



Algoritminen työkalu ohjelmallisessa ostamisessa - Case RADLY Optimizer

Anttoni Nurminen

2020 Laurea Otaniemi





Laurea-ammattikorkeakoulu

**Algoritminen työkalu ohjelmallisessa ostamisessa - Case RADLY
Optimizer**

Anttoni Nurminen
Liiketalouden koulutusohjelma
Opinnäytetyö
Joulukuu, 2020

Anttoni Nurminen

Algoritminen työkalu ohjelmallisessa ostamisessa - Case Radly Optimizer

Vuosi 2020

Sivumäärä 33

Opinnäytetyön tarkoituksena on tutkia algoritmisen optimointityökalun vaikutusta kahdessa ohjelmallisesti ostetussa mainoskampanjassa digitaalisen mainonnan mittarein. Tavoitteena on tutkia, minkälaista hyötyä optimointialgoritilla voidaan tutkimuksessa käytettyjen kampanjoiden kaltaisissa tapauksissa saavuttaa. Tutkimuksen kampanjoiden dataa tarkastellaan difference in differences -tutkimusmenetelmän avulla työkalun kausaalisen vaikutuksen arvioimiseksi.

Ohjelmallinen ostaminen ja algoritmit ovat hyvin laaja-alaisia käsitteitä. Siksi työn teoriaosuuden tavoite on luoda lukijalle yleiskäsitystä ohjelmallisesta ostamisesta ensisijaisesti ostajan näkökulmasta, digitaalisen markkinoinnin mittareista sekä algoritmeista tutkimusosan kontekstin ymmärtämiseksi.

Tutkimuksen keskeisenä tuotoksena on tutkimusmetodin mukaiset tulokset ja niistä tehdyt johtopäätökset algoritmisen optimointityökalun mahdollisista hyödyistä ohjelmallisessa ostamisessa. Tutkimuksen mukaan työkalulla voidaan saavuttaa tapauskohtaisesti suurtakin hyötyä digitaalisen mainonnan mittareilla mitattuna. On kuitenkin huomionarvoista, että jokainen kampanja, ja sen asetukset, ovat yksilöllisiä. Sen takia myös työkalun vaikutukset kampanjalle ovat aina yksilöllisiä. Tässä tutkimuksessa keskityttiin yksin optimointityökaluun muuttujana, jatkotutkimusten kannalta voisi olla hyödyllistä toteuttaa tutkimus monimuuttujamenetelmällä regressioanalyysiä hyödyntäen.

Anttoni Nurminen

Algorithmic tool in programmatic buying - Case Radly Optimizer

Year

2020

Pages

33

The purpose of the thesis is to inspect the effects of an algorithmic optimizing tool in programmatic buying for two marketing campaigns measured by digital marketing metrics. The objective is to examine the possible benefits of an optimizing algorithm in campaigns such as used in this study. The data of these two campaigns are observed through a difference-in-differences research method in order to verify the causal effect of the tool.

Programmatic buying and algorithms are very broad concepts. Therefore, the objective of the theory is to clarify and create general understanding of the subjects of programmatic buying primarily from the buyers view, digital marketing metrics and algorithms to enhance reader understanding on the context of the study.

The essential product of the study are the study results provided by the research method and the conclusions of possible benefits of an algorithmic optimizing tool in programmatic buying based on the results. By this study, it is possible to improve the digital marketing metrics of a programmatic advertising campaign with an algorithmic optimizing tool significantly in some cases. Still, it is noteworthy that every campaign and its settings are unique and therefore the effects of the tool are also unique. The study concentrated solely on the optimizing tool as a variable. In further studies, it could turn out beneficial to implement a multivariate study utilizing regression analysis.

Keywords: Programmatic buying, Algorithms, Digital Marketing

Käsitteet

Impressio - Yksittäinen mainosnäyttö

Inventaari - julkaisijoiden myytäväksi asetettujen impressioiden kokonaisuus

Order (Määräys) - Ostojärjestelmän mainosyksikkötasoa rajaava asetusten kokonaisuus

Line Item (Mainosyksikkö) - Ostojärjestelmässä asetustaso, jossa määritellään ostettava(t) inventaari(t), mainosyksikön budjetti, kohdennukset sekä ajankohta

Deal ID (Sopimus ID) - Julkaisijan toimittama yksilöllinen koodi, jota hyödyntämällä ostava taho pystyy ostamaan mainosinventaaaria toimijoiden kesken määritellyin sopimusehdoin

CPM (Cost per mille) - Tuhannen mainosnäytön hinta

CPC (Cost per click) - Yksittäisen mainosklikkauksen hinta

CPA (Cost per acquisition) - Yksittäisen mainoksesta aiheutuneen toiminnon, esimerkiksi tuotteen oston, hinta

Sisällys

1	Johdanto.....	8
2	Ohjelmallisen ostamisen perusteet	9
2.1	Osto-, myynti- ja datanhallintajärjestelmät	10
2.2	Ohjelmallisen ostamisen tasot ja hinnoittelu	13
2.2.1	Huutokaupamallit	13
2.2.2	Kiinteähintaiset mallit	14
3	Digitaalisen mainonnan mittaaminen.....	15
4	Algoritmit.....	16
5	Tutkimusmenetelmä	19
5.1	Toimeksiantaja ja tutkimuksen kohde	20
5.2	Tutkimusaineiston perustiedot	21
6	Tutkimustulokset	22
7	Johtopäätökset	27
	Lähteet.....	30
	Kaavat.....	33
	Taulukot	33

1 Johdanto

Tämän opinnäytetyön tarkoituksena on tutkia algoritmisen optimointityökalun käytön vaikutuksia kahdessa ohjelmallisesti ostetussa mainoskampanjassa. Tavoitteena on teoriaosuudella lisätä lukijan ymmärrystä ohjelmallisen ostamisen perusteista, digitaalisen mainonnan mittareista sekä algoritmien merkityksestä digitaalisessa markkinointiviestinnässä. Opinnäytetyössä luodaan lukijalle yleiskäsitystä ohjelmallisen ostamisen ilmiöstä ensisijaisesti ostajan näkökulmasta. Opinnäytetyössä kuvataan ohjelmalliseen ostamiseen käytettäviä järjestelmiä, niiden toimintalogiikkaa, hinnoittelumalleja. Lisäksi mainonnan mittaamista ja algoritmien merkitystä digitaalisissa ympäristöissä kuvataan omina kappaleinaan.

Ohjelmallinen ostaminen on laaja käsite ja kattaa alleen esimerkiksi sosiaalisen median mainonnan tai hakukonemainonnan. Tässä opinnäytetyössä ei tarkastella näitä alustoja muilta osin, kun ne liittyvät yleisen viitekehyksen alle, mutta voidaan käyttää havainnollistamaan asioita tai ilmiöitä. Työn tietoperustana on käytetty alan verkkojulkaisuja, kirjallisuutta sekä kirjoittajan omaa kokemusta ja näkemystä alalta.

Opinnäytetyön tutkimusosassa tutkitaan RADLY Optimizer -optimointityökalun vaikutuksia kahden tosiasiallisen ohjelmallisesti ostetun mainoskampanjan osalta mainonnanhallintajärjestelmästä ajettuun dataan perustuen. Tutkimuksessa hyödynnetään lähes kokeelliseksi luokiteltavaa difference in differences -tutkimusmetodia, jolla voidaan selvittää algoritmisen työkalun kausaalista vaikutusta kampanjakohtaisesti. Tutkimusmetodin perusajatuksena on hyödyntää dataa kontrolli- ja tutkimusryhmistä vertailu- ja tutkimusjaksoilla. Tästä datasta syntyvän nelikentän avulla toimenpiteen kausaalinen vaikutus on arvioitavissa matemaattista kaavaa hyödyntäen.

Työn lopullisena tuotoksena on tutkimustulosten, niiden analyysin ja johtopäätösten esittely sekä aiheen jatkotutkimusten pohdinta.

2 Ohjelmallisen ostamisen perusteet

Digitaalinen markkinointiviestintä on yrityksen tai brändin ja sen asiakkaiden välistä vuorovaikuttamista digitaalisten kanavien ja tietotekniikan välityksellä (Merisavo 2008, 20). Ohjelmallisella ostamisella on nykypäivänä merkittävä rooli tässä yritysten tai brändien ja niiden asiakkaiden välisessä vuorovaikutuksessa. Zenith arvioi, että vuonna 2020 mainostajat tulevat käyttämään 98 miljardia Yhdysvaltain dollaria ohjelmalliseen mainontaan, kattaen 68 % kaikesta digitaalisesta mainonnasta (Zenith 2018). Suomessakin ohjelmallinen on kasvanut voimakkaasti. Vuonna 2018 sen kokonaismäärä oli 54,2 miljoonaa euroa ja se tarkoitti 26 % prosentin kasvua edeltävään vuoteen (IAB 2019).

Ohjelmallinen ostaminen kattaa alleen laajan joukon markkinointiviestinnän muodoista digitaalisissa ympäristöissä. Pelkistettynä ohjelmallinen ostaminen tarkoittaa mainostilan ja -inventaarin ostamista valituista ympäristöistä järjestelmiä hyödyntäen. IAB (Interactive Advertising Bureau) määrittelee ohjelmallisen ostamisen seuraavalla tavalla: ”Ohjelmallinen ostaminen on mainonnan automaatiota, jossa hyödynnetään järjestelmiä mainonnan ostamisessa. Järjestelmät tarjoavat työkalut kaikenlaisen digitaalisen näkyvyyden (mm. display, mobiili, video) reaaliaikaiseen ostamiseen, kohdentamiseen ja optimointiin.” (IAB 2017, 3). Tämän määrittelyn mukaan mikä tahansa järjestelmiä hyödyntävä mainostilan ostaminen voidaan luokitella ohjelmalliseksi ostamiseksi ja kattaa alleen esimerkiksi sosiaalisen median mainonnan sekä hakukonemainonnan. Tässä opinnäytetyössä ilmiötä tarkastellaan ensisijaisesti display-mainontaan tarkoitettujen järjestelmien, prosessien, teknologioiden, ostamisen tasojen ja hinnoittelun valossa ostavan osapuolen näkökulmasta.

Display -mainonta määritellään usein puhtaasti internet-sivujen mainospaikoilla toteutetuksi bannerimainonnaksi. Display -mainonta on toki sitäkin, mutta edellä mainittu määritelmä on todellisuudessa hieman suppea, sillä se antaa vaikutelman, että kyseessä on vain sivustoilla kuvien muodossa toteutettava mainonta. Mainosmuodon laajuutta kuvaa paremmin muun muassa Markkinointi Akatemian (2020a) määritelmä: ”Display-mainonta on kuitenkin muutakin kuin bannereita: tässä mainosverkostossa on tarjolla myös teksti- ja videomainoksia.”. Yhteenvedona mainosmuodon voidaan todeta kattavan alleen eri tyyppisiä sisältöjä hyödyntävän visuaalisen mainonnan julkaisijoiden alustojen mainospaikoilla.

Ohjelmallisen ostamisen keskiöön kuuluu julkaisijoiden sivustoilla olevien mainospaikkojen mainosnäyttöjen automatisoidut osto- ja myyntiprosessit. Kun julkaisijan sivustolle saapuu vierailija, julkaisijan käyttämä myyntijärjestelmä lähettää mainostajien käyttämille ostojärjestelmille kutsun osallistua huutokauppaan kyseiselle kävijälle näytettävistä mainosnäytöistä. Huutokaupan lisäksi mainosnäyttöjen kauppaa voidaan käydä kiinteähintaisesti esimerkiksi näyttömäärään tai mainonnan kestoon perustuen.

Mainosnäyttöjen kauppaa käydään tuhannen näytön hintaa kuvaavalla CPM-hinnalla (cost per mille).

Ohjelmallisen ostamisen keskeisin hyöty perinteiseen display-mainostilan ostoon ja myyntiin verrattuna on manuaalisten työvaiheiden poistaminen prosessista. Perinteisesti mainostilan osto vaatii ostajan sekä julkaisijan välistä kommunikointia esimerkiksi volyymin, ajankohdasta ja verkostoista. Järjestelmiä hyödyntämällä tämä prosessi nopeutuu, kun ostaja voi ostotyökaluissa määrittää edellä mainitut asiat ja myyjä saa tarjoamansa mainospaikat tehokkaasti tavoitettaviksi.

Järjestelmiä hyödyntämällä saavutetaan myös muita merkittäviä hyötyjä kuten reaaliaikainen kaupankäynti, kohdennettavuus sekä optimointi. Ostojärjestelmät tarjoavat ostajalle täyden hallinnan mainonnasta koko sen prosessin ajan suunnittelusta raportointiin. Suoraostettaessa mainonnan hallinnointi ja raportointi on puhtaasti myyjällä, ohjelmallisesti ostettaessa ostava puoli saa reaaliaikaisen näkymän mainonnan suoriutumiseen ja pystyy sen perusteella arvioimaan tuloksia sekä tekemään tarvittavia muutoksia proaktiivisesti jo mainoskampanjan aikana.

Järjestelmät tarjoavat väylän myös kohdennusdatan ostamiseen ja myymiseen. Mainostajat voivat kohdentaa kampanjoitaan monipuolisemmin maksulliseen kolmannen osapuolen tarjoamaan dataan pohjautuen ja näin viestiä kohderyhmille, jotka eivät välttämättä muuten olisi tavoitettavissa. Kohderyhmät voivat olla esimerkiksi sijaintiin, demografisiin tietoihin, kiinnostuksen kohteisiin tai asiakastietoihin perustuvia. Datan tarjoajia voivat olla suuret mediatilat tai puhtaasti datan keräämiseen ja myyntiin erikoistuneet tahot. Näiden lisäksi mainostajilla on järjestelmien avulla mahdollisuus hyödyntää omaa asiakkaistaan keräämää dataa mainonnan kohdentamiseen. Kohdennusdata on tähän asti nojannut vahvasti mobiililaitetunnuksiin ja verkkoselainten evästeisiin, joiden pohjalta mainontaa on voitu kohdentaa selainkäyttäjien perusteella. Evästepohjaista kohdentamista uhkaa kuitenkin lainsäädännön muutokset evästeiden väärinkäytösten johdosta sekä enenevässä määrin selainkehittäjien, esimerkiksi Firefox ja Safari, evästeiden rajaaminen mainostajilta. (IAB 2020, 13).

2.1 Osto-, myynti- ja datanhallintajärjestelmät

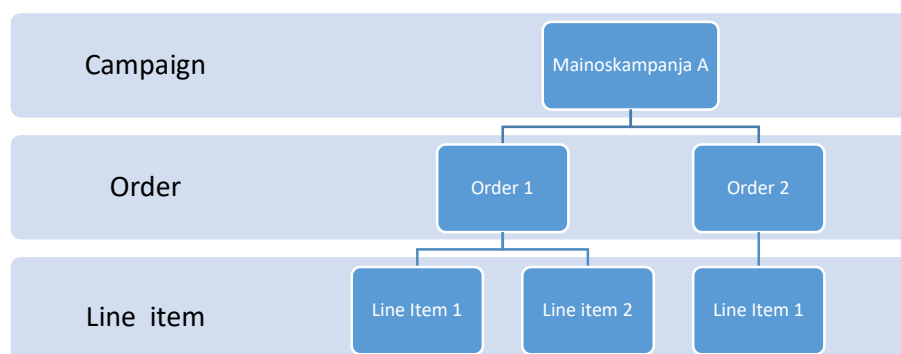
Ohjelmalliseen ostamiseen käytettävät järjestelmät voidaan luokitella kolmeen ryhmään, ostojärjestelmät, myyntijärjestelmät sekä datanhallintajärjestelmät. Näistä käytetään termejä Demand Side Platform (DSP), Supply Side Platform (SSP) sekä Data Management Platform (DMP).

Ohjelmallisen ostamisen kontekstissa inventaarilla tarkoitetaan julkaisijoiden myyntiin asettamien mainosnäyttöjen kokonaismäärää. Inventaaria voidaan tarkastella julkaisija- tai

mainosverkostokohtaisesti. DSP:t ovat ostavien tahojen käyttämiä järjestelmiä, jotka mahdollistavat mainospaikkojen inventaarin automatisoidun ostamisen julkaisijoilta mainospörssiin. Kyseiset järjestelmät antavat mainostajille pääsyn mainospörssiin, josta inventaaria voidaan ostaa lukuisilta tarjoajilta saman aikaisesti. (IAB 2020).

Ostojärjestelmiin luodaan kampanjat, joiden asetukset määrittelevät mitä inventaaria ja kuinka suurella summalla ostetaan. Useimmissa järjestelmissä toistuu sama kolmen tekijän hierarkia, jonka mukaan kampanjat rakennetaan. Korkeimpana määrittävänä tekijänä on itse kampanja ja sen asetukset, jonka sisään voidaan tarvittaessa luoda useampia ordereita. Order -termille ei ole vakiintunutta suomenkielistä vastinetta, mutta sitä kuvaava termi on määräys. Order voidaan nähdä mainosyksikkötasoa rajaavana määräysten, asetusten, kokonaisuutena. Rajaavia asetuksia voivat olla muun muassa määräyksen sisältämien mainosyksiköiden suurin sallittu rahallinen kulutus sekä ajankohta, jolloin mainosyksiköt voivat olla aktiivisia. Ordereiden avulla kampanjan toimenpiteitä voidaan myös lohkoa relevantteihin kokonaisuuksiin, kuten esimerkiksi kampanjassa käytettävien mainosmateriaalien mukaan. Esimerkkijaotteluna video- ja banneriaineisto omiin ordereihinsa. Koko vuoden kestävässä toimenpiteissä order-jaottelua voidaan tehdä esimerkiksi kvartaaleittain, jolloin budjettien hallinta voi olla selkeämpää.

Ordereiden sisään tulee luoda line itemit, mainosyksiköt, jotka lopulta määrittävät, mitä todella ostetaan, millä kohdennuksilla ja millä summilla. Line item -tasolla määritetään ajankohta, jolloin se on aktiivinen, minkä julkaisijoiden inventaaria ostetaan, kenelle se kohdennetaan ja mitä aineistoa käytetään. Hierarkian kannalta kampanjalle voidaan siis kampanjatasolla määrittellä kokonaisbudjetti, order-tasolla lohkoa kampanja relevantteihin kokonaisuuksiin ja line item tasolla toteuttaa suunnitellut toimenpiteet tarkalleen. Line item ei kuitenkaan voi kuluttaa enempää budjettia tai olla pidempään aktiivisena, kuin order-tasolla on rajattu. Sama suhde pätee ordereiden ja kampanjan asetusten välillä.

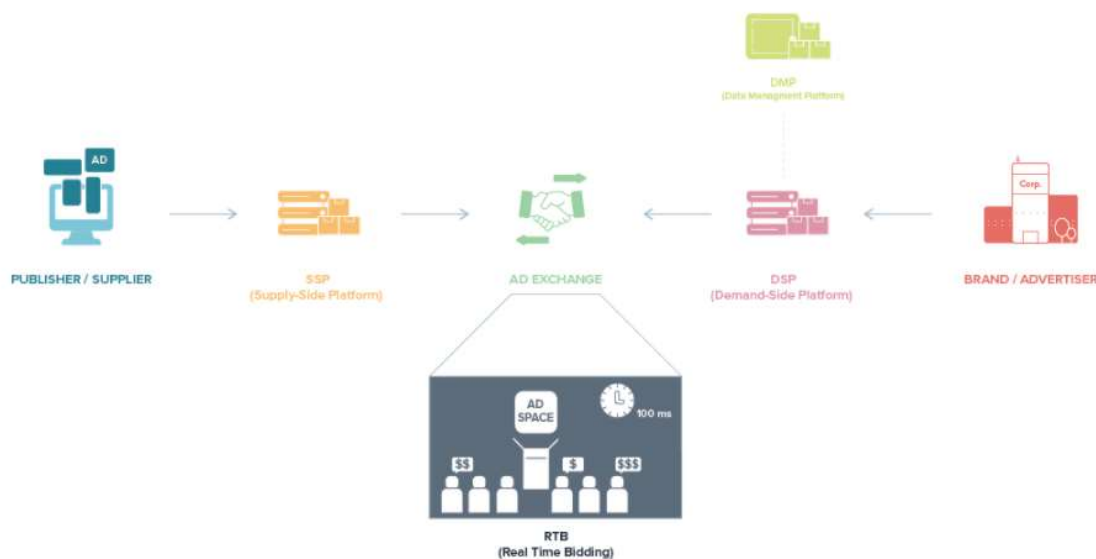


Kuvio 1: DSP kampanjahierarkia

SSP:t ovat julkaisijoiden käyttämiä järjestelmiä mainosinventaarin automatisoituun myyntiin. Näiden järjestelmien avulla julkaisijat saavat mainosinventaarinsa automatisoidusti useampien ostajien saataville mainospörssiin, johtaen tehokkaampiin myyntiprosesseihin. Käytännössä julkaisijat asettavat SSP:n avulla inventaarinsa mainospörssiin myytäväksi ja asettavat inventaareille pohjahinnat.

Datan hallintajärjestelmistä käytetään termiä Data Management Platform (DMP). DMP on tapa kerätä ja hallinnoida yrityksen dataa asiakkaistaan tai potentiaalisista asiakkaistaan. Datalähteitä voi olla useita, verkkosivu, CRM-järjestelmä, sosiaalinen media, analyyttikatyökalut. DMP:n avulla dataa voidaan säilöä ja pitää yllä, rikastaa, järjestellä relevanteiksi kokonaisuuksiksi ja hyödyntää ohjelmallisessa ostamisessa mainonnan kohdentamiseen. Järjestelmien keskeisiä ominaisuuksia ovat datan keruu ja segmentointi, uusien yleisöjen luonti ja tutkiminen sekä reaaliaikainen hallinnointi. Datan hallintajärjestelmät mahdollistavat olemassa olevien ja potentiaalisten asiakkaiden yksityiskohtaisemman palvelun personoidun markkinointiviestinnän keinoin. Nykyisiä asiakkaita pystytään palvelemaan paremmin yhdistämällä ja tutkimalla dataa eri lähteistä ja tarjoamalla heille todennäköisesti sopivampia tuotteita ja palveluita. Datan yhdistäminen eri lähteistä mahdollistaa saman käyttäjän tunnistamisen esimerkiksi eri laitteilla (cross-device), ja markkinoinnin panostuksien optimaalisemman käytön esimerkiksi mainonnan frekvenssin hallinnan kannalta. Yrityksen omaa dataa voidaan myös hyödyntää mallintamaan samankaltaisia isompia yleisöjä palveluntarjoajan laajemmasta evästedatasta. Käytännössä järjestelmä valjastetaan etsimään evästeavaruudesta lähdeyleisön kanssa samankaltaisesti käyttäytyviä evästeitä, ja koostamaan nämä omaksi yleisöksi. Näistä yleisöistä käytetään termiä look-a-like yleisöt.

Edellä mainituista osapuolista sekä prosesseihin käytetyistä teknologioista kokonaisuudessaan koostuu ohjelmallisen ostamisen ekosysteemi. Kuvassa 1 kuvataan ekosysteemin osapuolten ja teknologioiden yhteyttä toisiinsa. Mainostajat, tai heitä edustava taho, järjestävät ostotoimenpiteensä relevanteiksi kokonaisuuksiksi ostojärjestelmään. Myyvä taho, julkaisija, asettaa tarjoamansa inventaarin tarjolle myyntijärjestelmää hyödyntäen. Lopulta tämä kysyntä ja tarjonta kohtaa huutokauppanuotoisesti mainospörssissä useiden eri toimijoiden välillä saman aikaisesti.



Kuva 1: Ohjelmallisen ostamisen ekosysteemi (Match2One, 2020).

2.2 Ohjelmallisen ostamisen tasot ja hinnoittelu

Ohjelmallisen ostamisen eri tasoja ovat avoin huutokauppa, suljettu huutokauppa sekä kiinteähintaiset mallit. Kiinteähintaiset mallit voivat olla sidottuja toivottuun inventaarimäärään tai ajankohtaan. Yhteistä kiinteähintaisille malleille on tietyn näyttömäärän takaaminen.

Huutokauppamalleissa ostajat määrittelevät ostojärjestelmään CPM-bidin, eli mitä ovat valmiita maksamaan tuhannesta mainosnäytöstä kyseisessä verkostossa. Lopullisen maksettavan hinnan malleja on kaksi: first-price ja second-price. First-price mallissa voittavan huudon huutanut ostaja maksaa inventaarista huutamansa summan. Second-price mallissa voittavan huudon huutanut päätyy maksamaan toiseksi korkeimman huudon verran. Käytettävän mallin määrittää inventaaria myyvä taho, Suomessa on yleisesti käytetty second-price mallia mutta muutama iso mediatalo (Sanoma, Alma Media) on jo siirtynyt globaalisti yleistyvään first-price malliin. (Alma 2020; Sanoma 2020).

2.2.1 Huutokauppamallit

Ohjelmallisessa ostamisessa avoimella huutokaupalla tarkoitetaan nimensä mukaisesti kaikille ostajille avointa huutokauppaa. Avoimet huutokaupat ovat mainosverkostokohtaisia, joihin pääsee osallistumaan kaikki kyseessä olevaa ostojärjestelmää hyödyntävät ostajat. Perinteisen huutokaupan mukaisesti myös ohjelmallisessa huutokaupassa korkeimman hinnan huutanut voittaa huutokaupan. Avoimen huutokaupan suurin hyöty julkaisijoille on inventaarin myynti lukemattomille entuudestaan tuntemattomille ostajille, joihin ei tarvitse

olla suorassa kontaktissa myyntiä varten. Ostajille suurin hyöty on pääsy laajaan kansainväliseen inventaariin ilman kontaktia eri julkaisijoihin.

Kääntöpuolena avoimessa huutokaupassa on julkaisijoiden heikompi tietämys siitä, minkälaiset mainostajat ja millaisella mainosmateriaalilla heidän verkostossaan mainostavat. Toisaalta myös ostavalla taholla on todennäköisesti heikompi tietämys kyseisen verkoston yksittäisistä sivustoista ja näin suurempi riski olla esillä arveluttavien sisältöjen yhteydessä. Järjestelmät tarjoavat suojaa tiettyjen sisältöjen poissulkemiseksi kategorisesti, mutta nämä eivät täysin takaa turvallista ympäristöä mainostajalle. (IAB 2017).

Suljettu huutokauppa on toimintaperiaatteeltaan samanlainen avoimen huutokaupan kanssa, mutta suljetussa huutokaupassa julkaisija kutsuu valitsemiaan mainostajia osallistumaan huutokauppaan mainosinventaarista. Tämä tapahtuu erilaisia sopimus ID (Deal ID) -toimintoja hyödyntäen. Pelkistettynä sopimus ID on yksilöllinen koodi, jonka julkaisija toimittaa ostavalle osapuolelle. Ostaja pääsee koodia hyödyntämällä käsiksi julkaisijan inventaariin avoimen huutokaupan ohitse. Myös suljetussa huutokaupassa korkeimman huudon huutanut voittaa kaupan. (Aarki, 2020).

Eri huutokauppa- tai hinnoittelumalleista riippumatta ohjelmallisen ostamisen yleisimmin hyödynnetty muoto on real-time bidding (RTB). RTB on nimensä mukaisesti reaaliaikaisesti käytävää huutokauppaa mainosnäytöistä. Ostojärjestelmät osallistuvat huutokauppoihin niille asetetuin säännöin, myyntijärjestelmät asettavat inventaarin saataville, sekä käyvät huutokauppaan osallistuvien tarjoushuudot läpi päättäen lopulta voittavan tarjouksen. Koko prosessi tapahtuu millisekuntien aikana samalla aikaa, kun selain lataa vierailijalle sivuston sisältöä. (IAB 2020, 10).

2.2.2 Kiinteähintaiset mallit

Kiinteähintaisissa malleissa ostava ja myyvä taho määrittävät yhdessä kiinteän CPM hinnan ostettavalle näkyvyydelle. Kiinteähintaisien mallien välillä yhteistä on tietyn näyttömäärän takaaminen. Malli mukailee hyvin pitkälle perinteistä mediatilan suoraostoa, sillä se vaatii neuvotteluja myyvän ja ostavan tahon välillä aina tapauskohtaisesti. Näkyvyydestä voidaan neuvotella kampanjakohtaisesti tai pidemmälle aikavälille tietystä volyymistä. Sopimuksen synnyttyä myyjä toimittaa sovittujen ehtojen mukaisen Deal ID:n, jonka avulla osto voidaan toteuttaa. Ero perinteiseen suoraostoon on lopullisen mainostilan hankinnan ja mainosmateriaalien toimittaminen ohjelmallisesti järjestelmiä hyödyntäen.

Kiinteähintaisten mallien etuja ovat läpinäkyvyys molemmille osapuolille. Julkaisija tietää kuka sivustolla mainostaa ja minkälaisella materiaalilla, mainostaja tietää minkälaisessa mediaympäristössä mainonta tulee näkymään. Kääntöpuolena mainostajalle on mainonnan

heikko skaalautuvuus, sillä laajemman mediapeiton saavuttamiseksi vastaavia toimenpiteitä tulisi tehdä useamman julkaisijan kanssa erikseen.

3 Digitaalisen mainonnan mittaaminen

Digitaalisen mainonnan vahvuus suhteessa perinteiseen mainontaan on sen hyvä mitattavuus. Perinteisen offline-kanavissa tehtävän mainonnan, esimerkiksi printtimainonta tai radio, mittaaminen on vajavaista ja sen vaikutus liiketoimintaan on heikommin todennettavissa. Yksittäisellä lehden aukeamalla olevan mainoksen todellista katselijamäärää on mahdotonta todentaa, radiomainoksista saadaan vastaanotinten perusteella suuntaa antavaa lukua kuulijamäärästä. Kuitenkin näiden toimenpiteiden suoraa yhteyttä mainokselle altistumisesta toivottuun tulokseen asti on huomattavasti hankalampaa todentaa ja se vaatii erillistä tutkimusta aiheesta. Digitaalisessa mainonnassa sen sijaan voidaan hyvin tarkasti todentaa, kuinka moni käyttäjä mainokselle on altistettu, kuinka moni heistä on sen kautta siirtynyt verkkosivustolle ja kuinka moni heistä on tehnyt toivotun toimenpiteen sivustolla. Käyttäjien toimenpiteitä voidaan myös mitata vaikkei polku toimenpiteeseen olisikaan aivan näin suora, vaan vaiheita ja käytettyjä kanavia toivottuun toimenpiteeseen olisi useampia tai vähemmän.

Mittaamisen tarkoitus on tuottaa toimenpiteistä dataa, joka ohjaa tietoon perustuvaa päätöksentekoa. Digitaalisen markkinoinnin mittaamiseen käytettäviä työkaluja ja malleja on lukuisia, tunnetuimpana Google Analytics. Googlen analytiikkatyökalulla pystytään seuraamaan liikennettä ja toimenpiteitä verkkosivustolla tarkalla tasolla. Analytiikkatyökalut mittaavat ensisijaisesti verkkosivustojen suoriutumista ja näitä mittareita ei välttämättä suoraan pystytä jalkauttamaan mainonnan käyttöön. Ohjelmallisen mainonnan mittaamisen kannalta tärkeämpiä työkaluja ovat itse DSP:t ja niihin integroidut raportointijärjestelmät. DSP:den raportointi perustuu pikseli- ja evästedataan ja niistä saadaan ajettua suoraan mainonnan tehokkuutta kuvaavia mittareita. Oleelliset ja seurattavat mittarit johtuvat suoraan liiketoiminnan tavoitteista ja niiden tulee kuvastaa toimenpiteiden tehokkuutta.

Oikeiden seurattavien ja kehitettävien mittareiden valinta tulee juontua liiketoiminnan tavoitteista. Yksittäisillä kampanjoilla on usein kuitenkin spesifimmät mittarit, kuin liiketoiminnalla yleisellä tasolla. Vaikka mittarit olisivatkin eri, tulee niiden olla linjassa keskenään. Esimerkiksi liiketoiminnan tavoitteena voi olla kasvattaa sivukävijöiden määrää x määrä kvartaalin aikana. Mainoskampanjoilla voidaan vastata tähän liiketoiminnan tavoitteeseen mittaamalla ja optimoimalla mainontaa sivustolle siirtymisiä, klikkejä, kohden. Yhtä lailla liiketoiminnan tavoitteena voi olla myynnin kappalemääräinen kasvu tietyssä ajanjaksona, mainonnalla voidaan osaltaan edesauttaa tavoitteen täyttymistä optimoimalla yksittäisen konversion hintaa ja näin maksimoimalla konversioiden määrä käytössä olevalla budjetilla.

Ostojärjestelmien raportointityökalut mahdollistavat kampanjoiden suoriutumisen reaaliaikaisen tarkastelun. Saatavilla olevat metriikat ovat alustakohtaisia, mutta yleisesti raportoinnin skaala on laaja yleiseltä kampanjatasolta aina yksittäisten mainosversioiden, -verkostojen ja julkaisijoiden tarkasteluun asti. Yksittäisten mainonnan mittareiden lisäksi työkaluilla saadaan läpinäkyvyyttä myös huutokaupassa suoriutumiseen. Raportoinnilla voidaan tarkastella huutojen määrää, niiden voittoprosenttia sekä syitä huutojen häviämiseksi. Kaikki edellä mainittu antaa ostajalle arvokasta lisätietoa ja valtaa toimenpiteiden proaktiiviseen kehittämiseen.

Raportointityökalujen lisäksi markkinoinnin toimenpiteiden tehokkuutta voidaan tarkastella kokonaisuutena laajemmalla tasolla kanavakohtaisesti attribuutiomallinnuksen avulla. Mallinnuksen tavoitteena on koostaa näkemys ja ymmärrys siitä, mitä yksittäisissä kanavissa tapahtuu, ja kuinka merkittävä kunkin kanavan rooli on kuluttajan ostopäätökseen (Järvinen 2016). Attribuutiomallinnus mahdollistaa toimenpiteiden kanavakohtaisen tarkastelun ja optimoinnin kuluttajan matkalla mainokselle altistumisesta ostopäätökseen. Mallinnuksen avulla saadaan parempaa kokonais käsitystä toimenpiteiden merkittävydestä ja toimivuudesta kanavakohtaisesti, ja löydöksiä voidaan hyödyntää käynnissä olevien toimenpiteiden optimointiin tai tulevien kokonaisuuksien suunnitteluun.

Attribuutiomalleja on useita, mutta yhdistävää niille on tietyn arvon antaminen jokaiselle kauppaan tai muuhun toivottuun toimenpiteeseen johtaneelle kosketuspisteelle. Yleisimpiä malleja ovat viimeisen klikin malli (hyöty lasketaan sille kanavalle, joka on johtanut viimeiseen klikkiin), viimeinen kontakti (hyöty lasketaan sille kanavalle, joka on johtanut viimeiseen kontaktiin), ensimmäinen klikki, ensimmäinen kontakti, tasattu painoarvo (kaikille kanaville lasketaan sama arvo) sekä painotettu malli, jossa mainostajan aiempien kokemusten mukaan räätälöidään attribuutiomalli.

4 Algoritmit

Alun alkaen algoritmit ovat matemaattinen käsite ja tänä päivänä digitaalisen maailman perustyökalu. Algoritmit voivat yksinkertaisimmillaan olla tosi-epätosi ratkaisumalleja tietyn ongelman ratkaisemiseksi vuokaavio menetelmällä, tarkemmin ohje tai laskentakaava käsillä olevan ongelman ratkaisemiseksi. Algoritmien keskeisin tavoite on prosessien tehostaminen valmiita ratkaisumalleja, laskentakaavoja, hyödyntäen. Todellisuudessa digitaalisessa markkinoinnissa käytettävät algoritmit ovat edellä kuvailtua huomattavasti monimutkaisempia ja monivaiheisempia. Peruseriaate kuitenkin on sama. Niiden tarkoitus on laskea paras tarjolla oleva ratkaisu ongelmaan tarjolla olevaan dataan perustuen määriteltäviä ratkaisumalleja, laskentakaavaa, noudattaen. Algoritmi toimii järjestelmälle ohjeistuksena

siitä, miten missäkin tilanteessa tulee toimia, ja järjestelmä noudattaa kyseistä ohjeistusta tarkasti.

Algoritmeja hyödynnetään digitaalisessa maailmassa hyvin monimuotoisesti. Yksittäiselle digitaalisen palvelun kuluttajalle algoritmit näyttäytyvät esimerkiksi Googlen hakutulosten järjestyksenä, Facebook tai Instagram syötteen sisältönä tai verkkokaupan suosittelimina tuotteina. Googlen hakukoneen algoritmi laskee kullekin haulle todennäköisesti sopivimmat tulokset ja näyttävät ne osuvuuden mukaan. Facebookin ja Instagramin käyttäjäkohtainen syöte mukautuu käyttäjän alustalla kuluttaman sisällön mukaiseksi algoritmin nostaessa syöteeseen todennäköisimmin käyttäjän kiinnostuksia tai arvoja kohtaavaa sisältöä. Samoin verkkokaupassa voidaan algoritmien avulla ehdottaa kuluttajaa todennäköisimmin kiinnostavia tuotteita tai ostettuun tuotteeseen sidoksissa olevia tuotteita, esimerkiksi lisätarvikkeita tai muiden käyttäjien kyseisen tuotteen lisäksi ostamia tuotteita. Yhtä lailla algoritmeja voidaan hyödyntää myös mainosten sijoitteluun, kohdentamiseen tai mainosmateriaalien reaaliaikaiseen yksilöintiin saatavilla olevan käyttäjädatan mukaan. (Siltanen 2018; Toivonen 2018).

Algoritmin tarkka määrittely on haastavaa niiden monimuotoisuudesta vuoksi. Markkinoinnin kontekstissa voidaan puhua algoritmisen markkinoinnin kokonaisuudesta, jonka Katsov (2018, 4) määrittelee olevan markkinointiprosessi, joka on automatisoitu siinä määrin, että sitä voidaan ohjata asettamalla liiketoiminnallinen tavoite markkinointijärjestelmälle. Katsov lisää, että järjestelmän tulisi olla riittävä älykäs ja tietoinen ymmärtämään liiketoiminnan ylätasoa tavoitteita, kuten asiakasmäärän lisääminen tai tulojen maksimoiminen, suunnitellakseen ja toteuttaakseen liiketoimintoja, kuten mainoskampanjat tai hinnanmuutokset, liiketoiminnan tavoitteiden täyttämiseksi. Lisäksi järjestelmän tulisi oppia tuloksista ja tarvittaessa pystyä korjaamaan sekä optimoimaan toimenpiteitä. Ohjelmallisen ostamisen kontekstissa mainostajan näkökulmasta markkinointijärjestelmää edustaa ostotyökalu ja algoritmeilla ostojärjestelmälle asetetaan sääntöjä, liiketoiminnallisia tavoitteita, siihen kuinka huutokaupassa mainostilasta tulee huutaa. Algoritmin tulee ottaa huomioon markkina, kampanjatavoite, budjetti ja muut liitännäisvaikutteet yksittäisen huudon ympärillä (McRobie, 2012).

Ohjelmallisen ostamisen ostotyökaluissa liiketoiminnasta johdettujen tavoitteiden täyttymisen kannalta oleellisimpia algoritmeja ovat niin kutsutut tarjousalgoritmit, joista käytetään yleisesti termiä bidausalgoritmit (engl. bidding algorithm). Järjestelmässä määritellään käytettävä algoritmi valitsemalla kampanjan tavoite. Näitä voivat olla esimerkiksi puhtaasti CPM-hinnan, klikin hinnan (CPC) ja konversion hinnan (CPA) optimointi tai näytöllä näkyvillä olleiden mainosnäyttöjen maksimointi (viewability) sekä kampanjan kokonaistavoitavuuden (reach) maksimointi. Vaikka osto tapahtuu aina CPM-hinnalla, mainontaa voidaan silti optimoida tiettyä kampanjatavoitetta kohden ostotyökaluihin

rakennetuin algoritmein. Algoritmit vaihtelevat alustoittain, mutta tyypillisimpiä ovat edellä mainitut digitaalisen mainonnan perusmittareihin nojaavat Reach, CPC, CPA ja viewability. Valittu algoritmi määrittää ostotyökälulle, mitä lopputulemaa sen tulee arvottaa. Esimerkki: Mainonnan tavoitteena on kasvattaa verkkosivun liikennettä kampanjan aikana ja tukea liiketoiminnan ylätasoa tavoitteita. Tätä tavoitetta vasten optimaalisin algoritmi on klikin hintaa arvottava CPC, sillä se pyrkii toteuttamaan asetettua klikin hintarajaa ja näin maksimoimaan mainonnan klikkien määrän käytettävissä olevalla mainosbudjetilla saatavilla olevan datan perusteella.

Bidauusalgoritmien lisäksi ostojärjestelmissä on usein hyödynnettävissä muita budjetinhallintaa tehostavia työkaluja, tämä on kuitenkin hyvin järjestelmäkohtaista. Esimerkiksi Googlen DV360 järjestelmässä on hyödynnettävissä order-tason algoritmi, joka ohjaa asetettua budjettia line itemien välillä niiden suoriutumisen perusteella tavoitteeseen nähden. Facebook Business Managerissa on hyödynnettävissä samankaltainen ominaisuus Campaign Budget Optimization -algoritmin muodossa (Facebook for business, 2020). Googlen DV360:ssa aiemman kampanjahierarkiaesimerkin mukaisesti order -tasolla järjestelmälle asetetaan order tason budjetin optimointi, jolloin järjestelmän algoritmi allokoii annettua budjettia line itemeille niiden suoriutumisen mukaan kampanjatavoitteeseen nähden. Googlen tapauksessa järjestelmä voi nostaa päivittäistä budjettia hyvin toimivilla line itemeillä 20 % ja vastavuoroisesti laskea huonosti toimivien päiväbudjettia 20 %, järjestelmä toimii kuitenkin annetun kokonaisbudjetin rajoissa (Display & Video Help, 2020).

Yhtä kaikille sopivaa algoritmia markkinoinnin kontekstissa ei ole olemassa. Eri algoritmeilla on omat vahvuutensa ja heikkoutensa, ja ”parhaan” algoritmin jahtaamisen sijaan markkinoijille todennäköisesti tuloksellisempaa on hyödyntää järjestelmää, joka tarjoaa algoritmien osalta joustavuutta ja valinnanvaraa laajaan skaalaan digitaalisen markkinoinnin tarpeista. Mainonnanhallintajärjestelmät ja niihin luodut algoritmit eivät välttämättä ole luotu ottamaan huomioon yksittäisen mainostajan toimialakohtaisia tai yksilöllisiä ominaisuuksia ja toisaalta mittareita toimivuudelle on lukemattomia. Ostojärjestelmien tarjoamat algoritmit ovat kaikkien järjestelmää käyttävien ostajien hyödynnettävissä ja tarjoavat käyttäjilleen työkalut yksittäisten markkinointitavoitteiden saavuttamiseen kampanjakohtaisesti. Aiemman esimerkin mukaan mainostajat pystyvät tarjolla olevien algoritmien avulla osaltaan sovittamaan ohjelmallisen ostamisen toimenpiteitään liiketaloudellisia tavoitteita tukevaksi. Järjestelmien tarjoamat algoritmit ovat universaaleja monialaisesti skaalautuvia ratkaisumalleja mainostajan toimialasta riippumatta, siksi täydellisen algoritmin jahtaamisen sijaan oleellisempaa on järjestelmien joustavuus algoritmitarjonnassa, ja mainostajien kyvykyys valjastaa ne palvelemaan liiketalouden tavoitteita. (Kechley, 2012).

5 Tutkimusmenetelmä

Tämän opinnäytetyön tutkimusosaan hyödynnetään kvasikokeellista difference in differences - tutkimusmenetelmää. Tutkimusmenetelmä on syntynyt ekonometrian alalla, mutta menetelmän taustalla olevaa logiikkaa on käytetty jo 1850-luvulla John Snow'n toimesta (Columbia University, 2019a). Difference in differences tutkimusmenetelmä on yksi yleisimmin käytetyistä vaikutuksen arvioinnin tutkimuksissa (Fredriksson & Magälhaes de Oliveira 2019, 519). Tutkimusmetodiin viitataan opinnäytetyössä sen koko nimellä sekä lyhennelmällä DiD.


DiD voidaan luokitella kvasikokeellisten tai näennäiskokeellisiksiin kutsuttujen tutkimusmenetelmien joukkoon. Sen perusajatus on hyödyntää pitkittäissuuntaista dataa tutkimus- ja kontrolliryhmistä muodostamaan asianmukaista vaihtoehtoista informaatiota ennustamaan jonkin toimenpiteen, intervention, kausaalista vaikutusta. Tyypillisesti tutkimusmetodia hyödynnetään arvioimaan jonkin tietyn toimenpiteen, esimerkiksi lainsäädännön, vaikutusta vertailemalla niin sanottujen kontrolli- ja tutkimusryhmien vaihtelua tietyllä aikajaksolla. Vertailulle oleelliset ryhmät koostuvat ryhmästä, joka altistuu toimenpiteelle (tutkimusryhmä) sekä ryhmästä, jota ei altisteta toimenpiteelle (kontrolliryhmä). (Columbia University, 2019b).

Tutkimusmenetelmän tavoite on arvioida intervention kausaalista vaikutusta tapauksissa, joissa interventiotoimenpide ei ole satunnainen. Käytännössä tämä tapahtuu yhdistämällä tutkimus- ja kontrolliryhmien poikkileikkaavaa numeerista dataa sekä ennen-jälkeen tutkimusta luotettavamman tuloksen takaamiseksi. Tarkennettuna, tutkimus vaatii dataa kahdesta ryhmästä kahdella eri ajanjaksolla. Molempien ryhmien kehitystä seurataan sekä ennen, että jälkeen intervention. Näillä tekijöillä intervention vaikutuksen estimaatti voidaan kirjoittaa kaavan 1 mukaiseen muotoon.

$$DiD = (y_{t=jälkeen}^{interventio} - y_{t=ennen}^{interventio}) - (y_{t=jälkeen}^{kontrolli} - y_{t=ennen}^{kontrolli})$$

Kaava 1: DiD estimaatti

Kaavassa 1 y kuvastaa tuloksen muuttujaa, kyseessä oleva ryhmä on ilmoitettu termein ”Interventio” tai ”Kontrolli” ja t kuvaa ajankohtaa. Tutkimus- ja kontrolliryhmien ennen-jälkeen datasta saadaan tuotettua nelikenttä ja kaksinkertainen ero laskettua. Tyypillisesti tämä esitetään taulukossa, jossa on kaksi riviä ja kaksi saraketta ryhmien ennen ja jälkeen datalle. Taulukkoon lisätään kolmas sarake ja rivi ryhmien ja ajanjaksojen eroavaisuuksien sekä intervention vaikutuksen laskemiseksi. Kuvassa 2 on visualisoitu tutkimusmetodin mukaisten ryhmien muutokset ja intervention kausaalinen vaikutus.



Kuva 2: Kuvaus DiD estimaatista kaksiryhmäisessä tapauksessa vertailuajanjaksoilla (Fredriksson & Magälhaes de Oliveira 2019, 522).

Monimuuttujatutkimuksissa DiD mallin tuloksia voidaan tarkastella pidemmälle regressioanalyysin avulla. Regressioanalyysin tarkoitus on sulkea pois tutkittavaan muuttujaan vaikuttavia ulkoisia tekijöitä aikajaksoilla. Toisin sanoen regressioanalyysi on hyödyllinen siinä tapauksessa, että tutkittavaan kohteeseen vaikuttaa useampia tekijöitä, joita ei voida kontrolloida. Regressioanalyysillä näiden tekijöiden vaikutukset suljetaan pois intervention puhtaamman kausaalisen vaikutuksen selvittämiseksi. Tässä tutkimuksessa regressioanalyysia ei toteuteta, sillä kampanjoiden sisällä kontrolli- ja tutkimusryhmien välillä tunnistettuja muuttujia on vain yksi, algoritminen työkalu.

5.1 Toimeksiantaja ja tutkimuksen kohde

Opinnäytetyön toimeksiantajana toimii vuonna 2019 perustettu RADLY Oy, jonka toimialaa on ”markkinoinnin ja myynnin kehittäminen, konsultointi ja markkinointiteknologian hyödyntäminen” (Kauppalehti, 2020a). RADLY Oy on yhden Suomen suurimmista mediatoimistoista, Dagmar Oy:n, 100 % omistama tytäryhtiö.

Yrityksen liiketoiminta rakentuu vahvasti markkinoinnin automaation ja AI-kehityksen ympärille. RADLY:n tarjoama koostuu SaaS -työkaluista (Software as a service), tehokkaiden markkinointi- ja myyntiprosessien luomisesta, teknologioiden kehittämisestä ja toimittamisesta sekä markkinoinnin transformaatiosta sisältäen uusien mahdollisuuksien, toimintatapojen ja prosessien suunnittelun yhdessä asiakkaidensa kanssa. (RADLY, 2020a).

Tutkimuksen kohteena on RADLY Oy:n kehittämä algoritminen työkalu, Optimizer, joka on tarkoitettu ohjelmallisen ostamisen tehokkuuden parantamiseen. Optimizer on mainonnanhallintajärjestelmään kytkettävä työkalu, joka ohjaa sille optimoitavaksi osoitetun kampanjan budjetteja line item -tasolla. Sen tavoitteena on kampanjan tehokkuuden

maksimointi valitun metriikan perusteella sekä kampanjasta vastaavan suunnittelijan manuaaliseen optimointityöhön käytetyn ajan säästäminen. Tässä tutkimuksessa keskitytään algoritmisen työkalun vaikutukseen digitaalisen mainonnan mittareilla. (RADLY, 2020b).

Optimizer perustuu optimointiryhmiin, jotka luodaan järjestelmässä. Käytännössä tämä tarkoittaa manuaalista työtä, jossa käyttöjärjestelmässä määritellään optimointiryhmän kampanja ja tarkemmin automatisoituun budjetin optimointiin asetettavat line itemit. Optimointiryhmän lisäksi järjestelmälle tulee määritellä optimointiprosessin tavoite. Näitä ovat tällä hetkellä konversion hinta (CPA), klikin hinta (CPC) sekä viewability. Työkalun toimintaperiaate koostuu algoritmisesta prosessista, jonka toimintasykli on 24 tuntia. Käytännössä algoritmi tarkastelee optimointiryhmän line itemien suoriutumista yksilöllisesti, luo historiatiedon perusteella lyhyen ajan ennusteen suoriutumisesta ja budjetin kulutuksesta ja lopulta tämän ennusteen perusteella siirtää budjettia parhaiten toimiville line itemeille. Automatisoidun budjetin optimoinnin tavoitteena on saavuttaa tilanne, jossa jokaiselle line itemille on allokoitu sen suorituskyvyn perusteella optimaalinen budjetti parantaen optimointiryhmän suoriutumista kokonaisuutena. (RADLY, 2020c).

Tässä tutkimuksessa toteutettuihin kampanjoihin on käytetty Optimizerin CPC-optimointia. Kyseisellä optimointitavoitteella työkalu pyrkii klikkien määrän maksimointiin, johon on mahdollista päästä optimointiryhmän CPC-hintaa alentamalla tai ryhmän kokonaiskulutusta kasvattamalla. Kokonaiskulutuksen kasvatus ei tarkoita kampanjalle asetetun budjetin ylitystä, vaan sen maksimaalista käyttöä. Ohjelmallisesti ostetuissa kampanjoissa ilmenee usein alikulutusta, joka aiheutuu monesti puutteellisesta manuaalisesta optimointityöstä. (RADLY, 2020d).

5.2 Tutkimusaineiston perustiedot

Tutkimusaineisto koostuu kahden todellisen ohjelmallisesti ostetun mainoskampanjan tunnistamattomaan muotoon muunnetuista numeerisista tuloksista. Aineistoa jaetaan kampanjoittain ja ryhmittäin kahteen ajanjaksoon ennen interventiota ja sen jälkeen. Kumpikin ajanjakso on 28 päivän mittainen. Tulokset ovat raportoitu suoraan mainonnanhallintajärjestelmästä, tässä tapauksessa Adformista, kampanjakohtaisesti ja sisältävät tutkimukselle olennaisimpiin mittareihin liittyvät tulokset. Mittareiksi on valittu kampanjoiden keskimääräiset kulutukset, impressiot (mainosnäytöt), klikit, klikkien hinnat sekä klikkiprosentit tarkastelujaksoilta. Tulokset ovat suodatettu kampanjakohtaisesti ajanjaksoittain. Kampanjatulokset on jaettu kampanjakohtaisesti tutkimusmetodin kannalta oleelliseen neljään osaan. Kampanjat erotellaan toisistaan nimeämisellä A ja B, kampanjanimen lisäksi taulukoista ilmenee kyseessä oleva ryhmä ja aikajakso. Kontrolli ja tutkimusryhmät ovat aineistossa nimetty ”control group” ja ”research group”, sen mukaan onko ne altistettu interventiolle, ja eroteltu ajanjaksoin ”comparison” ja ”optimization” sen

mukaan, onko kyseessä tulokset ennen vai jälkeen intervention. Tutkimuksessa interventiolla viitataan työkalun käyttöönottoon. Taulukoiden otsikoinnissa ilmaistaan kyseessä oleva kampanja, ryhmä sekä ajanjakso.

Kampanjoiden tuloksista on laskettu tutkimusmetodin mukaisesti vertailuryhmien väliset kaksinkertaiset erot metriikkakohtaisesti algoritmisen työkalun vaikutuksen arvioimiseksi. Difference in differences -tulokset ovat raportoitu omina taulukkoinaan kampanjakohtaisesti numeerisessa muodossa. Tutkimusmetodin tuomat tulokset algoritmisen työkalun vaikutuksesta esitetään myös oleellisimman metriikan, keskiarvoisen klikin hinnan, osalta kuvioin kampanjakohtaisesti.

6 Tutkimustulokset

Taulukossa 1 esitetään kampanjan A kontrolliryhmän tuloksia aikajaksolla ennen interventiota ja taulukossa 2 saman ryhmän tuloksia intervention jälkeen. Huomionarvoista on, että kyseistä ryhmää ei altistettu interventiolle ja se toimii vertailuryhmänä. Tuloksia tarkastelemalla voidaan todeta keskimääräisen päivittäisen kulutuksen laskeneen vertailujaksolta optimointijaksolle. Myös keskimääräiset impressio- ja klikkimäärät, kuten myös klikkiprosentti, ovat laskeneet. Kampanjan optimointitavoite, CPC, on noussut 0,15 euroa kontrolliryhmässä. Yhteenvetona, kaikki mainonnan mittarit kampanjan A kontrolliryhmässä ovat heikentyneet kampanja-aikana.

A - Control Group/Comparison	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
control-A-lineitem3	19,81	2877,00	24,50	0,81	0,85

Taulukko 1: Kampanja A - kontrolliryhmä vertailujaksolla

A - Control Group/Optimization	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
control-A-lineitem3	17,75	2645,96	18,50	0,96	0,70

Taulukko 2: Kampanja A - kontrolliryhmä optimointijaksolla

Taulukoissa 3 ja 4 esitetään kampanjan A interventiolle altistetun tutkimusryhmän tuloksia vertailu- ja optimointijaksolla. Tutkimusryhmän sisällä line itemeissa on huomattaviakin eroja keskimääräisissä päivittäisissä tuloksissa mutta se ei ole tutkimusmetodille olennaista, vaan ryhmää tarkastellaan kokonaisuutena. Tuloksista ilmenee, että keskimääräinen päivittäinen kulutus on noussut. Kuitenkin impressiomäärä on laskenut ja tästä voidaan tehdä

johtopäätös mainonnan kustannustehokkuuden heikkenemisestä. Myös keskimääräinen klikkien määrä on laskenut johtaen kalliimpaan yksittäisen klikin hintaan ja heikentyneeseen klikkiprosenttiin.

A - Research Group/Comparison	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
optimized-A-lineitem1	19,81	2847,04	50,04	0,40	1,76
optimized-A-lineitem2	19,80	2824,32	36,39	0,54	1,29
optimized-A-lineitem4	26,31	6273,54	27,86	0,94	0,44
optimized-A-lineitem5	28,63	5098,43	42,93	0,67	0,84
Grand Total	23,64	4260,83	39,30	0,60	0,92

Taulukko 3: Kampanja A - tutkimusryhmä vertailujaksolla

A - Research Group/Optimization	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
optimized-A-lineitem1	25,23	3614,43	35,61	0,71	0,99
optimized-A-lineitem2	26,43	3762,39	40,25	0,66	1,07
optimized-A-lineitem4	20,09	4736,89	19,00	1,06	0,40
optimized-A-lineitem5	25,01	4276,71	34,18	0,73	0,80
Grand Total	24,19	4097,61	32,26	0,75	0,79

Taulukko 4: Kampanja A - tutkimusryhmä optimointijaksolla

Taulukoista 5 ja 6 ilmenee kampanjan B kontrolliryhmän tulokset vertailuajanjaksoilla. Kampanjan B kontrolliryhmän keskimääräisen kulutuksen voidaan todeta laskeneen johtaen pienentyneeseen impressioiden määrään. Myös klikkien määrän voidaan todeta laskeneen, klikin hinnan pysyneen ennallaan ja klikkiprosentin nousseen suhteellisesti melko paljon, noin 13 %. Klikkiprosentin nousu selittyy seuratun ryhmän sisäisillä eroilla ja tutkimuksen kannalta oleellista on ryhmän keskiarvon muutoksen tarkastelu.

B - Control Group/Comparison	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
control-B-lineitem7	19,62	4157,96	42,75	0,46	1,03
control-B-lineitem8	17,57	3671,54	18,39	0,96	0,50
Grand Total	18,60	3914,75	30,57	0,61	0,78

Taulukko 5: Kampanja B - kontrolliryhmä vertailujaksolla

B - Control Group/Optimization	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
control-B-lineitem7	15,75	3044,75	33,61	0,47	1,10
control-B-lineitem8	16,05	2883,29	18,46	0,87	0,64
Grand Total	15,90	2964,02	26,04	0,61	0,88

Taulukko 6: Kampanja B - kontrolliryhmä optimointijaksolla

Kampanjan B tutkimusryhmän tulosten vaihtelua tarkastellaan taulukoissa 7 ja 8. Tutkimusryhmän keskimääräinen kulutus ja sen myötä impressiomäärä on noussut. Yhtä lailla keskimääräinen klikkien määrä ja klikkiprosentti ovat nousseet johtaen alhaisempaan yksittäisen klikin keskimääräiseen hintaan. Jälleen ryhmän sisällä line itemien välillä on suurta vaihtelua, tutkimusmetodissa tarkastellaan ryhmää kokonaisuutena.

B - Research Group/Comparison	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
optimized-B-lineitem9	8,24	1728,14	9,57	0,86	0,55
optimized-B-lineitem10	10,82	2427,86	10,46	1,03	0,43
optimized-B-lineitem11	0,08	14,75	0,00	0,00	0,00
optimized-B-lineitem12	5,38	887,57	1,68	3,21	0,19
optimized-B-lineitem13	4,51	897,82	12,43	0,36	1,38
Grand Total	5,97	1225,83	7,03	0,85	0,57

Taulukko 7: B - tutkimusryhmä vertailujaksolla

B - Research Group/Optimization	Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
optimized-B-lineitem9	12,01	2198,39	18,71	0,64	0,85
optimized-B-lineitem10	13,59	2707,29	24,57	0,55	0,91
optimized-B-lineitem11	0,01	3,44	0,00	0,00	0,00
optimized-B-lineitem12	6,69	1432,00	6,86	0,98	0,48
optimized-B-lineitem13	4,32	709,32	9,61	0,45	1,35
Grand Total	7,89	1518,29	12,87	0,61	0,85

Taulukko 8: Kampanja B - tutkimusryhmä optimointijaksolla

Taulukoissa 1-8 esitettyjä kampanja- ja ryhmäkohtaisia tuloksia ennen ja jälkeen intervention hyödynnetään difference in differences menetelmän mukaisesti selvittämään intervention kausaalista vaikutusta ja kaksinkertaisen eron laskemiseen. Kuten tutkimusmenetelmästä on aiemmin mainittu, kausaalinen vaikutus saadaan laskettua kaavan 1 avulla. Taulukoissa 9 ja 10 on esitetty metodin mukaiset numeeriset estimaatit intervention vaikutukselle metriikkakohtaisesti kampanjoittain.

Kampanjoiden A ja B ryhmäkohtaisten line itemien päivittäisen kulutuksen keskiarvon muutoksien perusteella voidaan todeta, ettei käytössä ollut algoritmisen työkalu allokoii budjettia aggressiivisesti pelkästään ryhmän parhaiten toimivalle line itemille, vaan jakaa sen melko tasaisesti, kuitenkin painottaen paremmin suorituvia.

Taulukon 9 mukaisesti kampanjasta A voidaan todeta, että algoritmisen työkalun avulla keskimääräinen päivittäinen kulutus on noussut 2,62 euroa korkeammalle kuin se olisi ilman työkalua asettunut. Optimointiryhmän lähtötilanteeseen nähden tämä tarkoittaa 11 % suhteellista kasvua keskimääräiseen päivittäiseen kulutukseen. Vastaavasti impressioiden

päivittäinen keskiarvo on tutkimusmetodin mukaan noussut 67 impressiolla. Tavoitemittarissa, klikin hinnassa, ei työkalulla ole DiD-mallin mukaan ollut kausaalista vaikutusta toteumaan. Myös klikkien keskiarvoinen määrä on mallin mukaan laskenut yhdellä.

A DiD results				
Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
2,62	67,81	-1,04	0,00	0,02

Taulukko 9: Kampanjan A mallinnetut tulokset

Taulukon 10 perusteella algoritmisen työkalun kausaalinen vaikutus kampanjaan B on ollut kaikilla mittareilla positiivinen. Keskimääräinen päivittäinen kulutus kampanjassa on noussut työkalun ansiosta 4,61 euroa, johtaen osaltaan 1243 impression keskimääräiseen kasvuun. Optimointiryhmän lähtötilanteeseen suhteutettuna keskimääräinen päivittäisen kulutuksen kasvu oli 77 %, sillä ilman työkalua kulutuksen voidaan olettaa laskeneen kontrolliryhmän tapaan. Tavoitemittari, klikin hinta, on laskenut työkalun ansiosta 0,24 euroa tuottaen keskimäärin noin 10 klikkiä enemmän ja nostaa keskimääräistä klikkiprosenttia 0,18.

B DiD results				
Avg. Cost	Avg. Impressions	Avg. Clicks	Avg. CPC	Avg. CTR
4,61	1243,19	10,38	-0,24	0,18

Taulukko 10: Kampanjan B mallinnetut tulokset


Difference in differences tulokset kertovat intervention kausaalisesta vaikutuksesta kampanjalle absoluuttisesti numeerisin arvoin. Toisin sanoen DiD estimaatilla voidaan melko tarkasti mallintaa, mikä intervention vaikutus toimenpiteeseen on ollut. Kausaalisen vaikutuksen ja saavutetun hyödyn arvioimiseksi on kuitenkin huomionarvoista, että intervention suhteellisesta vaikutuksesta ne eivät itsessään kerro mitään. Suhteellisten muutosten selvittämiseksi aineistoa on tarkasteltava perinteisen prosenttilaskennan menetelmin kontrolli- ja tutkimusryhmien välillä.

Kampanjassa A DiD estimaatti kertoo intervention kausaalisen vaikutuksen klikkien keskimäärään olleen negatiivinen. Tarkempi tarkastelu kuitenkin kertoo, että kontrolliryhmässä keskimääräinen klikkien määrä on laskenut neljänneksen (24,45 %) ja tutkimusryhmässä alle viidesosan (17,91 %). Voidaan siis arvioida, että intervention vuoksi tutkimusryhmän keskimääräinen klikkien määrä on laskenut suhteellisesti vähemmän kuin ilman interventiota. Tavoitemittarin, klikin hinnan, osalta samaa tarkastelua noudattaen voidaan todeta kontrolliryhmän klikin hinnan nousseen lähes viidenneksen (18,51 %) ja

tutkimusryhmässä tarkalleen neljänneksen (25 %). Muutosten suhteellisen tarkastelun mukaan vaikutus olisi ollut negatiivinen. On kuitenkin huomionarvoista, että tutkimusryhmän klikin hinta on pysynyt kontrolliryhmän lähtötasoa alaisempana.

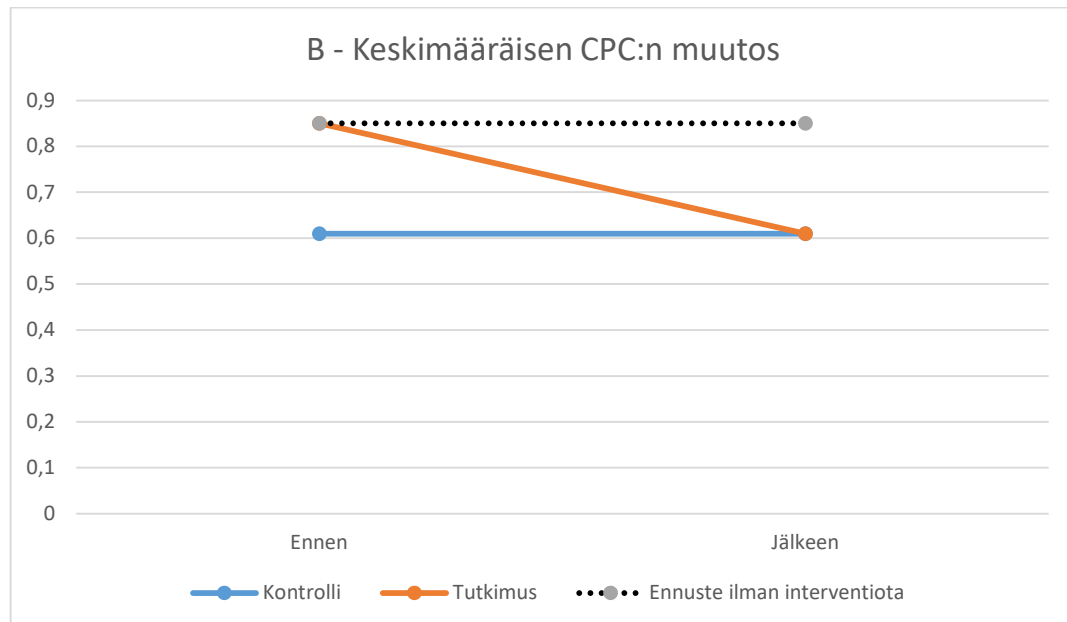
Vastaavasti kampanjan B suhteellisia muutoksia tarkasteltaessa voidaan todeta keskimääräisen klikkien määrän kontrolliryhmässä laskeneen noin 15 prosenttia (14,82 %) ja tutkimusryhmässä nousseen 83 prosenttia (83,07 %). Keskimääräisessä klikin hinnassa ei kontrolliryhmässä tapahtunut muutosta, tutkimusryhmässä se on laskenut lähes 30 prosentilla (28,24 %). Algoritmisen työkalun voidaankin todeta tämän kampanjan osalta tuoneen merkittävää hyötyä mainoskampanjan suoriutumislle keskimääräisellä CPC:llä mitattuna.

Tutkimusmetodilla saavutettujen tulosten visualisointi auttaa ymmärtämään intervention kausaalista vaikutusta ja DiD estimaattia. Kuvioissa 2 ja 3 ilmenee kampanjakohtaisesti toteuma ja tutkimusryhmän ennustettu toteuma ilman interventiota tutkimuksen alla olevan työkalun kannalta oleellimmista mittareista, klikinhinnan, osalta. Kuten taulukosta 2 ilmenee, DiD-mallin mukaan interventiolla ei pystytty osoittamaan kausaalista vaikutusta kampanjassa A. Siksi kuviossa 2 ennuste noudattaa tutkimusryhmän kanssa samaa kuvaajasuoraa.



Kuvio 2: Kampanja A - Keskimääräisen CPC:n muutos ja ennuste ilman interventiota

Kuviossa 3 ilmenee tutkimusmetodin mukaisesti ennuste toteumasta ilman interventiota kampanjalle B. Koska ainoa muuttuja ryhmien välillä oli algoritmisen työkalun, voidaan tutkimusryhmän ilman työkalua ennustaa noudattavan samaa kehityskulkua kuin kontrolliryhmä. Tässä tapauksessa DiD estimaatti ja ryhmien vaihteluväli tarkastelujaksoilla muodostuivat yhtä suureksi.



Kuvio 3: Kampanja B - Keskimääräisen CPC:n muutos ja ennuste ilman interventiota

7 Johtopäätökset

Ohjelmallinen ostaminen on merkittävässä asemassa digitaalisessa markkinointiviestinnässä. Sen kautta ostettu mainonta on kasvattanut osuuttaan mainostajien mediapanostuksista koko 2010-luvun ja kasvu tulee jatkumaan 2020-luvulla. Ohjelmallisen ostamisen rahamääräisiä osuuksia koko mediaostamisesta kuvaavat katsaukset sisältävät usein vain mainostilasta maksetut summat, eivätkä ota huomioon alan toimijoiden panostuksia teknologioiden ja prosessien kehitykseen. Nämä tekijät huomioiden voidaan todeta ohjelmallisen ostamisen merkityksen ja rahallisen koon olevan suurempi, kuin yksittäinen tutkimus antaa olettaa. Yhtä lailla algoritmien merkitys ohjelmallisessa ostamisessa on huomattava, sillä mainonnanhallinnan järjestelmät itsessään hyödyntävät sisään rakennettuja algoritmeja monimuotoisesti kampanjoiden tavoitteiden täyttämiseksi. Näitä voidaan tehostaa ulkoisilla algoritmisilla työkaluilla, kuten Optimizer. Algoritmien hyödyntäminen ei rajoitu pelkästään ostavien tahojen puolelle, vaan myös julkaisijat hyödyntävät algoritmeja mainosten sijoitteluun verkostoissaan parempien kampanjatulosten ja suurempien tulovirtojen tuottamiseksi. Toimijat, kuten RADLY Oy, puskevat ohjelmallisen ostamisen prosesseja kohti automatisoidumpaa ympäristöä mahdollistaen suuremman ajallisen panostuksen digitaalisen markkinoinnin strategioiden suunnitteluun.

Opinnäytetyön tutkimuksen perusteella voidaan todeta, että algoritmisella optimointityökalulla voidaan saavuttaa kampanjan tavoitteiden kannalta positiivisia

vaikutuksia. Vaikutusten absoluuttinen mittaaminen on kuitenkin ongelmallista, mahdollisesti jopa vääristävää, ja vaatii rinnalleen syvempää tarkastelua esimerkiksi muutosten kokoluokasta suhteutettuna tutkittavien ryhmien välillä. Suhteellisten muutosten valossa tutkimuksessa oli havaittavissa algoritmisen työkalun mahdollisuus parantaa kampanjan tuloksia, jossain määrin jopa huomattavastikin. Kampanjoiden ryhmäkohtaisien line itemien kulutuksen muutoksista voidaan päätellä, ettei tutkittu optimointityökalu allokoisi budjettia aggressiivisesti pelkästään parhaiten toimivalle line itemille, vaan jakaa sitä melko tasaisesti. Yhtenä tulevaisuuden tutkimiskohteena voisikin olla työkalun vaikutukset aggressiivisemmalla budjetin optimoinnilla. Ohjelmallisen ostamisen kontekstissa on myös todettava, ettei tutkimustulokset ole suoraan toistettavissa, vaan jokainen kampanja ja line item ovat yksilöllisiä. Yksilöllisyys voi tarkoittaa esimerkiksi valittuja inventaareja, kohdennuksia ja mainostajan sesonkivaihteluja. Optimointityökalun kannalta tämä tarkoittaa yksilöllisiä vaikutuksia yksilöllisille kampanjoille. Toisin sanoen, Optimizer toimii aina tapauskohtaisesti algoritmista prosessia noudattaen, eikä yksittäisen kampanjan tulokset välttämättä ole tarkasti toistettavissa. Tässä opinnäytetyössä toteutetun tutkimuksen luotettavuutta tarkasteltaessa ei tutkimuksen voida todeta olevan edellä mainittujen tekijöiden ulottumattomissa. Kontrolli- ja tutkimusryhmät ovat luotu tutkimusmetodia palveleviksi ja pyritty rauhoittamaan merkittävilta manuaalisilta muutoksilta. Todellisuudessa manuaalisten muutosten täysi poissulkeminen osoittautuu usein hankalaksi kampanjoiden yksilöllisyyden ja mainosverkostojen muutosten vuoksi. Järjestelmät toteuttavat niille määriteltyjä asetuksia ja kampanjan luoja ei niitä määrittellessään voi tietää mainosverkostojen sen hetkistä tilannetta läpikotaisin, joka usein pakottaa jonkin asteisiin muutoksiin kampanjan toteuttamiseksi. Yhteenvedona tutkimuksen on todettava olevan tapauskohtainen ja vaikutusten yksilöllisiä, eikä tutkimuksessa havaittuja hyötyjä välttämättä pystytä toisintamaan muiden ohjelmallisesti ostettujen kampanjoiden kohdalla.

Difference in differences -menetelmä on algoritmisen työkalun kausaalisten vaikutusten mittaamiseen relevantti. Sitä hyödyntäessä on kuitenkin otettava huomioon, että sen tuottamat tulokset ovat absoluuttisia, eivätkä kerro muutosten suhteellisesta suuruusluokasta. Menetelmää hyödyntävän tutkijan on hyvä ymmärtää tutkittavan aiheen luonnetta ja muuttujia kestävien kontrolli- ja tutkimusryhmien luomiseksi, regressioanalyysin tarpeellisuuden arvioimiseksi ja lopulta luotettavan tutkimuksen tuottamiseksi. Tutkimusmetodin tulosten luotettavuus nojaa vahvasti kontrolli- ja tutkimusryhmien vertailukelpoisuuteen, siksi mittausasettelussa tulee olla huolellinen. Ohjelmallisen ostamisen kontekstissa tämä tarkoittaa ryhmien sisältämien line itemien vertailukelpoisuutta ja tutkimusta vääristävien tekijöiden poissulkemista. Mittausasettelun kannalta kampanjan rakentamisessa on otettava huomioon esimerkiksi kohdennusten ja inventaarien eroavaisuudet. Tulosten luotettavuutta vaarantaa yhtä lailla line item -asetusten muokkaus kesken mittausjakson. Ohjelmalliseen ostamiseen käytettyjen algoritmisten työkalujen

jatkotutkimuksissa syvemmän ymmärryksen tuottamiseksi voisikin olla hyödyllistä hyödyntää tutkimusmetodia lisättynä monimuuttujamenetelmällä ja regressioanalyysillä.

Lähteet

Painetut

Ensimmäinen painettu lähde

Sähköiset

Aarki. 2020. Differentiating between open auction, private auction & preferred deal in programmatic advertising. Viitattu 10.11.2020.

<https://www.aarki.com/blog/differentiating-between-open-auction-private-auction-preferred-deal-in-programmatic-advertising>

Ad Exchanger. 2012. Define It - What is an algorithm? Viitattu 21.9.2020.

<https://www.adexchanger.com/online-advertising/algorithm/>

Alma Media. 2020. Alma on siirtynyt first price -huutokauppamalliin ohjelmallisessa mainonnassa. Viitattu 24.11.2020.

<https://www.almamedia.fi/mainostajat/mainonnan-ostaminen/ohjelmallinen-ostaminen/blogi/alma-on-siirtynyt-first-price--huutokauppamalliin-ohjelmallisessa-mainonnassa>

Display & Video Help. 2020. Automatic budget allocation. Viitattu 23.9.2020.

https://support.google.com/displayvideo/answer/2956568?hl=en&ref_topic=3094997

Facebook for business. 2020. About campaign budget optimization. Viitattu 10.11.2020

<https://www.facebook.com/business/help/153514848493595?id=561906377587030>

Fredriksson, A. & Magalhaes de Oliveira. 2019. Impact evaluation using Difference-in-Differences. Viitattu 13.11.2020.

<https://www.emerald.com/insight/content/doi/10.1108/RAUSP-05-2019-0112/full/pdf?title=impact-evaluation-using-difference-in-differences>

IAB. 2017. Ohjelmallisen ostamisen opas. Viitattu 10.9.2020.

<https://www.iab.fi/media/pdf-tiedostot/standardit-ja-opaat/ohjelmallisen-ostamisen-opas-2017.pdf>

IAB. 2019. Ohjelmallisen kasvu jatkuu Suomessa. Viitattu 10.9.2020.

<https://www.iab.fi/uutiset-blogi/uutiset-ja-tiedotteet/ohjelmallisen-kasvu-jatkuu-suomessa.html>

Järvinen, J. 2016. The use of digital analytics for measuring and optimizing digital marketing performance. Viitattu 23.10.2020.

https://jyx.jyu.fi/bitstream/handle/123456789/51512/978-951-39-6777-2_vaitos21102016.pdf?sequence=1&isAllowed=y

Katsov, I. 2018. Introduction to algorithmic marketing. Viitattu 10.11.2020.

<https://algorithmicweb.files.wordpress.com/2018/07/algorithmic-marketing-ai-for-marketing-operations-r1-7g.pdf>

Kauppalehti. 2020. Yrityshaku. Viitattu 18.11.2020.

<https://www.kauppalehti.fi/yritykset/yritys/radly+oy/29970131#registrations>

Match2One. 2020. What is programmatic advertising? The Ultimate 2020 guide. Viitattu 23.11.2020.

<https://www.match2one.com/blog/what-is-programmatic-advertising/>

Merisavo, M. 2008. The interaction between digital marketing communication and customer loyalty. Viitattu 9.11.2020.

<http://epub.lib.aalto.fi/pdf/diss/a333.pdf>

Sanoma Media Finland. 2020. Sanoma siirtyy ohjelmallisessa mainonnassa First Price - hinnoittelumalliin. Viitattu 24.11.2020.

<https://media.sanoma.fi/ajankohtaista/2020-03-30-sanoma-siirtyy-ohjelmallisessa-mainonnassa-first-price-hinnoittelumalliin>

Siltanen, S. 2018. Algoritmi toimii kuin anopin kakkuresepti - miksi se sitten pelottaa niin paljon? YLE. Viitattu 23.10.2020.

<https://yle.fi/aihe/artikkeli/2018/06/08/algoritmi-toimii-kuin-anopin-kakkuresepti-miksi-se-sitten-pelottaa-niin-paljon>

Toivonen, J. 2018. Algoritmit mullistavat verkkokaupan - ne tietävät jo nyt mitä juuri sinä aiot ostaa ensi viikolla. YLE. Viitattu 23.10.2020.

<https://yle.fi/uutiset/3-10097475>

Zenith. 2018. 65% of digital media to be programmatic in 2019. Viitattu 10.9.2020

<https://www.zenithmedia.com/65-of-digital-media-to-be-programmatic-in-2019/>

IAB 2020. Ohjelmallisen ostamisen opas. Viitattu 9.11.2020.

<https://www.iab.fi/opaat-suositukset/opaat/ohjelmallisen-ostamisen-opas-102020.html>

Julkaisemattomat

Radly. 2020. Radly Optimizer. Viitattu 19.11.2020.

Kaavat

Kaava 1: DiD estimaatti.....	19
------------------------------	----

Kuvat

Kuva 1: Ohjelmallisen ostamisen ekosysteemi (Match2One, 2020).....	13
Kuva 2: Kuvaus DiD estimaatista kaksiryhmäisessä tapauksessa vertailuajanjaksoilla (Fredriksson & Magälhaes de Oliveira 2019, 522).	20

Kuviot

Kuvio 1: DSP kampanjahierarkia.....	11
Kuvio 2: Kampanja A - Keskimääräisen CPC:n muutos ja ennuste ilman interventiota.....	26
Kuvio 3: Kampanja B - Keskimääräisen CPC:n muutos ja ennuste ilman interventiota.....	27

Taulukot

Taulukko 1: Kampanja A - kontrolliryhmä vertailujaksolla	22
Taulukko 2: Kampanja A - kontrolliryhmä optimointijaksolla	22
Taulukko 3: Kampanja A - tutkimusryhmä vertailujaksolla.....	23
Taulukko 4: Kampanja A - tutkimusryhmä optimointijaksolla.....	23
Taulukko 5: Kampanja B - kontrolliryhmä vertailujaksolla	23
Taulukko 6: Kampanja B - kontrolliryhmä optimointijaksolla	23
Taulukko 7: B - tutkimusryhmä vertailujaksolla.....	24
Taulukko 8: Kampanja B - tutkimusryhmä optimointijaksolla.....	24
Taulukko 9: Kampanjan A mallinnetut tulokset	25
Taulukko 10: Kampanjan B mallinnetut tulokset.....	25