ , pri 5% stopnji značilnosti. Rezultati analize kažejo, da so respondenti, ki uporabljajo atribucijske modele z več dotiki, ocenili, da učinkoviteje porabijo oglaševalski proračun kot respondenti, ki uporabljajo atribucijske modele z enim dotikom.

Tabela 11: Rezultati za T-test za neodvisna vzorca za H3

Učink. poraba oglašev. prorač.		Levinov test o enakosti dveh varianc		T-test o enakosti aritmetičnih sredin						
		F	p	t	g	P (2-stransko)	Srednja razlika	St. napaka razlike	95% interval zaupanja	
									Sp. meja	Zg. meja
	Predpostavka o enakosti varianc	24,765	0,001	-2,369	79	0,020	-0,383	0,16	-0,706	-0,061
	Predpostavka o neenakosti varianc			-2,839	78,9	0,006	-0,383	0,16	-0,652	-0,115

Vir: lastno delo.

#### H4: Podjetja, ki uporabljajo večje število oglaševalskih kanalov, izbirajo bolj dovršene atribucijske modele.

Postavljena hipoteza se navezuje na četrto vprašanje v anketi, kjer me je zanimalo, kateri so kanali oglaševanja, ki jih podjetja uporabljajo pri predstavitvi na spletu. Hipotezo sem preverjal s pomočjo T-testa za dva neodvisna vzorca, pri čemer je bilo potrebno tudi prekoderirati odgovore. Tako sem seštel vse oglaševalske kanale, ki jih je posamezno podjetje izbralo v vprašalniku, ter jih kodiral v novo spremenljivko z oznakami od 1 do 5 (1 = en kanal, 5 = pet kanalov). Na podlagi testa sem želel preveriti, ali obstajajo statistično značilne

razlike v številu kanalov med podjetji, ki uporabljajo atribucijski model z enim dotikom, in podjetji, ki uporabljajo model z več dotiki.

Tabela 12: Opisna statistika T-test za neodvisna vzorca za H4

Opisna statistika T-test za neodvisna vzorca					
	Modeli	n	Aritmetična sredina	Standardni odklon	Standardna napaka
Število kanalov	En dotik	53	2,1	1,07	0,15
	Več dotikov	28	2,6	1,31	0,25

Vir: lastno delo.

Iz rezultatov v tabeli 13 je razvidno, da je ob predpostavki o homogenosti varianc ( $F = 1,463$  ;  $\alpha = 0,230$ ) T-test za neodvisne spremenljivke pokazal statistično značilne razlike v številu oglaševalskih kanalov ( $t = -2,095$  ;  $g = 79$ ;  $\alpha = 0,039$ ) med podjetji, ki uporabljajo modele z enim dotikom in modele z več dotiki. To pomeni, da ničelno domnevo zavrnilo in sprejmemo  $H_1$ , pri 5% stopnji značilnosti. Rezultati analize kažejo, da podjetja, ki uporabljajo večje število kanalov, pogosteje izbirajo atribucijske modele z več dotiki.

Tabela 13: Rezultati za T-test za neodvisna vzorca za H4

Število kanalov		Levinov test o enakosti dveh varianc		T-test o enakosti aritmetičnih sredin						
		F	p	t	g	P (2-stransko)	Srednja razlika	St. napaka razlike	95% interval zaupanja	
									Sp. meja	Zg. meja
Število kanalov	Predpostavka o enakosti varianc	1,463	0,230	-2,095	79	0,039	-0,567	0,27	-1,106	-0,028
	Predpostavka o neenakosti varianc			-1,969	46,4	0,055	-0,567	0,29	-1,147	-0,0126

Vir: lastno delo.

### H5: Tržniki uporabljajo zbrane podatke o porabnikih pri oblikovanju nakupne poti kupca.

Postavljena hipoteza se navezuje na deseto vprašanje v anketi, kjer sem respondente spraševal, ali zbrane podatke uporabljajo pri oblikovanju nakupne poti. V tabeli 14, ki prikazuje rezultate testa, je možno videti, da sem anketirance razdelil v dve skupni. V skupino 1 so vključeni anketiranci, ki uporabljajo zbrane podatke o porabnikih za oblikovanje nakupne poti, v skupino 2 pa so vključeni anketiranci, ki ne uporabljajo zbranih

podatkov za oblikovanje nakupne poti. Delež prve skupine je znašal 59 %, delež druge skupine pa 41 %.

Tabela 14: Rezultati za test deležev za H5

Test deležev						
		Kategorija	n	Preučevan delež	Testiran delež	P-vrednost
<b>Oblikovanje nakupne poti kupca?</b>	Skupina 1	Da	55	0,59	0,5	0,121
	Skupina 2	Ne	39	0,41		
	Skupaj		94	1,00		

*Vir: lastno delo.*

Preverjal sem pri 50 %, ali večina tržnikov uporablja zbrane podatke o porabnikih za oblikovanje nakupne poti. Rezultati testa deležev v tabeli 14 kažejo, da je p-vrednost 0,121. Vidimo, da je p-vrednost nad 0,05, kar pomeni, da ničelno domnevo sprejmemo pri 5 % stopnji značilnosti. Na podlagi rezultatov analize ni mogoče trditi, da tržniki uporabljajo zbrane podatke o porabnikih za oblikovanje nakupne poti.

#### 5.4.4 Interpretacija rezultatov hipotez

V nadaljevanju predstavljam ugotovitve empirične raziskave. V tabeli 15 so podane hipoteze in rezultati njihovega preverjanja.

Tabela 15: Pregled ugotovitev preverjanja raziskovalnih hipotez

	Raziskovalna hipoteza	Rezultat
<b>H1a</b>	Podjetjem je pri izbiri atribucijskega modela najpomembnejša enostavnost uporabe.	Sprejemem
<b>H1b</b>	Podjetja se strinjajo, da njihov atribucijski model ustrezno ovrednoti vse oglaševalske kanale.	Sprejemem
<b>H2</b>	Natančnejše zbiranje podatkov o porabnikih vodi v izbiro bolj dovršenega modela atribucije.	Ne morem sprejeti
<b>H3</b>	Podjetja, ki uporabljajo model z več dotiki, se bolj strinjajo, da učinkoviteje uporabljajo oglaševalski proračun med kanali kot podjetja, ki uporabljajo model z enim dotikom.	Sprejemem
<b>H4</b>	Podjetja ki uporabljajo večje število oglaševalskih kanalov, izbirajo bolj dovršene atribucijske modele.	Sprejemem
<b>H5</b>	Tržniki uporabljajo zbrane podatke o porabnikih pri oblikovanju nakupne poti kupca.	Ne morem sprejeti

*Vir: lastno delo.*

Pri H1a sem preverjal, kateri kriterij izbire je najpomembnejši za respondente pri izbiri atribucijskega modela. Rezultati moje raziskave so pokazali, da je za 61 % respondentov glavni kriterij izbire enostavnost uporabe. Spoznanja avtorjev Jayawardane, Halgamuge in Kayande (2015), da so tržniki zaradi enostavnosti uporabe in intuitivnega razumevanja pripravljani sprejeti kompromis z natančnostjo modela ter da ne vidijo dovolj dodane

vrednosti v atribucijskih modelih z več dotiki, potrjujejo tudi ugotovitve moje raziskave. Ta kriterij izbire je izrazito viden, ker so v raziskavi sodelovala predvsem manjša podjetja, ki želijo s poenostavljenimi atribucijskimi modeli z enim dotikom zadovoljivo ovrednotiti doprinos posameznih oglaševalskih kanalov.

Pri H1b sem preverjal, ali se podjetja strinjajo, da atribucijski model ustrezno ovrednoti vse oglaševalske kanale. Uporaba atribucijskih modelov, ki ustrezno ovrednotijo oglaševalske kanale, je ključna pri učinkovitem dodeljevanju oglaševalskega proračuna med kanali. V raziskavi so odgovori respondentov potrdili mojo hipotezo, da atribucijski modeli ustrezno ovrednotijo vse oglaševalske kanale. Kljub temu pa je največ, kar 76 % respondentov, odgovorilo, da bi bolj natančno ovrednotenje izboljšalo uspešnost oglaševanja, pri čemer lahko sklepamo, da tržniki v bolj dovršenih modelih atribucije vidijo dodatne koristi. Vendar teh modelov zaradi raznolikih dejavnikov, kot npr. nezbiranje podatkov, neznanje na področju atribucije ali dodatni finančni stroški, niso pripravljeni vpeljati (Ferencova, Jelenova & Kakalejcík, 2015).

Pri H2 sem preverjal, ali natančnejše zbiranje podatkov o porabnikih s tehnologijami sledenja vodi v izbiro bolj dovršenega modela. Po mnenju avtorja Taffs (2018) uporaba širokega nabora naprednih tehnologij za zbiranje podatkov o porabnikih tržnikom dovoljuje, da se pri nadaljnji analizi usmerjajo v bolj dovršene atribucijske modele. Slednji med drugim ponujajo tržnikom koristne vpogled v uspešnost posameznih kanalov ter pogoste premike porabnikov med kanali na nakupni poti. V moji raziskavi je vidno, da kar 93 % respondentov, ki uporablja atribucijske modele, hkrati uporablja vsaj eno vrsto tehnologij za zbiranje podatkov o porabnikih na spletnem mestu. Vendar na podlagi analize ne morem potrditi hipoteze, da uporaba tehnologij za zbiranje podatkov o porabnikih vodi v izbiro bolj dovršenega modela atribucije. Razlog za to vidim predvsem v tem, da manjša podjetja stremijo k uporabi poenostavljenih atribucijskih modelov, kljub temu da bi lahko na podlagi izbranih tehnologij sledenja izbirala tudi med bolj dovršenimi modeli z več dotiki.

Pri H3 sem preverjal, ali se podjetja, ki uporabljajo bolj dovršene atribucijske modele z več dotiki, bolj strinjajo, da učinkoviteje porabljajo oglaševalski proračun med kanali kot podjetja, ki uporabljajo model z enim dotikom. Raziskava avtorja Shao in Li (2011) nakazuje, da atribucijski modeli z več dotiki tržnikom prinašajo natančnejše vpogled v uspešnost kanalov, ki jih lahko tržniki izkoristijo za prilagajanje porabe oglaševalskega proračuna med kanali. To hipotezo sem preverjal na podlagi strinjanja respondentov s trditvijo »Atribucijski model omogoča učinkovito porabo oglaševalskega proračuna med kanali«. Aritmetična sredina pri podjetjih, ki uporabljajo model z enim dotikom, je bila statistično značilno nižja kot pri podjetjih, ki uporabljajo modele z več dotiki. Rezultati raziskave potrjujejo mojo hipotezo, da se podjetja z atribucijskimi modeli z več dotiki močneje strinjajo, da jim ti modeli omogočajo učinkovitejšo porabo oglaševalskega proračuna v primerjavi s podjetji z atribucijskimi modeli z enim dotikom.



Pri H4 sem preverjal, ali podjetja, ki uporabljajo večje število oglaševalskih kanalov, izbirajo bolj dovršene atribucijske modele. Ker podjetja v oglaševalskih kampanjah vedno pogosteje uporabljajo več kanalov hkrati, je potreba po bolj dovršenih modelih atribucije vedno večja (IAB, 2012). To hipotezo potrjuje tudi moja raziskava, kjer se je pokazalo značilno višje povprečje uporabljenih komunikacijskih kanalov za podjetja, ki uporabljajo modele z več dotiki. Rezultati moje raziskave se sovpadajo s predhodnimi raziskavami, ki pravijo, da podjetja, ki uporabljajo večje število kanalov, v želji po večji natančnosti pogosteje izbirajo atribucijske modele z več dotiki (Anderl, Becker, Wangenheim & Schumann, 2013).

Pri H5 sem preverjal, ali tržniki uporabljajo zbrane podatke o porabnikih pri oblikovanju nakupne poti kupca. Todri (2016) pravi, da zmožnost sledenja porabnikom v spletnem okolju vodi v prilagajanje nakupne poti z namenom povečanja števila konverzij na spletnem mestu. Z rezultati moje raziskave domneve, da tržniki uporabljajo zbrane podatke o porabnikih za oblikovanje nakupne poti, ne morem potrditi. Razlog, da kar 41 % ( $n = 39$ ) respondentov ne uporablja zbranih podatkov za oblikovanje nakupne poti, vidim predvsem v tem, da gre v raziskavi za manjša podjetja, ki v povprečju uporabljajo 2 oglaševalska kanala ter enostavne modele atribucije. Ugotavljam, da se podjetja na podlagi omejenih možnosti oblikovanja nakupne poti in pomanjkljivega zbiranja ter analize podatkov ne odločajo za prilagajanje nakupne poti strank.

#### 5.4.5 Ugotovitve raziskave

Na podlagi teoretičnih izhodišč ter primarne kvantitativne raziskave želim v nadaljevanju predstaviti ugotovitve raziskave, in sicer: kako pristopajo podjetja k zbiranju podatkov o porabnikih, da lahko izberejo ustrezen atribucijski model, kateri so najbolj učinkoviti modeli atribucije, ki ustrezno ovrednotijo prispevek posameznih oglaševalskih kanalov, ter katere podatke o porabnikih potrebuje podjetje, da lahko omogoči natančnost modela atribucije in odkriva ključne korake.

Prvo raziskovalno vprašanje se nanaša na pristop k zbiranju podatkov, na podlagi katerih lahko podjetja izberejo ustrezen atribucijski model. Na podlagi analize rezultatov ugotavljam, da v manjših podjetjih prevladuje želja po enostavnosti, to nakazuje tudi trinajsto vprašanje, kjer 61 % respondentov za glavni kriterij izbire atribucijskega modela navaja enostavnost uporabe. Razlog za ta pristop je mogoče pripisati tudi uporabi pomanjkljivih tehnologij za zbiranje podatkov o porabnikih na spletnem mestu, kot so npr. piškotki, ki vodijo k uporabi poenostavljenih atribucijskih modelov z enim dotikom. Vendar po podatkih moje kvantitativne raziskave nekoliko presenetljivo zgolj 11 % respondentov meni, da je razlog za nevpeljavo bolj dovršenega modela v pomanjkljivem zbiranju podatkov o porabnikih. Predvsem se je v kvantitativni raziskavi izkazalo, da podjetja vidijo ključni vzrok, za nevzpostavitev bolj naprednega atribucijskega modela v neznanju na področju atribucije. Medtem pa za ostale razloge podjetja navajajo stroške vpeljave in uporabe, dodaten čas za analizo, pomanjkanje trženjske strategije in premajhen finančni učinek.

Drugo raziskovalno vprašanje se nanaša na najbolj učinkovite modele atribucije, ki ustrezno ovrednotijo prispevek posameznih oglaševalskih kanalov. Iz raziskave je razvidno, da podjetja, ki uporabljajo modele atribucije z več dotiki, ocenjujejo, da učinkoviteje porabijo oglaševalski proračun med več kanali kot podjetja, ki uporabljajo modele z enim dotikom. Prav tako je mogoče v raziskavi zaznati, da z večanjem števila kanalov tržniki pogosteje uporabljajo modele z več dotiki. Te ugotovitve so skladne s pregledom znanstvene literature na področju atribucije. Te obravnavajo številne algoritemske pristope z več dotiki z namenom, da bi premagale slabosti poenostavljenih modelov (Nisar & Yeung, 2018). Čeprav v marsikaterem manjšem podjetju izbira algoritemskega atribucijskega modela ni smiselna, to ne velja za modele, ki temeljijo na podlagi »intuitivnih« pravil. Slednji v primerjavi s poenostavljenimi modeli, ki zaslugo za konverzijo dodelijo zgolj zadnjemu kanalu, tržnikom ponujajo natančnejše ovrednotenje doprinosa posameznih kanalov ter hkrati omogočajo boljši pregled nad premiki strank na nakupnih poti.

Tretje raziskovalno vprašanje se nanaša na zbiranje podatkov o porabnikih, ki dovoljujejo podjetju, da omogoči natančnost modela atribucije in odkriva ključne korake na nakupni poti. Vzpostavitev tehnologij sledenja na spletnem mestu je poglavitno za zbiranje podatkov ter nadaljnjo analizo učinkovitosti posameznih kanalov kot tudi medsebojno dinamiko pri večkanalnem oglaševanju (Anderl, Becker, Wangenheim & Schumann, 2013). Kot je vidno iz raziskave 79 % respondentov pri sledenju porabnikov uporablja piškotke, kar sovпада tudi z deležem pritrtilnih odgovorov na vprašanje glede beleženja vira oz. oglaševalski kanal prihoda porabnikov na spletno mesto, ki znaša 77 %. Zgolj na podlagi piškotkov je mogoča uporaba predvsem poenostavljenih atribucijskih modelov, medtem ko bolj dovršeni atribucijski modeli praviloma zahtevajo tudi druge tehnologije sledenja, kot npr. sledilne oznake ali UTM-parametri. V raziskavi presenetljivo kar 53 % podjetij povezuje porabnike, ki obišejo spletno mesto preko več različnih naprav (npr. telefon, računalnik, tablica) v en podatkovni zapis. Kljub temu da se v manjših podjetjih pogosto soočajo tako z omejenimi finančni sredstvi kot tudi človeškimi viri, lahko zaključim, da je natančnost zbiranja podatkov na spletnih mestih zelo dobra.

#### 5.4.6 Implikacije za podjetja

To magistrsko delo ponuja tržnikom širši vpogled in razumevanje pri oblikovanju ustreznega večkanalnega atribucijskega modela. Kot predstavljeno je področje atribucije zelo obsežno in hitro spreminjajoče, zaradi česar uporaba atribucijskega modela zahteva dodatno nadaljnje prilagajanje in posodabljanje. Zahteve po spremembah so tako na strani potreb tržnikov po natančnejšem merjenju uspešnosti oglaševalskih kampanj kot tudi na strani ponudnikov oglaševalskega prostora, sledilnih tehnologij na spletnih mestih ter zakonodaje in smernic pri zbiranju podatkov. Zaradi same raznolikosti potreb po merjenju med podjetji univerzalni atribucijski model ne obstaja. Pri izbiri modela morajo podjetja upoštevati vidike, kot so npr. velikost podjetja oz. število zaposlenih, finančna sredstva, številčnost

podatkov, znanje na področju atribucije, uporaba tehnologij za sledenje in analitičnih orodij itd. (Xu & Whinston, 2014). Kot ugotavljam v moji raziskavi med podjetji prevladuje uporaba poenostavljenih atribucijskih modelov z enim dotikom. Smiselno je, da tržniki predvsem zaradi nenatančnosti poenostavljenih modelov začnejo prehajati na modele, ki dodelijo ovrednoteni prispevek za konverzije več kanalom na podlagi intuitivnih pravil ali na podlagi podatkovnega pristopa.

Za namene natančnega dodeljevanja konverzij med oglaševalskimi kanali velja, da je potrebno izbrani model atribucije uskladiti s cilji trženjske strategije. Pri oblikovanju podatkovnega pristopa morajo podjetja uporabljati sodobne tehnologije sledenja obiskovalcem na spletnih mestih. Te tehnologije omogočajo, da atribucijski model temelji zbranih na podatkih, kjer so zajeti vsi vidiki oglaševalske kampanje (npr. odzivi na oglase, premiki med kanali, konverzije). Podjetja se morajo pri tem osredotočiti predvsem na natančno zbiranje podatkov na ravni obiskovalca, saj ti podatki predstavljajo izhodišče za nadaljnjo analizo. Kot je vidno v moji raziskavi, podjetja v veliki večini k zbiranju podatkov pristopajo nenatančno oz. neustrezno, da bi lahko vpeljala bolj dovršene atribucijske modele z več dotiki. S tem namenom sem v drugem poglavju podrobneje predstavil tehnologije zbiranja podatkov znotraj naprave in med napravami. Te napredne tehnologije sledenja omogočajo tržnikom, da na podlagi zbranih podatkov objektivno ovrednotijo doprinos posameznih oglaševalskih kanalov ter služijo kot vpogled v premike porabnikov na nakupni poti do končne konverzije (Jayawardane, Halgamuge & Kayande, 2015).

Z magistrskim delom želim spodbuditi podjetja, ki trenutno k digitalni atribuciji pristopajo zelo pomanjkljivo, ter jim predstaviti priložnosti za napredek na področju spletne atribucije. S tem namenom sem v delu predstavil ključne dejavnike, katerim je potrebno posvetiti pozornost pri zbiranju ter nadaljnji analizi podatkov s pomočjo izbranega atribucijskega modela. Doprnos uporabe atribucijskih modelov in natančnega dodeljevanja konverzij je viden predvsem pri vprašanjih, kot so: razporejanje oglaševalskega proračuna med kanali, merjene učinkovitosti oglaševalskih kanalov, napovedovanje premikov med kanali in oblikovanje trženjskih strategij. To se je pokazalo tudi v moji raziskavi, kjer podjetja, ki uporabljajo model z več dotiki, menijo, da bolj učinkovito porabljajo oglaševalski proračun med kanali kot podjetja, ki uporabljajo model z enim dotikom. S tem, ko tržniki izkoriščajo doprinos atribucije s pomočjo naprednih atribucijskih modelov z več dotiki, ti pridobijo vedno natančnejše vpoglede v uspešnost oglaševalskih kampanj in temu primerno učinkovito porabo proračuna med oglaševalskimi kanali (Shao & Li, 2011).

#### 5.4.7 Omejitve raziskave in priporočila

Omejitve kvantitativne raziskave so povezane predvsem s slabostmi spletne ankete. Pri tem je bilo doseganje oseb, ki so zadolžene za spletno analitiko v podjetjih, ena glavnih omejitev moje raziskave. Praviloma osebe, ki niso zadolžene za spletno analitiko, ne poznajo tematike ter hkrati nimajo popolnih informacij o delovanju trženja v podjetju. Pri pregledu anket je

zato razmeroma veliko število enot, ki so izbrale možnost »Ne vem« ali pa so pomanjkljivo izpolnile vprašalnik. Zato obstaja verjetnost, da delež respondentov ni imel dovolj informacij o poslovanju podjetja. Prav tako zaradi nezmožnosti nadziranja okolja zbiranja podatkov obstaja velika možnost, da respondenti anketo zgolj na hitro preleteli, ne da bi prebrali vse odgovore. Za sodelovanje v anketi so se hkrati odločala predvsem manjša podjetja, kar je vplivalo na samo usmeritev kvantitativne raziskave v poenostavljene atribucijske modele.

Pri pisanju magistrskega dela sem naletel tudi na težavo pomanjkanja ustrezne raziskovalne literature na področju primerjave pristopov k izbiri atribucijskih modelov med tržniki. Velika večina tujih znanstvenih raziskav na področju digitalne atribucije temelji na analizi obstoječih atribucijskih modelov z zbirkami podatkov izbranih podjetij. Te raziskave so osredotočene predvsem na predstavitev posameznih atribucijskih modelov ter ocenjevanje njihove natančnosti pri dodeljevanju zaslug med oglaševalskimi kanali. V kvantitativni raziskavi iz tega razloga tako nisem obravnaval razlik med rezultati moje raziskave in pristopi drugih podjetij k izbiri atribucijskega modela. Kljub omenjenim omejitvam menim, da sem z izbrano metodologijo dosegel cilje raziskovalne naloge in podal nekaj glavnih značilnosti podjetij pri oblikovanju atribucijskih modelov.

Z nenehnim razvojem spletne analitike in atribucijskih modelov se ponujajo priložnosti za nadaljnje raziskave. Te vidim predvsem v kvalitativnih raziskavah oz. poglobljenih intervjujih z večjimi podjetji ter analizah obstoječih atribucijskih modelov podjetij. Ta način raziskav bi omogočil veliko bolj praktično razumevanje tematike, na podlagi katere bi bilo mogoče pridobiti koristne vpoglede v aktivnosti podjetij na področju atribucije. Pri tem je potrebno opomniti, da navkljub zagotovitvi o anonimnosti v večjih podjetjih informacije o spletni analitiki ter atribuciji pogosto postanejo zaupne oziroma poslovna skrivnost, kar je bil, predvidevam, tudi eden izmed dejavnikov za neodgovore v moji anketi.

## **SKLEP**

Namen magistrskega dela je bil predstaviti razliko med atribucijskimi modeli, ki dodelijo prispevek enemu ali več oglaševalskim kanalom, ki vplivajo na končno odločitev porabnika za konverzijo. V okviru tega sem naredil širši pregled strokovne in znanstvene literature na področju atribucije. Na podlagi predstavljene tematike sem med podjetji, ki prodajo prek spleta, izvedel podrobno raziskavo s pomočjo spletne ankete. Na osnovi pridobljenih rezultatov sem pripravil analizo in odgovoril na tri raziskovalna vprašanja s preverjanjem šestih hipotez, oblikovanih na podlagi teoretičnih izhodišč. Z raziskavo sem želel prispevati k poznavanju atribucijskih modelov, ki omogočajo podjetjem natančnejše ovrednotenje večkanalnega spletnega oglaševanja. Menim, da mi je tekom dela uspelo z izpolnitvijo ciljev, ki sem si jih zastavil na podlagi teoretičnih izhodišč oziroma raziskav na področju atribucije v oglaševanju. Upam, da bodo pregled iz literature in ugotovitve iz raziskave v pomoč tržnikom pri oblikovanju atribucijskih modelov, ki bodo omogočali objektivno ovrednotenje vseh oglaševalskih kanalov.

Atribucija v oglaševanju velja za pomemben vir vpogledov, ki pomaga pri splošni interpretaciji in trženjskem načrtovanju. Na podlagi atribucijskih modelov tržniki merijo vrednosti različnih taktik spletnega oglaševanja, vendar ti ne nadomeščajo tržnikov ali analitikov, saj od posameznikov zahtevajo presojo in oceno, kaj deluje in kaj ne. S tem, ko se razdrobljenost med napravami in kanali povečuje, postaja sledenje na ravni obiskovalcev ključno za merjenje vrednosti različnih taktik spletnega oglaševanja. Tržniki so tako pod pritiskom zahtev glede zasebnosti porabnikov kot tudi pričakovanj podjetij, da vzpostavijo zbiranje ter prenos podatkov o sledenju in uspešnosti v sisteme atribucije ter iz njih (IAB, 2012). V moji raziskavi večina podjetij uporablja neko obliko digitalne atribucije, kot je npr. model zadnjega dotika, kar nakazuje, da obstaja potreba po dodeljevanju zaslug za opravljene konverzije. S tem, ko bodo tržniki prešli na bolj dovršene atribucijske modele kot npr. na podlagi pravil ali algoritmov, bo to pripomoglo k natančnejši oceni vrednosti kanalov oglaševanja, ki pomembno prispevajo k dejavnostim strank v zgornjem delu prodajnega lijaka, kot npr. ozaveščanje strank (Anderl, Becker, Wangenheim & Schumann, 2013).

S tem, ko se delež prodaje prek spleta in digitalnih izdelkov v celotnem trženju povečuje, atribucija postaja ključna za razumevanje, kako se različni deli trženjskih aktivnosti med seboj povezujejo. Pričakuje se, da bodo tržniki in njihove agencije v prihodnosti svoje atribucijske modele razvijali v smeri trženjskih strategij komuniciranja, ki bo veliko bolj avtomatizirano in učinkovito pri nakupu oglaševalskega prostora. Poglavitni cilj digitalne atribucije v prihodnje bo razumeti, katere trženjske izpostavljenosti in strategije vodijo do želenih rezultatov v življenjskem ciklu stranke, ki skozi čas pogosto vključuje več konverzij. S tem, ko se podatkovno usmerjeno trženje razvija, se bodo tržniki vedno manj osredotočali na optimizacijo posameznih kampanj in namesto tega skušali tem bolj povečati življenjsko vrednost za ključne segmente strank in svoja prizadevanja prilagoditi temu cilju (IAB, 2012).

Magistrsko delo nudi teoretični in empirični prispevek na področju raziskovanja dejavnikov pri oblikovanju atribucijskega modela. Preučitev literature s področja digitalne atribucije ter opravljena empirična raziskava nudita uporabno vrednost za podjetja in smernice bodočim raziskovalcem kot izhodišče za nadaljevanje raziskave.

## LITERATURA IN VIRI

1. Abhishek, V. & Hosanagar, K. (2013). Optimal bidding in multi-item multislot sponsored search auctions. *Operations Research*, 61(4), 855-873.
2. Abhishek, V., Fader, P. & Hosanagar, K. (2012). *Media exposure through the funnel: A model of multi-stage attribution*. Pridobljeno 23. februarja 2021 iz [https://kithub.cmu.edu/articles/media\\_exposure\\_through\\_the\\_funnel\\_a\\_model\\_of\\_multi-stage\\_attribution/6471698/files/11901179.pdf](https://kithub.cmu.edu/articles/media_exposure_through_the_funnel_a_model_of_multi-stage_attribution/6471698/files/11901179.pdf)
3. Abhishek, V., Fader, P. S. & Hosanagar, K. (2015). *Media exposure through the funnel: A model of multi-stage attribution*. Pridobljeno 5. marca 2021 iz <https://ssrn.com/abstract=2158421>

4. Abraham, M. (2008). The off-line impact of online ads. *Harvard Business Review*, 86(4), 28.
5. Anderl, E., Becker, I., Wangenheim, F. V. & Schumann, J. H. (2013). *Mapping the customer journey: A graph-based framework for online attribution modeling*. Pridobljeno 25. januarja 2021 iz <https://ssrn.com/abstract=2343077>
6. Anderl, E., Becker, I., Von Wangenheim, F. & Schumann, J. H. (2016). Mapping the customer journey: Lessons learned from graph-based online attribution modeling. *International Journal of Research in Marketing*, 33(3), 457-474.
7. Anderson, S. P. & Coate, S. (2005). Market provision of broadcasting: A welfare analysis. *The review of Economic studies*, 72(4), 947-972.
8. Ansari, A. & Li, Y. (2018). Big data analytics. *Handbook of Marketing Analytics*. Cheltenham: Edward Elgar Publishing.
9. Baltés, L. P. (2017). Marketing technology - the most important dimension of online marketing. *Transilvania University of Brasov. Economic Sciences. Series V*, 10(2), 43-48.
10. Batra, R. & Keller, K. L. (2016). Integrating marketing communications: New findings, new lessons, and new ideas. *Journal of Marketing*, 80(6), 122-145.
11. Berman, R. (2014). *Essays on incentives and measurement of online marketing efforts* (doktorska disertacija). Berkeley: University of California.
12. Berman, R. (2015). *Beyond the last touch: Attribution in online advertising*. Pridobljeno 21. februarja 2021 iz <http://ron-berman.com/papers/attribution.pdf>
13. Berthon, P., Pitt, L.F. & Watson, R.T. (1996). The World Wide Web as an advertising medium: Toward an understanding of conversion efficiency. *Journal of Advertising Research*, 36(1), 43-54.
14. Bhargava, H. K. & Feng, J. (2002). Paid placement strategies for internet search engines, *11. mednarodna konferenca svetovni splet* (str. 117-123). New York: Association for Computing Machinery.
15. Borgesius, F. J. Z. (2016). Singling out people without knowing their names—Behavioural targeting, pseudonymous data, and the new Data Protection Regulation. *Computer Law & Security Review*, 32(2), 256-271.
16. Bowman, D. & Narayandas, D. (2001). Managing customer-initiated contacts with manufacturers: The impact on share of category requirements and word-of-mouth behavior. *Journal of marketing Research*, 38(3), 281-297.
17. Bowman, J. (2018). *The overlooked value of multichannel attribution ... and why last-click models should be killed off*. Pridobljeno 18. januarja 2021 iz [https://www.warc.com/content/paywall/article/the\\_overlooked\\_value\\_of\\_multichannel\\_attribution\\_%e2%80%a6\\_and\\_why\\_last-click\\_models\\_should\\_be\\_killed\\_off/123550](https://www.warc.com/content/paywall/article/the_overlooked_value_of_multichannel_attribution_%e2%80%a6_and_why_last-click_models_should_be_killed_off/123550)
18. Bregar, L., Ograjenšek, I. & Bavdaž, M. (2005). *Metode raziskovalnega dela za ekonomiste: Izbrane teme*. Ljubljana: Ekonomska fakulteta.
19. Camilleri, M. A. (2020). The use of data-driven technologies for customer-centric marketing. *International Journal of Big Data Management*, 1(1), 50-63.

20. Chaffey, D. & Patron, M. (2012). From web analytics to digital marketing optimization: Increasing the commercial value of digital analytics. *Journal of Direct, Data and Digital Marketing Practice*, 14(1), 30-45.
21. Chaffey, D. & Smith, P. R. (2017). *Digital marketing excellence: Planning, optimizing and integrating online marketing*: Taylor & Francis.
22. Che, H. & Seetharaman, P. B. (2009). Speed of replacement: Modeling brand loyalty using last-move data. *Journal of Marketing Research*, 46(4), 494–505.
23. Cho, C.-H. & Khang, H. (2006). The state of Internet-related research in communications, marketing, and advertising: 1994–2003. *Journal of Advertising*, 35(3), 143–163.
24. Chugh, A. (2020). *Multi-touch attribution: A data-driven approach* [objava na blogu]. Pridobljeno 14. decembra 2020 iz <https://data-science-blog.com/blog/2020/02/04/multi-touch-attribution-a-data-driven-approach/>
25. Cioffi, R. (2019). *Data-driven marketing: Strategies, metrics and infrastructures to optimize the marketing performances* (doktorska disertacija). Politecnico di Torino.
26. Clifton, B. (2015). *Successful Analytics: Gain Business Insights by Managing Google Analytics*. *Advanced Web Metrics*. West Sussex.
27. Criteo. (2013). *Marketing attribution comes of age*. Pridobljeno 23. januarja 2021 iz <https://www.csa.eu/media/1292/etu20130924-criteo-white-paper-marketing-attribution-comes-of-age-sep-2013.pdf>
28. Dalessandro, B., Perlich, C., Stitelman, O. & Provost, F. (2012). Causally motivated attribution for online advertising. *Konferenčni prispevek predstavljen na Zborniku šeste mednarodne delavnice o rudarjenju podatkov za spletno oglaševanje in internetno gospodarstvo* (str. 1–9). New York: Association for Computing Machinery.
29. Danaher, P. J. & Dagger, T. S. (2013). Comparing the relative effectiveness of advertising channels: A case study of a multimedia blitz campaign. *Journal of Marketing Research*, 50(4), 517–534.
30. Dardis, F. E., Schmierbach, M., Sherrick, B., Waddell, F., Aviles, J., Kumble, S. & Bailey, E. (2016). Adver-Where? Comparing the effectiveness of banner ads and video ads in online video games. *Journal of Interactive Advertising*, 16(2), 87-100.
31. Day, George. (1994). The capabilities of market-driven organizations. *Journal of Marketing*, 58(4), 37–52.
32. De Haan, E., Wiesel, T. & Pauwels, K. (2016). The effectiveness of different forms of online advertising for purchase conversion in a multiple-channel attribution framework. *International Journal of Research in Marketing*, 33(3), 491-507.
33. Dijkstra, M. (2002). *An experimental investigation of synergy effects in multiple-media advertising campaigns* (doktorska disertacija). Nizozemska: University of Tilburg.
34. Dzyabura, D. & Yoganarasimhan, H. (2018). *Machine learning and marketing. Handbook of Marketing Analytics*. Združeno kraljestvo: Edward Elgar Publishing.
35. Eckersley, P. (2010). How unique is your web browser? *Na mednarodnem simpoziju o tehnologiji za izboljšanje zasebnosti* (str. 1-18). Berlin: Springer.

36. Ferencova, M., Jelenova, I. & Kakalejcik, L. (2015). Social Media Usage in Product Information Searching. *Applied Mechanics and Materials*, 795, 69-76.
37. FitzGerald, R. (2019). *Types of Customer Data to Enhance Your Marketing Campaigns*. Pridobljeno 20. januarja 2021 iz <https://connexdigital.com/types-customer-data-enhance-marketing-campaigns-infographic/>
38. Flosi, S., Fulgoni, G. M. & Vollman, A. (2013). If an advertisement runs online and no one sees it, is it still an ad? Empirical generalizations in digital advertising. *Journal of Advertising Research*, 53(2), 192–199.
39. Forgas, J. P. (2011). Can negative affect eliminate the power of first impressions? Affective influences on primacy and recency effects in impression formation. *Journal of Experimental Social Psychology*, 47(2), 425-429.
40. Fulgoni, G. M. (2018). How Limited Data Access Constrains Marketing-Mix Analytical Efforts. *Journal of Advertising Research*, 58(4), 390–393.
41. Geyik, S.C., Saxena, A. & Dasdan, A. (2014). Multi-touch attribution based budget allocation in online advertising. *Zbornik osme mednarodne delavnice o pridobivanju podatkov za spletno oglaševanje* (str 1-9). New York: Association for Computing Machinery.
42. Ghose, A. & Todri, V. (2015). *Towards a digital attribution model: Measuring the impact of display advertising on online consumer behavior*. Pridobljeno 22. januarja 2021 iz [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=2638741](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2638741)
43. Guha, S., Cheng, B. & Francis, P. (2010). Challenges in measuring online advertising systems. *V zborniku 10. konference ACM SIGCOMM o internetnih meritvah* (str. 81-87). New York: Association for Computing Machinery.
44. Homburg, C., Steiner, V. V. & Totzek, D. (2009). Managing dynamics in a customer portfolio. *Journal of Marketing*, 73(5), 70–89.
45. Hoofnagle, C. J. & Whittington, J. (2014). The price of 'Free': Accounting for the costs of the Internet's most popular price. *UCLA Law Review*, 61(3).
46. Hurstinen, J. (2020). *Data-driven marketing-Impacting a Revolution in the Marketing Industry: Using data-driven marketing to improve profitability* (magistrsko delo). Helsinki: University of Applied Sciences Metropolia
47. IAB. (2012). *Digital attribution comes of age: The Last-Click Paradigm Erodes As Marketers Turn To Fractional Attribution*. Pridobljeno 25. decembra 2020 iz <https://www.iab.com/wp-content/uploads/2015/08/DigitalAttributionComesOfAge.pdf>
48. IAB. (2016). *Digital attribution primer 2.0*. Pridobljeno 14. februarja 2021 iz <https://www.iab.com/wp-content/uploads/2016/10/Digital-Attribution-Primer-2-0-FINAL.pdf>
49. Iafrate, F. (2018). *Artificial intelligence and big data: The birth of a new intelligence*. Velika Britanija: John Wiley & Sons.
50. Janal, R. (2017). Data Portability-A Tale of Two Concepts. *Journal of Intellectual Property, Information Technology and Electronic Commerce Law*, 8, 59.



51. Jayawardane, C., Halgamuge, S. & Kayande, U. (2015). Attributing conversion credit in an online environment: An analysis and classification. *Konferenčni prispevek predstavljen na 3. mednarodnem simpoziju o računalniški in poslovni inteligenci* (str. 68-73). Bali: International Symposium on Computational and Business Intelligence.
52. Jayawardane, C. (2019). *Methods for modeling advertising channel sequences in an online environment* (doktorska disertacija). Avstralija: University of Melbourne.
53. Ji, W., Wang, X. & Zhang, D. (2016). A probabilistic multi-touch attribution model for online advertising. *Konferenčni prispevek predstavljen na zborniku 25. ACM mednarodne konference o informacijah in znanju* (str. 1373-1382). New York: Association for Computing Machinery.
54. Johnson, D. S., Muzellec, L., Sihi, D. & Zahay, D. (2019). The marketing organization's journey to become data-driven. *Journal of Research in Interactive Marketing*, 13(2), 162-178.
55. Kahneman, D. (1973). *Attention and effort*. Englewood. Cliffs, NJ: Prentice-Hall.
56. Kakalejčik, L., Bucko, J., Resende, P. A. & Ferencova, M. (2018). Multichannel marketing attribution using Markov chains. *Journal of Applied Management and Investments*, 7(1), 49-60.
57. Kakalejčik, L., Bucko, J. & Vejačka, M. (2019). Differences in buyer journey between high-and low-value customers of e-commerce business. *Journal of theoretical and applied electronic commerce research*, 14(2), 47-58.
58. Kannan, P. K., Reinartz, W. & Verhoef, P. C. (2016). The path to purchase and attribution modeling: Introduction to special section. *International Journal of Research in Marketing*, 33(3).
59. Kaushik, A. (2012). *Multi-channel attribution: Definitions, models and a reality check*. Pridobljeno 22. februarja 2021 iz <https://www.kaushik.net/avinash/multi-channel-attribution-definitions-models/>
60. Kireyev, P., Pauwels, K. & Gupta, S. (2016). Do display ads influence search? Attribution and dynamics in online advertising. *International Journal of Research in Marketing*, 33(3), 475–490.
61. Kitts, B., Wei, L., Au, D., Powter, A. & Burdick, B. (2010). Attribution of conversion events to multi-channel media. *Mednarodna konferenca IEEE o rudarjenju podatkov* (str. 881-886). Sydney: Institute of Electrical and Electronics Engineers.
62. Langanke, C. (2015). Consumer data as consideration. *Journal of European Consumer and Market Law*, 4(6).
63. Lee, G. (2010). Death of 'last click wins': Media attribution and the expanding use of media data. *Journal of Direct, Data and Digital Marketing Practice*, 12(1), 16-26.
64. Lemon, K. N. & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of marketing*, 80(6), 69-96.
65. Lemos, A. M. F. (2015). *Optimizing multi-channel use in digital marketing campaigns* (magistrsko delo). Lizbona: School of Business & Economics Lisbon.

66. Li, H. & Kannan, P. K. (2014). Attributing conversions in a multichannel online marketing environment an empirical model and a field experiment. *Journal of Marketing Research*, 51(1), 40-56.
67. Li, Y., Xie, Y. & Zheng, E. (2017). *Modeling multi-channel advertising attribution across competitors*. Pridobljeno 4. aprila 2021 iz <https://ssrn.com/abstract=3047981>
68. Libert, T., Graves, L., & Nielsen, R. K. (2018). *Changes in third-party content on European news websites after GDPR*. Združeno kraljestvo: Reuters Institute for the Study of Journalism.
69. Loos, M. B. M., Guibault, L., Helberger, N., Mak, C., Pessers, L., Cseres, K. J. & Tigner, R. (2011). *Comparative analysis, law & economics analysis, assessment and development of recommendations for possible future rules on digital content contracts*. Nizozemska: University of Amsterdam.
70. Manchanda, P., Dubé, J. P., Goh, K. Y. & Chintagunta, P. K. (2006). The effect of banner advertising on internet purchasing. *Journal of Marketing Research*, 43(1), 98-108.
71. Mariani, M. (2020). Web 2.0 and destination marketing: Current trends and future directions. *Sustainability*, 12(9), 3771.
72. Martin, A. (2009). *The long road to conversion: The digital purchase funnel*. Digital Marketing Insights, Microsoft's Atlas Institute.
73. Matoulek, M. (2018). *Data analytical way to identify an appropriate attribution model for digital marketing* (magistrsko delo). Češka: Technical University in Prague.
74. McKinsey. (2017). *Invest, Create, Perform: Mastering the three dimensions of growth in the digital age*. Pridobljeno 4. decembra 2020 <https://www.mckinsey.com/business-functions/marketing-and-sales/our-insights/invest-create-perform>
75. Mizik, N. & Hanssens, D. M. (2018). *Handbook of Marketing Analytics: Methods and Applications in Marketing Management, Public Policy, and Litigation Support*. Združeno kraljestvo: Edward Elgar Publishing.
76. Moe, W. W. & Fader P. S. (2004). Dynamic Conversion Behavior at E-Commerce Sites. *Management Science*, 50(3), 326–335.
77. Moffett, T. (2014). *Cross-channel attribution providers*. Pridobljeno 16. marca 2021 iz <https://docplayer.net/8669578-The-forrester-wave-cross-channel-attribution-providers-q4-2014.html>
78. Morales, D. R. (2015). Cross-device tracking: Matching devices and cookies. *Mednarodna konferenca o podatkovnem rudarstvu* (str. 1699-1704). New Jersey: Institute of Electrical and Electronics Engineers.
79. Mulpurporu, S., VanBoskirk, S., Evans, P. F. & Roberge, D. (2011). *The Purchase Path of Online Buyers: A Joint Holiday Shopping Study with GSI Commerce of 15 Retail Websites* (poročilo o raziskavi). ZDA: Forrester Research.
80. Naik, P. A. & Raman, K. (2003). Understanding the impact of synergy in multimedia communications. *Journal of marketing research*, 40(4), 375-388.

81. Nisar, T. M. & Yeung, M. (2018). Attribution modeling in digital advertising: An empirical investigation of the impact of digital sales channels. *Journal of Advertising Research*, 58(4), 399-413.
82. Nottorf, F. & Funk, B. (2013). A cross-industry analysis of the spillover effect in paid search advertising. *Electronic Markets*, 23(3), 205-216.
83. Pechmann, C. & Stewart, D. W. (1988). Advertising repetition: A critical review of wearin and wearout. *Current issues and research in advertising*, 11(1-2), 285-329.
84. Peters, R. G. & Bijmolt, T. H. (1997). Consumer memory for television advertising: A field study of duration, serial position, and competition effects. *Journal of Consumer Research*, 23(4), 362-372.
85. Petersen, J. A., McAlister, L., Reibstein, D. J., Winer, R. S., Kumar, V. & Atkinson, G. (2009). Choosing the right metrics to maximize profitability and shareholder value. *Journal of Retailing*, 85(1), 95-111.
86. Pfeifer, P. E. & Carraway, R. L. (2000). Modeling customer relationships as Markov chains. *Journal of Interactive Marketing*, 14(2), 43–55.
87. Raconteur. (2020). *Ad Evolution*. Pridobljeno 20. januarja 2021 iz <https://www.raconteur.net/infographics/ad-evolution/>
88. Rappaport, S. D. (2007). Lessons from online practice: New advertising models. *Journal of Advertising Research*, 47(2), 135–141.
89. Renko, J. (2019). *Varstvo osebnih podatkov potrošnika v pogodbah o dobavi digitalnih vsebin ali digitalnih storitev po Direktivi (EU) 2019/770* (doktorska disertacija). Ljubljana: Pravna fakulteta.
90. Rentola, O. (2014). *Analyses of Online Advertising Performance Using Attribution Modeling* (magistrsko delo). Helsinki: Aalto University.
91. Sciforce. (2019). *Data Cleaning and Preprocessing for Beginners*. Pridobljeno 21. decembra 2020 iz <https://medium.com/sciforce/data-cleaning-and-preprocessing-for-begin-ners-25748ee00743>
92. Shao, X. & Li, L. (2011). Data-driven multi-touch attribution models. *Zbornik 17. mednarodne konference o odkrivanju znanja in rudarjenju podatkov* (str. 258-264). New York: Association for Computing Machinery.
93. Stammerjohan, C., Wood, C. M., Chang, Y. & Thorson, E. (2005). An empirical investigation of the interaction between publicity, advertising, and previous brand attitudes and knowledge. *Journal of Advertising*, 34(4), 55-67.
94. Styan, G. P. H. & Smith, H. (1964). Markov chains applied to marketing. *Journal of Marketing Research*, 1(1), 50–55.
95. Szulc, C., Rees, M., Steele, A. & Aders, A. (2013). *Valuing Digital Marketing Channels With Attribution Models*. Pridobljeno 8. januarja 2020 iz <http://relevance.com/wp-content/uploads/2013/04/multi-touch-eBook-digitalrelevance.pdf>
96. Taffs, L. (2018). *How to develop an effective data-driven marketing strategy*. Pridobljeno 6. decembra 2020 iz

- <https://www.warc.com/content/paywall/article/bestprac/how-to-develop-an-effective-data-driven-marketing-strategy/123013>
97. Technopedia. (2018). *Online Advertising*. Pridobljeno 4. decembra 2020 <https://www.techopedia.com/definition/26362/online-advertising>
  98. Teicher, J. (2017). *The 3 Most Important Reasons Marketers Use Marketing Technology in Contently*. Pridobljeno 27. januarja 2021 iz <https://contently.com/strategist/2017/03/27/3-reasons-use-marketing-technology>
  99. Todri, V. (2016). *Modeling and measuring digital advertising effectiveness with atomic data* (doktorska disertacija). ZDA: New York University.
  100. Tucker, C. (2012). The implications of improved attribution and measurability for antitrust and privacy in online advertising markets. *George Mason Law Review*, 20, 1025.
  101. Unnava, H. R. & Burnkrant, R. E. (1991). Effects of repeating varied ad executions on brand name memory. *Journal of marketing research*, 28(4), 406-416.
  102. Wang, Q., Li, B. & Yang, J. (2015). When structural models meets big data: Examining multi-device attribution for native ads using TB-sized data. V *zborniku delavnice o informacijskih sistemih in ekonomiji* (str.1-6). Dallas: Workshop on Information Systems and Economics.
  103. Wedel, M. & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), 97-121.
  104. West, S. M. (2019). Data capitalism: Redefining the logics of surveillance and privacy. *Business & society*, 58(1), 20-41.
  105. Wiesel, T., Pauwels, K. & Arts, J. (2011). Marketing's profit impact: Quantifying online and off-line funnel progression. *Marketing Science*, 30(4), 604-611.
  106. Windsor. (2020). *Attribution modelling in R*. Pridobljeno 16. decembra 2020 iz <https://www.windsor.ai/attribution-modelling-in-r/>
  107. Wooff, D. A. & Anderson, J. M. (2015). Time-weighted multi-touch attribution and channel relevance in the customer journey to online purchase. *Journal of statistical theory and practice*, 9(2), 227-249.
  108. Wright, T. (2016). *Your Ultimate Cheat Sheet to Marketing Technology*. Pridobljeno 7. februarja 2021 iz <https://www.inc.com/travis-wright/your-ultimate-cheat-sheet-to-marketing-technology-martech.html>
  109. Xu, L., Duan, J. A. & Whinston, A. (2014). Path to purchase: A mutually exciting point process model for online advertising and conversion. *Management Science*, 60(6), 1392-1412.
  110. Yuvaraj, C., Chandavarkar, B., Kumar, V. S. & Sandeep, B. S. (2018). Enhanced last-touch interaction attribution model in online advertising. *Konferenčni prispevek predstavljen na 2018 IEEE Distribuiranem računalništvu, električnih vezjih in robotiki* (str. 110-114). India: Institute of Electrical and Electronics Engineers.

## **PRILOGE**



## Priloga 1: Vprašalnik

Spoštovani,

sem Marko Novak in v sklopu magistrske naloge na Ekonomski fakulteti delam raziskavo na področju spletne analitike in atribucije konverzij med spletnimi kanali. V anketo so zajeta podjetja, katerih večinski del dejavnosti predstavlja prodaja prek spleta. Čas reševanja ankete je približno 2 minuti, s svojimi odgovori pa boste pripomogli k razumevanju problematike, ki sem jo zaznal na tem področju. Za sodelovanje v anketi se vam vnaprej zahvaljujem.

### Q1 - Ali večinski del dejavnosti vašega podjetja predstavlja prodaja prek spleta?

- Da
- Ne

IF (1) Q1 = [1] ( Da )

### Q2 - Ali se v vašem podjetju poslužujete spletnega oglaševanja?

- Da
- Ne

IF (2) Q2 = [1] ( Da )

### Q3 - Kaj je glavni namen uporabe spletnega oglaševanja za vaše podjetje?

Možnih je več odgovorov, prosim, izberite največ 3 razloge.

- Prodaja storitev/izdelkov
- Spletna prisotnost
- Povečanje prepoznavnosti
- Pridobivanje novih strank
- Zagotavljanje informacij porabnikom
- Zbiranje informacij/idej
- Drugo (prosim, navedite):

IF (2) Q2 = [1] ( Da )

### Q4 - Katere plačljive kanale oglaševanja uporablja vaše podjetje pri predstavitvi na spletu?

Možnih je več odgovorov

- Družbena omrežja (npr. Facebook, YouTube, LinkedIn, itd.)

- Prikazno oglaševanje (npr. pasice in pojavní oglasi)
- Iskalno oglaševanje (npr. oglasi med rezultati iskanja)
- E-poštno oglaševanje
- Partnerske »Affiliate« povezave na spletu (npr. vplivneži)
- Drugo (prosim, navedite):

IF (2) Q2 = [1] ( Da )

### **Q5 - Kako vaše podjetje spremlja uspešnost oglaševalskih kanalov?**

Možnih je več odgovorov

- Analitika znotraj kanalov oglaševanja
- Orodja za spletno analitiko (npr. Google Analytics, HubSpot)
- Poročila s strani oglaševalske agencije/zunanjih sodelavcev
- Lastni prilagojeni sistemi
- Drugo (prosim, navedite):

IF (2) Q2 = [1] ( Da )

### **Q6 - Kdo je zadolžen za spremljanje uspešnosti in ovrednotenje oglaševalskih kanalov?**

- Zaposleni znotraj podjetja
- Oglaševalska agencija
- Zunanji sodelavci
- Ponudnik spletne analitike
- Za pomoč prosim prijatelje/znance
- Drugo (prosim, navedite):

IF (2) Q2 = [1] ( Da )

### **Q7 - Katere vrste trženjskih orodij uporablja vaše podjetje?**

Možnih je več odgovorov

- Spletna orodja za trženjsko analitiko
- CRM orodja
- Trženjska orodja za avtomatizacijo
- Ponudnike e-poštnih storitev
- Platforme za upravljanje podatkov (angl. DMP)
- Platforme za upravljanje spletnih vsebin (angl. CMS)
- Platforme za upravljanje vsebin družbene skupnosti
- Nič od naštetega
- Drugo (prosim, navedite):



IF (2) Q2 = [1] ( Da )

**Q8 - Ali beležite vir (oglaševalski kanal) prihoda porabnikov na spletno mesto?**

- Da
- Ne
- Ne vem

IF (2) Q2 = [1] ( Da )

**Q9 - Katere tehnologije uporabljate na spletnem mestu za zbiranje podatkov o porabnikih?**

Možnih je več odgovorov

- Piškotke
- Sledilne oznake (angl. Tracking tags)
- UTM parametre
- Nič od naštetega
- Ne vem
- Drugo (prosim, navedite):

IF (3) Q9 = [Q9a, Q9b, Q9c, Q9f]

**Q10 - Ali uporabljate zbrane podatke o porabnikih za oblikovanje nakupne poti kupca?**

- Da
- Ne
- Ne vem

IF (2) Q2 = [1] ( Da )

**Q11 - Ali se iste porabnike, ki obiskujejo vaše spletno mesto preko različnih naprav, povezuje v enovito porabnikovo prisotnost?**

\* Enovita porabnikova prisotnost - Povezovanje naprav istega porabnika (npr. telefon, računalnik, tablica) v en podatkovni zapis preko skupnih identifikatorjev

- Da, preko osebnih informacij (npr. uporabniško ime, e-pošta, telefonska številka)
- Da, preko značilnosti naprav (npr. vrsta naprave, tip brskalnika, geolokacija, IP naslov)
- Ne
- Ne vem
- Drugo (prosim, navedite):

IF (2) Q2 = [1] ( Da )

**Q12 - Kateri pristop/model atribucije uporabljate pri ovrednotenju prispevka posameznih oglaševalskih kanalov?**

- Celotni prispevek za konverzijo se dodeli zgolj enemu kanalu (npr. Model zadnjega dotika)
- Ovrednoteni prispevek za konverzijo se dodeli več kanalom na podlagi intuitivnih pravil (npr. Linearni atribucijski model)
- Ovrednoteni prispevek za konverzijo se dodeli več kanalom na podlagi algoritemskega pristopa (npr. Markovske verige)
- Nič od naštetega
- Ne vem
- Drugo (prosim, navedite):

IF (4) Q12 = [1, 2, 3, 6]

**Q13 - Kateri so glavni razlogi uporabe modela atribucije?**

Možnih je več odgovorov

- Merjenje vrednosti in uspešnosti oglaševalskih kanalov
- Merjenje medsebojnega vpliva spletnih oglaševalskih kanalov
- Izboljšanje trženjskih strategij (npr. razporeditev sredstev za oglaševanje)
- Izboljšanje taktik trženjskih kampanj (npr. ciljne skupine, teksti in grafične podobe oglasov, formati oglasov)
- Merjenje vpliva posameznih trženjskih aktivnosti
- Neposredna izvršitev nakupa oglaševalskega prostora
- Drugo (prosim, navedite):

IF (4) Q12 = [1, 2, 3, 6]

**Q14 - Kaj vam je najpomembnejše pri izbranem modelu atribucije?**

- Enostavnost
- Prilagodljivost
- Natančnost
- Drugo (prosim, navedite):

IF (4) Q12 = [1, 2, 3, 6]

**Q15 - Kakšno je vaše mnenje o trenutnem načinu ovrednotenja oglaševalskih kanalov?**

Prosim, da na lestvici od 1 do 5 označite, v kolikšni meri se s trditvami strinjate. 1 = sploh se ne strinjam; 2 = Se ne strinjam; 3 = Niti strinjam niti ne strinjam; 4 = Strinjam se; 5 = Popolnoma se strinjam

	1-Sploš se ne strinjam	2-Se ne strinjam	3-Niti niti	4-Se strinjam	5-Povsem se strinjam
Zadovoljni smo s trenutnim atribucijskim modelom.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Trenutni atribucijski model ustrezno ovrednoti vse oglaševalske kanale.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Atribucijski model omogoča učinkovito porabo oglaševalskega proračuna med kanali.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Bolj natančno ovrednotenje kanalov bi izboljšalo uspešnost oglaševanja.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

IF (5) Q15a = [1, 2, 3, 4]

### Q16 - Kaj je glavni razlog, da ne vzpostavite bolj dovršenega modela atribucije?

Možnih je več odgovorov

- Pomanjkanje trženjske strategije
- Pomanjkljivo zbiranje podatkov o porabnikih
- Neznanje na področju atribucije
- Dodatna časovna ovira pri analizi podatkov
- Premajhen finančni učinek
- Visoki stroški vpeljave in uporabe
- Naprednejši model ni potreben
- Drugo (prosim, navedite):

IF (2) Q2 = [1] ( Da )

### Q17 - Katero delovno mesto zasedate v podjetju?

\_\_\_\_\_

IF (2) Q2 = [1] ( Da )

### Q18 - Koliko zaposlenih je v vašem podjetju? \_\_\_\_\_

IF (2) Q2 = [1] ( Da )

### Q19 - V kateri kategoriji poslovanja deluje vaše podjetje?

Možnih je več odgovorov

- B2B

- B2C
- C2C
- C2B

IF (2) Q2 = [1] ( Da )

**Q20 - Kolikšni so letni prihodki vašega podjetja?**

- Manj kot 50.000€
- Od 50.000€ 66 199.999€
- Od 200.000€ 66 349.999€
- Od 350.000€ 66 499.999€
- Od 500.000€ 66 749.999€
- Od 750.000€ 66 999.999€
- Več kot 1.000.000€
- Ne želim odgovoriti

Hvala za sodelovanje v anketi.

## Priloga 2: Tabela hipotez in spremenljivk

Tabela 1: Tabela hipotez in spremenljivk

	HIPOTEZA	VPRAŠANJE V ANKETI	PROUČEVANE SPREMENLJIVKE	VIRI ZA HIPOTEZE in KVALITATIVNA RAZISKAVA	STATISTIČNI TEST
<b>H1a</b>	Podjetjem je pri izbiri atribucijskega modela najpomembnejša enostavnost uporabe.	14	<b>Kriterij izbire modela</b> -enostavnost (a) -prilagodljivost (b) -natančnost (c)	- <b>IAB (2012)</b> - <b>Criteo (2013)</b>	Test enake verjetnosti
<b>H1b</b>	Podjetja se strinjajo, da njihov atribucijski model ustrezno ovrednoti vse oglaševalske kanale.	12 15	<b>Atribucijski model</b> -modeli z enim dotikom, modeli z več dotiki (a, b, c)  <b>Učinkovitost modela</b> -ustrezno ovrednotenje (b)	- <b>IAB (2012)</b> - <b>Criteo (2013)</b>	T- test za en vzorec
<b>H2</b>	Natančnejše zbiranje podatkov o porabnikih vodi v izbiro bolj dovršenega modela atribucije.	9 12	<b>Zbiranje podatkov</b> -piškotki, sledilne oznake, UTM parametri (a, b, c)  <b>Atribucijski model</b> -modeli z enim dotikom (a)  <b>Atribucijski model</b> -modeli z več dotiki (b, c)	- <b>Baltes (2017)</b> - <b>Johnson (2019)</b> - Todri (2016) - Flosi (2013) - Li (2014) - Guha (2010)	Hi-kvadrat test
<b>H3</b>	Podjetja, ki uporabljajo model z več dotiki, se bolj strinjajo, da učinkoviteje porabljajo oglaševalski proračun med kanali kot podjetja, ki uporabljajo model z enim dotikom.	12 15	<b>Atribucijski model</b> -modeli z enim dotikom (a)  <b>Atribucijski model</b> -modeli z več dotiki (b, c)  <b>Učinkovitost modela</b> -poraba oglaševalskega proračuna (c)	- <b>IAB (2012)</b> - Tucker (2012) - Dalessandro (2012) - Berman (2015) - Berman (2014) - Anderl (2016)	T-test za neodvisna vzorca
<b>H4</b>	Podjetja ki uporabljajo večje število oglaševalskih kanalov, izbirajo bolj dovršene atribucijske modele.	4 12	<b>Kanali oglaševanja</b> -št. kanalov (povp. št.)  <b>Atribucijski model</b> -modeli z enim dotikom (a)  <b>Atribucijski model</b> -modeli z več dotiki (b, c)	- Jayawardane (2015) - Nisar (2018)	T-test za neodvisna vzorca
<b>H5</b>	Tržniki uporabljajo zbrane podatke o porabnikih pri oblikovanju nakupne poti kupca.	10	<b>Oblikovanje nakupe poti</b> -Da (a)	- <b>Chaffey (2012)</b> - Wiesel (2011) - Lemon (2016)	Binominalni test