

Enni Lähde

**MASSADATAN JA MASSADATA-ANALYTIIKAN
HYÖDYNTÄMINEN VERKKOKAUPOISSA:
LIIKETOIMINNALLINEN NÄKÖKULMA**



JYVÄSKYLÄN YLIOPISTO
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA
2021

TIIVISTELMÄ

Lähde, Enni

Massadatan ja massadata-analytiikan hyödyntäminen verkkokaupoissa:
liiketoiminnallinen näkökulma

Jyväskylä: Jyväskylän yliopisto, 2021, 30 s.

Tietojärjestelmätiede, Kandidaatintutkielma

Ohjaaja(t): Kokko, Tuomas

Tässä kandidaatintutkielmassa tarkastellaan massadatan (engl. big data) ja massadata-analytiikan hyödyntämistä verkkokaupoissa liiketoiminnallisesta näkökulmasta. Datan ja erityisesti massadatan määrä kasvaa vuosi vuodelta ja se tarjoaakin verkkokaupoille mahdollisuuksia hyödyntää sitä monilla eri tavoin. Massadatan kasvun ohella myös verkkokauppojen suosio on kasvanut ja kilpailu on koventunut. Asiakkaat ovat myös entistä tarkempia verkkokauppaa valitessa. Tässä tutkielmassa syvennytäänkin siihen millaisia mahdollisuuksia massadata ja massadata-analytiikka tarjoaa verkkokaupoille ja kuinka niiden avulla voidaan kasvattaa liiketoimintaa. Työssä määritellään termit massadata, massadata-analytiikka ja verkkokauppa, jonka jälkeen vastataan tutkimuksessa esitettyihin tutkimuskysymyksiin ”Kuinka massadataa ja massadata-analytiikkaa voidaan hyödyntää verkkokaupoissa?” ja ”Mitä hyötyä massadatan ja massadata-analytiikan käyttäminen tarjoaa verkkokaupoille?”. Tutkielman keskeinen tulos on, että massadatan ja massadata-analyysin tarjoamat mahdollisuudet ulottuvat monelle osa-alueelle, jotka jaetaan tässä tutkielmassa kuuteen osa-alueeseen: personointiin, dynaamiseen hinnoitteluun, asiakaspalveluun, toimitusketjuun, turvallisuuteen ja ennustaviin analyttikoihin. Kirjallisuuden perusteella voidaan huomata, että massadataa hyödyntämällä verkkokaupat voivat esimerkiksi optimoida resursseja tehokkaammin, parantaa myyntiä ja voittoa, rakentaa uskollisuutta asiakkaitansa kohtaan ja viestiä sidosryhmien kanssa monikanavaisesti.

Asiasanat: massadata, data-analytiikka, verkkokauppa, digitaalinen liiketoiminta

ABSTRACT

Lähde, Enni

Utilizing big data and big data analytics possibilities in e-commerce: business perspective

Jyväskylä: University of Jyväskylä, 2021, 30 pp.

Information Systems, Bachelor's thesis

Supervisor(s): Kokko, Tuomas

This bachelor's thesis examines the utilization of big data and big data analytics in e-commerce from a business perspective. The amount of data and big data is growing year by year and that offers e-commerce the opportunity to take advantage of it in many different aspects. At the same time with the big data growing, the popularity of online shopping has also increased, and competition has intensified. Customers are also more specific when choosing an online store. This Bachelor's thesis delves into the opportunities of big data and big data analytics offer for e-commerce and how those things can be used to make a growth in business. This work defines the terms big data, big data analytics and e-commerce. After that the research questions "How can big data and big data analytics be utilized in e-commerce?" and "What are the key benefits of using big data and big data analytics in e-commerce?" are answered. The key findings of the thesis are that the possibilities offered by big data and big data analysis extend to many areas, which in this work are divided into six areas: personalization, dynamic pricing, customer service, supply chain, security, and predictive analysis. Based on the literature, by leveraging mass data, e-commerce's can, for example, optimize resources more efficiently, improve sales and profits, build loyalty to their customers, and communicate with stakeholders in multiple channels.

Keywords: big data, big data analytics, e-commerce

KUVIOT

Kuva 1. Massadatan 5V-malli	10
Kuva 2. Massadata-analytiikan arvoketju.....	11

SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT JA TAULUKOT

1	JOHDANTO.....	6
2	MASSADATA JA MASSADATA-ANALYTIikka	8
2.1	Massadatan määrittely ja sen ominaispiirteet	8
2.1.1	V-mallit	9
2.2	Massadata-analytiikan arvoketju	10
2.2.1	Massadatan muodostuminen ja kerääminen	11
2.2.2	Massadatan säilöminen ja analysointi.....	12
3	VERKKOKAUPPA.....	14
3.1	Verkkokaupan määrittely ja sen ominaispiirteet	14
3.2	Verkkokaupan käytettävyys	15
3.3	Verkkokaupoissa käytetty massadata	16
4	MASSADATAN JA MASSADATA-ANALYTIIKAN HYÖDYNTÄMINEN VERKKOKAUPPOISSA	18
4.1	Personointi ja suosittelujärjestelmät.....	18
4.2	Dynaaminen hinnoittelu.....	20
4.3	Asiakaspalvelu	20
4.4	Toimitusketju ja sen läpinäkyvyys.....	22
4.5	Turvallisuus ja petoksien havainnointi	23
4.6	Ennustavat analytiikat	24
5	YHTEENVETO JA POHDINTA	25
	LÄHTEET	27

1 JOHDANTO

Datalle ja erityisesti massadatalle (*engl. big data*) on annettu viime vuosina merkittäviä tunnustuksia. Arvostettu englantilainen talouslehti *The Economist* julisti vuonna 2017 datan syrjäyttäneen öljyn maailman arvokkaimpana resursina (*The Economist*, 2017). McKinsey arvioi vuonna 2011, että massadatasta tulee merkittävä tekijä kilpailukentässä (Manyika ym., 2011). Itseohjautuvien (eli datalla toimivien) autojen on arvioitu vähentävän kasvihuonepäästöjä parhaimmillaan jopa 60 % (Igliński & Babiak, 2017). Massadatan määritelmä ei kuitenkaan ole sen merkittävydestä huolimatta yksiselitteinen, vaan sille on luotu eri tutkijoiden toimesta erilaisia määritelmiä. Massadatalle on kuitenkin keskeistä se, että jotta siitä saadaan sen potentiaalinen arvo irti, täytyy sitä analysoida massadata-analytiikalla (Gandomi & Haider, 2015).

Samaan aikaan kun massadata on saanut osakseen suurta huomiota, on myös verkkokauppojen suosio kasvanut merkittävästi. Postin teettämässä Suuri verkkokauppatutkimus 2020- tutkimuksessa arvioitiin, että jo lähes 60 % suomalaisista tekee verkkokauppaostoksia kuukausittain. Lisäksi covid-19-pandemia kasvatti suomalaisten verkko-ostamista lähes 30 prosentilla. (Posti, 2020.)

Verkkokaupat ovat eräs keskeisimpiä massadata-analytiikan hyödyntäjiä joihin tuen verkkokauppojen tiukasta kilpailutilanteesta ja tarpeesta pysyä pelissä mukana (Akter & Wamba, 2016). Toisaalta massadatan ja massadata-analytiikan on myös todettu lisäävän esimerkiksi tuottavuutta. McAfee, Brynjolfsson, Davenport, Patil ja Barton arvioivat (2012) ovat arvioineet, että massadata-analytiikan hyödyntäminen lisää tuottavuutta 5–6 % verrattuna kilpailijoihin.

Niin massadatasta, kuin verkkokaupoistakin on tehty erillään lukuisia tutkimuksia. Tästä huolimatta massadatan hyödyntämisestä verkkokaupoissa tehty tutkimus keskittyy vielä suurilta osin tekniseen näkökulmaan. Tämä kirjallisuuskatsauksena toteutettu kandidaatintutkielma tarkoituksena on tarkastella massadatan ja massadata-analytiikan hyödyntämistä verkkokaupoissa liiketoiminnallisesta näkökulmasta. Tutkielman tarkoituksena on tarjota kattava kokonaiskuva mitä erilaisia mahdollisuuksia massadatalle on verkkokaupoille ja toisaalta minkälaisia hyötyjä nämä mahdollisuudet tuovat. Tämän tutkielman kaksi tutkimuskysymystä ovatkin seuraavat:

- Kuinka massadataa ja massadata-analytiikkaa voidaan hyödyntää verkkokaupoissa?
- Mitä hyötyä massadatan ja massadata-analytiikan käyttäminen tarjoaa verkkokaupoille?

Tutkielmassa tarkastellaan tutkimuskysymyksiä erityisesti verkkokaupan omistan näkökulmasta, lisäksi tutkielma keskittyy ainoastaan kuluttajille suunnattuihin verkkokauppoihin (*engl. B2C tai business-to-consumer*). Tutkielmaan on tehty myös muita rajauksia. Tutkielmassa rajataan tarkastelun ulkopuolelle massadataan ja massadata-analytiikkaan liittyvien ongelmien ja haasteiden tarkempi käsittely. Lisäksi tutkielmassa käsiteltävä verkkokauppa keskittyy perinteiseen verkkokauppaan, eli mobiilikauppaa (*engl. m-commerce*) ei käsitellä tässä tutkielmassa tarkemmin. Tutkielmassa on päädytty käyttämään big datan suomenkielistä käännöstä eli massadataa, jotta sana olisi helpompi taivuttaa tutkielman muuhun kieleen sopivaksi.

Tässä kandidaatintutkielmassa on yhteensä viisi lukua, joista kolme lukua on sisältölukuja. Tutkielman ensimmäinen luku on johdanto, jonka tarkoituksena on johdatella lukija aiheeseen ja herättää hänen mielenkiintonsa aiheeseen. Toinen luku on tutkielman ensimmäinen sisältöluku ja tässä luvussa tutkitaan massadatan määritelmää, millaisia ominaisuuksia massadatalla on ja kuinka massadataa kerätään ja varastoidaan. Lisäksi toisessa luvussa perehdytään massadata-analytiikan arvoketjuun ja syvennyttään erityisesti ketjun viimeiseen vaiheeseen, eli massadata-analytiikkaan. Kolmas luku on tutkielman toinen sisältöluku. Tässä luvussa perehdytään tarkemmin verkkokaupan määritelmään, ominaisuuksiin ja liiketoimintamalleihin. Tässä luvussa pohditaan myös verkkokaupan käytettävyyttä ja sen merkitystä niin asiakkaalle, kuin verkkokaupoille. Tutkielman neljäs luku on viimeinen sisältöluku ja syvenyy tarkemmin tutkielman tutkimuskysymyksiin ja pyrkii vastaamaan niihin mahdollisimman kattavasti. Lisäksi neljäs luku yhdistää aikaisempien lukujen näkökulmat. Tutkielman viimeinen luku on yhteenveto. Yhteenvedossa lisäksi pohditaan mahdollisia jatkotutkimuskysymyksiä. Kaikissa luvuissa on pyritty esittelemään käsiteltäviä aiheita tieteellisen pohjan lisäksi myös konkreettisten esimerkkien kautta.

Tutkielmaan on kerätty lähdekirjallisuutta useista tietokannoista. Käytetyimmät tietokannat ovat olleet Google Scholar, JYKDOK ja IEEE. Hakutermeinä tutkielmaan on käytetty muun muassa seuraavia: "big data", "big data analytics", "big data analytics AND e-commerce", "e-commerce". Tutkielmaan on pyritty keräämään mahdollisimman korkeatasoisia lähteitä ja niiden laatu on pyritty aina varmistamaan julkaisufoorumi.fi -sivuston avulla.

2 MASSADATA JA MASSADATA-ANALYTIikka

Tässä ensimmäisessä sisältöluvussa syvennytään massadatan monipuoliseen käsitteeseen ja tarkastellaan sitä erityisesti V-mallien näkökulmasta. Lisäksi tässä luvussa syvennytään massadata-analytiikkaan ja massadata-analytiikan arvo-
ketjuun.

2.1 Massadatan määrittely ja sen ominaispiirteet

Massadatan suosio on noussut useiden vuosien ajan, mutta tarkkaa alkamisajan-
kohtaa sille on vaikea määrittää. Termi massadata otettiin kuitenkin laajasti käyt-
töön vuonna 2011 (Gandomi & Haider, 2015), jolloin voitaisiin myös nähdä,
että "big data"-ilmiö on alkanut (Salo, 2014). Tätä tukee myös Google Analytics,
josta on havaittavissa moninkertainen nousu termille "big data" vuodesta 2011
alkaen (Google, 2021).

Massadatalle ei ole yksiselitteistä tai vakiintunutta määritelmää. Määritel-
män lisäksi massadata on myös terminä on osittain kiistanalainen ja kaikki tutki-
jat eivät usko, että se on kovin pitkäikäinen. Esimerkiksi Davenport (2014) en-
nustaa massadatalle terminä hyvinkin lyhyttä elinkaarta hankalan määriteltä-
vyyden ja yleisen sekavuuden vuoksi. Vaikka massadata on määritelmänä ja ter-
minä kiistanalainen, niin sille on eri tutkijoiden toimesta kehitetty erilaisia mää-
ritelmiä ja tunnusmerkkejä. Manyika, Chui, Brown, Bughin, Dobbs, Roxburgh ja
Byers (2011) määrittelevät massadatan siten, että massadata on tietomäärää, joka
ylittää tekniikan kyvyn tallentaa, hallita ja käsitellä sitä tehokkaasti tavanomai-
silla tietokantatyökaluilla. Simon (2013) taas määrittelee massadatan olevan suu-
ria määriä strukturoimatonta dataa. Johnson (2012) ja Davenport (2012) keskitty-
vät määritelmässään datalähteiden monimuotoisuuteen. Yksinkertaisesti voi-
daankin määritellä, että massadata tarkoittaa suuria datamassoja, joita voidaan
hyödyntää erilaisilla datanhallintatyövälineillä.

2.1.1 V-mallit

Tiedepiireissä ehkä käytetyin viitekehys massadatalle on kuitenkin Doug Laine'n vuonna 2001 esittelemä 3V-malli, jossa massadatalle toistuu kolme ominaisuutta: volyymi (*engl. volume*), vaihtelevuus (*engl. variety*), ja vauhti (*engl. velocity*) (Salo, 2014).

3V-mallin ominaisuus volyymi viittaa datan suureen määrään ja onkin yksi massadatan ominaisimpia tuntomerkkejä (Salo, 2014). Koko on myös monesti ainoa ja merkittävin massadatan liitettävä ominaisuus (Gandomi & Haider, 2015). Massadatan voidaan mitata terabiteissa ja petaluvuissa. McAfee ym. (2012) arvioivat vuonna 2012, että suuri amerikkalainen päivittäistavaraketju Walmart keräsi dataa asiakkaidensa ostotapahtumista jopa 2.5 petatavua joka tunti. Massadatalle onkin oleellista se, että sitä kertyy koko ajan kiihtyvällä vauhdilla lisää.

Vaihtelevuus viittaa datan laatuun ja monimuotoisuuteen. Massadata voi olla strukturoitua, semi-strukturoitua ja strukturoimatonta (Salo, 2014). Strukturoitu data tarkoittaa tunnistettua ja helposti lajiteltavaa dataa, kun taas strukturoimaton data on satunnaista ja vaikeasti analysoitavaa (Sagiroglu & Sinanc, 2013). Strukturoidun datan voidaan kuvitella olevan dataa, jota tietokone kykenee käsittelemään suoraan, kun taas strukturoimattoman datan käsittelyyn tarvitaan joko ihmislogiikkaa tai kehittynyttä tekoälyä. Semi-strukturoitu data on jotakin edellä mainittujen väliltä, esimerkiksi metatiedoilla varustettu strukturoimaton data luokitellaan semi-strukturoiduksi dataksi (Salo, 2014). Semi-strukturoitua dataa voisi olla Salon (2014) esimerkin mukaan videokuvaa, jossa metatiedoissa kerrotaan milloin se on kuvattu ja missä se on kuvattu.

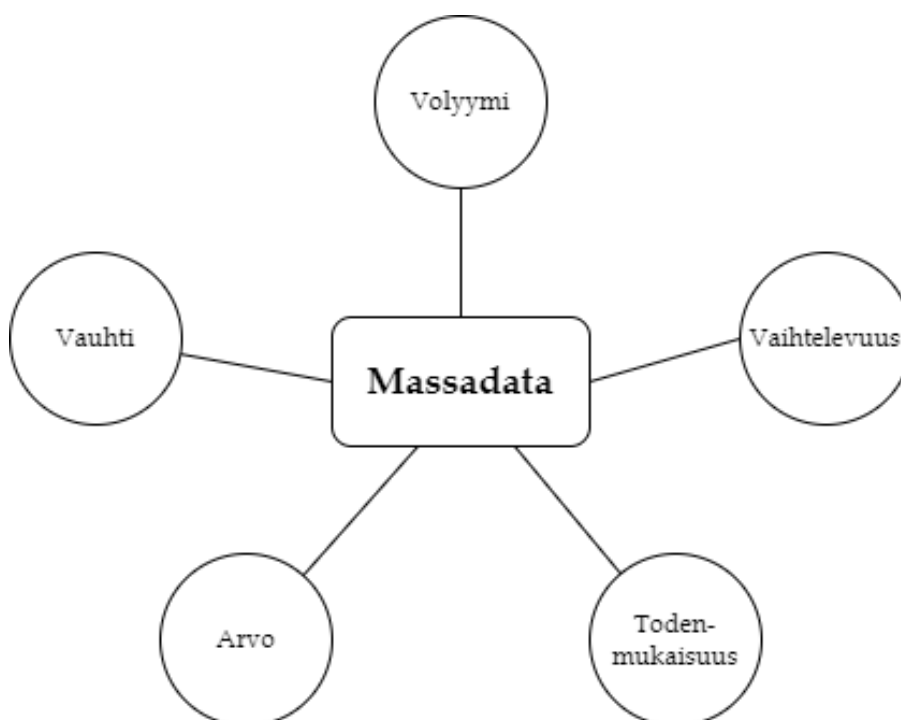
Massadatan osa datasta on strukturoitua, mutta ylivoimaisesti suurin osa on strukturoimatonta (Salo, 2014). Davenport (2014) arvioi, että ainoastaan 25 % datamäärästä on hyödyllistä. Tämän vuoksi datan moninaisuus on piirre, joka aiheuttaa paljon haasteita, sillä sen analysoiminen ja arvon saaminen aiheuttavat paljon työtä.

Vauhti viittaa datan kertymisen nopeuteen ja paineeseen reagoida uuteen dataan nopeasti, erityisesti liiketoiminnassa (Salo, 2014). Datana nopea käsittely nopeuttaa esimerkiksi päätöksentekoa ja sitä tulisi pystyä analysoimaan mahdollisimman nopeasti, jotta sillä olisi taloudellista arvoa (Chen, Mao & Liu, 2014).

3V-mallin rinnalle on myös kehittynyt myöhemmin 4V- ja 5V-malleja (Akter & Wamba, 2016). Chen ym. (2014) lisäävät neljänneksi "V":ksi arvon. Arvo (*engl. value*) viittaa massadatan tuottamaan arvoon ja sen tarjoamiin transaktionaalisiin, strategisiin ja informaationaalisiin etuihin (Akter & Wamba, 2016). Tämä määritelmä korostaakin sitä, mikä massadatassa on oleellista, eli sen tarjoama liiketoiminnallinen hyöty. Gandomi & Haider lisäävät myös viidennen "V":n, todenmukaisuuden (*engl. veracity*). Todenmukaisuus viittaa datalähteiden luotettavuuteen. Koska massadatan kerätään paljon ja sitä kertyy erilaisista lähteistä, kuten mahdollisesti epäluotettavista sensoreista, niin sen uskottavuus ja luotettavuus vaihtelee.

Davenport (2014) on kritisoinut 3V-mallia ja siitä kehittyneitä 4V- ja 5V-malleja. Hän kyseenalaistaa, mitä tapahtuu, kun data täyttää ainoastaan esimerkiksi kaksi vaatimusta kolmesta 3V:stä, onko tällöin data myös vain osittain

massadataa. Kriittistä huolimatta 3V-mallia ja siitä kehittyneitä V-malleja on käytetty määrittelemään massadataa useissa tieteellisissä teoksissa, esimerkiksi tähän tutkielmaan käytetyissä lähdeoteoksissa on monissa käytetty jotakin V-mallia. De Mauro, Greco ja Grimaldi (2016) ehdottavatkin, että massadata määritellään V-malliin pohjautuen seuraavasti: massadata on tietoresurssi, jolle on ominaista niin suuri volyyymi, vauhti ja vaihtelevuus, että se vaatii erityistä teknologiaa ja analyysia, jotta siitä saadaan irti sen potentiaalinen arvo (De Mauro ym., 2016).




Kuva 1. Massadatan 5V-malli

2.2 Massadata-analytiikan arvoketju

Massadatalle on ominaista se, että se on itsessään suhteellisen arvotonta määräänsä nähden, mutta analysoinnin kautta siitä voidaan erotella arvokasta tietoa (Gandomi & Haider, 2015). Tämän vuoksi Gandomi & Haider (2015) ovat määritelleet, että jotta massadatatista saadaan sen todellinen hyöty irti, niin siitä on saatava analysoinnin avulla irti päätöksenteon kannalta oleellinen data. Massadatan analysoinnissa on tarkoituksena löytää uutta informaatiota (Anagnostopoulos, Zeadally & Exposito, 2016).

Massadata-analytiikan arvoketju (*engl. big data value chain*) on nelivaiheinen prosessi, jonka päämääränä on erotella datasta yritykselle oleellinen informaatio ja arvo. Tämä massadata-analytiikan arvoketjun prosessi jakautuu datan

muodostumiseen, keräämiseen, säilömiseen ja analysointiin. (Hu, Wen, Chua & Li, 2014.) Seuraavaksi tarkastellaan hieman syvemmin näitä vaihteita.



Kuva 2. Massadata-analytiikan arvoketju. Mukailten Hu ym. (2014).

2.2.1 Massadatan muodostuminen ja kerääminen

Massadata-analytiikan arvoketjun ensimmäinen vaihe on massadatan muodostuminen. Massadata on pitkälti suuria, monimuotoisia ja monimutkaisia aineistoja, jotka muodostuvat erilaisten tiedostolähteiden kautta. Datan määrän kasvua selittää osittain teknologiset innovaatiot. Erityisesti internet ja sosiaalisen median palvelut, kuten esimerkiksi Facebook ja Twitter, tuottavat suuren määrän dataa nykyään. Massadataa muodostuukin niin sisäisistä, kuin ulkoisista lähteistä (Faroukhi, El Alaoui, Gahi & Amine, 2020). Ulkoiset lähteet voivat olla esimerkiksi käyttäjäsyötteet, videot ja viestit.

Massadata-analytiikan toinen vaihe on kerääminen. Kerääminen on prosessi, jossa muutetaan tosielämän objekteista dataa raaka dataksi (Hu ym. 2015). Dataa voidaan kerätä monenlaisilta toimijoilta riippuen käyttötarkoituksesta, esimerkiksi asiakkailta, kansalaisilta ja poliitikoilta (Anagnostopoulos ym., 2016). Verkkokaupoissa dataa kerätään tyypillisesti asiakkailta ja selailijoilta. Massadataa voidaan kerätä monella eri tavalla ja nämä tavat riippuvat esimerkiksi massadata-analyysistä ja datalähteestä (Hu ym., 2014). Datan kerääminen on kriittinen vaihe massadatatessa ja se edellyttää tarkkaa huolellisuutta, sillä epätoimen datan kerääminen saattaisi vaikuttaa data-analyysiin ja tätä kautta lopullisiin tuloksiin epäsuotuisasti (Hu ym., 2014).

Massadataa voidaan kerätä monenlaisilla menetelmillä ja tutkimuksissa onkin nostettu ra'an datan keräämiselle monenlaisia erilaisia menetelmiä. Hu ym. (2014) nostavat esiin kolme keskeistä datan keräystapaa: sensorit, lokitiedostot ja hakurobotit (*engl. web crawler*).

Sensorit muuttavat fyysiset ominaisuudet sellaisiksi, että niitä voidaan tallentaa ja käsitellä myöhemmin digitaalisesti (Chen ym., 2014). Sensoreista mitattu data kerätään digitaalseksi joko langallisesti tai langattomasti ja se voidaan luokitella esimerkiksi ääniaaltoihin, ääneen, tärinään, paineeseen, säähän jne. (Chen ym., 2014). Esimerkkinä sensoripohjaisesta mittaamistavasta Hu ym. (2014) nostavat radioteleskoopin, jota käytetään datan mittaamiseen erilaisten sensoreiden avulla. Esimerkiksi käyttäjien maantieteellistä dataa voidaan mitata mobiililaitteiden GPS-sensoreista.

Toinen menetelmä kerätä dataa on lokitiedostot. Lokitiedostot ovat eräs käytetyimmistä tavoista kerätä dataa (Hu ym., 2014). Lokitiedostot ovat hyvin suosittu ja yleinen datan keräämismetodi, sillä lähes kaikki nykyaikaiset mobiililaitteet käyttävät niitä (Chen ym., 2014). Lokitiedostot ovat tiedostoja, jotka

tietolähdejärjestelmät luovat automaattisesti ja joihin kerätään erilaista tietoa palvelimilta. Esimerkiksi verkkosivujen palvelimet tallentavat lokitiedostoihin verkkosivukäyntien määrän (Chen ym., 2014) ja klikkausdatan (Hu ym., 2014).

Viimeinen keräysmenetelmä on hakurobotit. Hakurobotit ovat tietokantaohjelmia, jotka keräävät suuria massoja dataa verkkosivuista ja niille tehdyistä hauista. Hakurobottien toiminta perustuu siihen, että ne keräävät web palvelimissa olevia verkkosivuja ja tallentaa niistä tiettyjä kenttiä tiedonhakua varten. (Hu ym., 2014.)

2.2.2 Massadatan säilöminen ja analysointi

Massadata-analytiikan arvoketjun kolmas vaihe on säilöminen. Massadatan säilömiseen tarvitaan massiivinen tallennusjärjestelmä, sillä säilömistä lisäksi järjestelmän täytyy kyetä edelleen lukemaan sinne säilöttyä ja tallennettua dataa. Hu ym. (2014) asettavat massadatan tallennusjärjestelmälle kaksi ehtoa, jotka tallennusjärjestelmän pitäisi täyttää: järjestelmän pitää tallentaa tiedot pysyvästi ja luotettavasti ja järjestelmän täytyy kyetä skaalautumaan suuren määrän kyselyihin ja analysointiin. Ohlhorst (2012) korostaa lisäksi tallennusjärjestelmän turvallisuuden tärkeyttä. Säilötty data voi olla arkaluontoista, kuten terveys- tai pankkiasiat, jonka vuoksi säilytysjärjestelmän turvallisuuteen pitää myös kiinnittää erityistä huomiota.

Massadata-analytiikan arvoketjun viimeinen ja Chen ym. (2014) mukaan myös tärkein vaihe on massadata-analytiikka (*engl. big data analytics* tai *BDA*). Massadata-analytiikka voidaan jakaa osiin eri ulottuvuuksiensa perusteella. Nämä ulottuvuudet ovat kuvaileva- (*engl. descriptive*), ennustava- (*engl. predictive*), tutkiva- (*engl. exploratory*) ja ohjaileva (*engl. prescriptive*) analyysi. (Rajaraman, 2016.)

Kuvaileva analyysi keskittyy vastaamaan kysymykseen mitä on tapahtunut aiemmin ja esittämään tämä helposti ymmärrettävässä muodossa. Historiallinen data kerätään helposti visualisoitavaksi esimerkiksi erilaisten taulukoiden avulla. Kuvailevaa analyysia on esimerkiksi maan väestön lisääminen pylväsdiagrammiin ominaisuuksien, kuten iän ja sukupuolijakauman perusteella. (Rajaraman, 2016.) Verkkokaupoissa kuvailevaan analyysiin voitaisiin koostaa esimerkiksi sen mukaan, mihin kaupunkeihin toimituksia on lähetetty.

Ennustava analyysi keskittyy siihen, mitä tulee tapahtumaan tulevaisuudessa. Verrattuna kuvailevaan analyysiin se siis tarkastelee tulevaisuutta historian sijaan. Ennustavassa analyysissä hyödynnetään staattista analyysia ja koneoppimista (*engl. machine learning*) mahdollisimman tarkasti, jotta lopputulos olisi mahdollisimman lähellä totuutta. Eräs merkittävä hyödyntämistapa ennustavalle analytiikalle on asiakkaiden ja trendien ennustaminen. Ennustaviin analytiikkoihin syvennytään tämän tutkielman neljännessä luvussa tarkemmin. (Rajaraman, 2016.)

Tutkivassa analyysissä pyritään löytämään yhteyksiä odottamattomien parametrien välillä. Esimerkiksi yritykset voivat analysoida asiakkaidensa käyttäytymistä, palautetta ja blogeja ja ennustaa näiden tietojen pohjalta aikooko asiakas esimerkiksi irtisanoa tilauksensa tai vaihtaa teleoperaattoria. Mikäli yhteyksiä

löydetään, niin yritys voi vielä yrittää saada muuttamaan asiakkaan mielen esimerkiksi tarjoamalla alennusta. (Rajaraman, 2016.)

Viimeinen ulottuvuus on ohjaileva analyysi. Ohjailevassa analyysissä tarjoaa mahdollisuuksia optimoida ratkaisuja olemassa oleviin ongelmiin. Toisin sanottuna ohjaileva analyysi kertoo mitä täytyy tehdä, jotta tavoitteet saavutetaan. Esimerkiksi eräs yleinen käyttötarkoitus on lentoyhtiöiden hintapolitiikka, jossa paikkojen hinta määräytyy historian, tulevien tapahtumien, lomien ym. mukaan, jotta yritys maksimoi voiton. (Rajaraman, 2016.)

3 VERKKOKAUPPA

Tässä sisältöluvussa syvennytään verkkokaupan määritelmään, siihen millaisia ominaispiirteitä sillä on ja mitkä tekijät vaikuttavat verkkokaupan käytettävyyteen. Luvussa esitellään verkkokaupalle erilaisia määritelmiä ja näkökulmia ja esitellään käytettävyyden merkitystä verkkokaupassa liiketoiminnan näkökulmasta. Lisäksi tässä luvussa eritellään tarkemmin minkä tyyppistä dataa verkkokaupoissa tyypillisesti käytetään.

3.1 Verkkokaupan määrittely ja sen ominaispiirteet

Verkkokauppa voidaan yksinkertaisesti määritellä tarkoittavan kaikkea sähköistä internetin välityksellä tapahtuvaa kaupankäyntiä, kuten pankkitoimintaa, sijoittamista ja vähittäiskauppaa (Niranjanamurthy, Kavyashree, Jagannath, & Chahar, 2013). Verkkokaupalle voidaan kuitenkin terminä nähdä olevan useita määritelmiä (Chaffey, 2007) massadatan tavoin.

Verkkokauppa saatetaan määritellä eri tavoin riippuen esimerkiksi kysyjästä, minkä vuoksi Kalakota ja Whinston (1997) ovatkin jakaneet verkkokaupan määrittelyn neljään näkökulmaan: Kommunikaatio-, liiketoimintaprosessi-, palvelu- ja onlinenäkökulmaan. Kommunikaation näkökulmasta tarkasteltaessa verkkokauppa on tiedon, tuotteiden, palveluiden tai maksujen levittämistä tietoverkkojen kautta. Liiketoimintaprosessin näkökulmasta tarkastellessa verkkokauppa on teknologian hyödyntämistä, jotta liiketapahtumat ja työnkulku saataisiin automatisoitua. Palvelun näkökulmasta verkkokaupan nähdään olevan työväline, jolla saadaan johdon näkökulmasta samaan aikaan niin leikattua kuluja, kuin parannettua tuotteiden tai palveluiden laatua ja lyhennettyä toimitusaikaa. Neljäs ja viimeinen näkökulma on onlinenäkökulma, jonka mukaan verkkokauppa tarjoaa mahdollisuuden tuotteiden ja palveluiden ostamiseen ja myymiseen verkon välityksellä. (Kalakota & Whinston, 1997.)

Myös Mourya ja Gupta (2014) mainitsevat samat neljä näkökulmaa, lisäksi he täydentävät vielä viidennen näkökulman - käyttöliittymänäkökulman.

Käyttöliittymänäkökulmasta verkkokauppa on alusta tiedon ja transaktioiden vaihtokaupalle. Transaktiot voivat tapahtua joko yhdellä tapahtumalla (esimerkiksi Amazon ja Expedia) tai ne voivat olla jatkuvia tapahtumia (esimerkiksi Netflix ja Spotify) (Akter ja Wamba, 2016). Lisäksi vaihtokauppoja voidaan jaotella eri tyyppeihin riippuen yrityksen toimialasta (Mourya & Gupta, 2014). Tärkeimpiä tyyppejä ovat yritysten välinen kauppa (*engl. business-to-business tai B2B*), yritysten ja kuluttajien välinen kauppa (*engl. business-to-consumers tai B2C*) ja kuluttajien välinen kauppa (*consumer-to-consumer tai C2C*) (Bigdoli, 2002). Yritysten välinen kauppa on kuluttajakauppaan verrattuna luonteeltaan pitkäaikaisia johtuen esimerkiksi siitä, että yritysten tarjoamat tuotteet ovat monimutkaisia. Tästä johtuen yrityskaupat tarvitsevat tyypillisesti syvempää konsultointia (Bigdoli, 2002). Yritysten välisessä kaupassa myös hinta on monesti neuvoteltavissa johtuen siitä, että yritysten välisissä kaupoissa merkitsee erityisesti kaupan koko (Manzoor, 2010). Lisäksi yrityskaupassa voi olla tuotteella tai palvelulla useampi osapuoli, kuten päättävä, ostaja ja käyttäjä (Manzoor, 2010).

Verkkokaupat tarjoavat lukuisia hyötyjä niin kuluttajille, yrityksille, kuin yhteiskunnallekin. Yrityksen näkökulmasta verkkokaupat tarjoavat esimerkiksi kansainvälisen kohdeyleisön, mahdollisuuden tarkkailla kuluttajien ostokäyttäytymistä ja halvemmat markkinointikeinot. Kuluttajalle verkkokaupat taas ovat esimerkiksi avoinna ympäri vuorokauden, niiden valikoima on kattavampi kuin kivijalkaliikkeiden ja kuluttajien on mahdollista tehdä hintavertailua verkossa. Toisaalta verkkokaupoilla on myös haittapuolia niin kuluttajille, kuin yrityksille. Esimerkiksi kaikkia tuotteita ei saa ostettua verkon kautta, verkkokaupoista puuttuu monesti henkilökohtainen kohtaaminen ja tietoturva saattaa aiheuttaa erinäisiä haasteita. (Mourya & Gupta, 2014.)

Verkkokaupan määrittelyssä on myös huomioitavaa, että verkkokaupat ja sähköinen liiketoiminta (*engl. electronic business tai e-business*) ovat kaksi eri asiaa, eikä näitä pidä sekoittaa toisiinsa. Kuten tämän luvun alussa mainittiin, niin verkkokauppaliiketoiminta on internetin välityksellä tapahtuvaa myymistä ja ostamista. Sähköinen liiketoiminta tarkoittaa kuitenkin mitä tahansa internetin välityksellä tapahtuvia transaktioita. Sähköinen liiketoiminta on siis isompi kokonaisuus, jonka yksi alalajeista on verkkokauppa. (Manzoor & Amir, 2010.) Sähköinen liiketoiminta kattaa kaikki yrityksen toiminnot, jotka tapahtuvat verkon yli. Sähköiseen liiketoimintaan lukeutuu siis myös yrityksen sisäiset prosessit, kuten työntekijöiden palvelut ja koulutus (Manzoor & Amir, 2010). Verkkokauppa ei siis ole edellytys sähköiselle liiketoiminnalle, vaan sähköistä liiketoimintaa voi olla myös esimerkiksi perinteisellä kivijalalla (Bigdoli, 2002).

3.2 Verkkokaupan käytettävyys

Verkkokaupoille on käytettävyyden merkitys erityisen tärkeää, sillä mikäli verkkokauppa ei toimi odotetusti, niin asiakkaat siirtyvät herkästi toiseen kauppaan (Nielsen & Loranger, 2006). Kuluttajat myös odottavat verkkokaupoilta koko ajan enemmän, jonka vuoksi he sietävät huonoja verkkokauppoja entistä

vähemmän (Nielsen & Loranger, 2006). Tutkittaessa miten asiakas kokee verkkokaupan, on tärkeää kiinnittää huomiota tekijöihin, jotka tekevät verkkokaupasta helposti lähestyttävän ja käytettävän. Nielsen (1994) on määritellyt, että verkkokaupan käytettävyyttä koostuu viidestä komponentista: opittavuudesta, tehokkuudesta, muistettavuudesta, virheistä ja tyytyväisyydestä.

Opittavuus tarkoittaa sitä, että järjestelmän täytyy olla helposti opittava, jotta sen käyttäjät pääsevät käyttämään sitä nopeammin. Opittavuutta voidaan mitata esimerkiksi ajalla. Mikäli verkkokauppasivusto on vaikeasti käytettävä, saattaa käyttäjä turhautua ja siirtyä toiseen verkkokauppaan. Tehokkuudella viitataan siihen, kuinka tehokkaasti järjestelmän käyttäjä pystyy käyttämään kyseistä järjestelmää opittuaan sen käytön. Muistettavuus tarkoittaa sitä, että järjestelmän pitäisi olla helposti muistettava, vaikka käyttäjä ei käyttäisi sitä hetkeen. Käyttäjän pitää siis pystyä palaamaan sivustolle helposti tauon jälkeen ilman, että järjestelmän käyttö täytyy opetella uudelleen. Järjestelmällä pitäisi olla myös mahdollisimman vähän virheitä. Tähän viitataan virheillä. Mikäli järjestelmällä kuitenkin ilmenee virheitä, niin sen täytyisi kyetä helposti palautumaan niistä. Kuitenkaan katastrofaalisia virheitä ei pitäisi päästä syntymään. Viimeinen komponentti tyytyväisyys viittaa siihen, että järjestelmän täytyy olla mukava käyttää, jotta sen käyttäjät ovat siihen tyytyväisiä. (Nielsen, 1994)

3.3 Verkkokaupoissa käytetty massadata

Verkkokaupat keräävät käyttäjiltään monen tyyppistä dataa. Tämä data voidaan jakaa yleisesti neljään kategoriaan: transaktioihin tai liiketoimintaan liittyvään dataan, dataan käyttäjän klikkauksista (*engl. clickstream data*), äänidataan ja videodataan. Dataa kerätään ajan myötä käyttäjien selauksien ja muiden tapahtumien avulla. (Akter & Wamba, 2016.)

Transaktioihin tai liiketoimintaan liittyvää dataa kerätään ajan mittaan yrityksen ja asiakkaan välisistä tapahtumista. Tämän tyyppinen strukturoitu data kertyy monista lähteistä, kuten ostoista, kanta-asiakkuusohjelmista ja asiakasprofiileista (Akter & Wamba, 2016). Keskeinen lähde datalle on nykyään käyttäjien tekemät klikkaukset verkkosivuilla. Tätä dataa kerätään monista eri lähteistä, kuten verkosta, online-mainoksista ja sosiaalisesta mediasta. Klikkauksista kertyvä data on keskeinen työväline yrityksille, kun halutaan tehdä strategisia ja taktisia päätöksiä liittyen liiketoimintaan (Akter & Wamba, 2016). Klikkausdataa tallennetaan lokitiedostoihin (Hu ym., 2014). Verkkokaupat voivat analysoimalla asiakkaidensa klikkausdataa löytää hyödyllisiä havaintoja. Esimerkiksi striimauspalvelu Netflix kerää ja analysoi yli miljardia elokuvaan liittyvää dataa, jotta yritys ymmärtää asiakkaidensa mieltymykset (Davenport & Harris, 2007). Silah-taroğluin & Gokhanin (2015) klikkausdataa analysoivassa tutkimuksessa havaittiin, että miehet tekevät verkkokauppatilauksia todennäköisesti eniten juhlasongin aikoihin, kun taas naiset tekevät ostoksia saman verran arkena ja

juhlasesonkina. Tällaisten havaintojen avulla yrityksissä voidaan tehdä esimerkiksi kohdennettua markkinointia ja kategoriasuunnittelua.

Dataa voidaan kerätä myös videona. Videodata on videoista napattua reaaliaikaista strukturoimatonta dataa (Akter & Wamba, 2016). Videodatalla on potentiaalia lisätä yritykselle arvoa. Esimerkiksi Netflixin on raportoitu käyttävän videodataa ennustaakseen käyttäjiensä katselutottumuksia ja arvioidakseen kokemusten laatua (Ramaswamy, 2013). Videodatalla ja erityisesti sen analyysissä on haasteena kuitenkin videodatan suuruus (Gandomi & Haider, 2015). Viimeinen datan Akterin & Wamban (2016) määrittelemä massadatan keräyskategoria on äänidata. Äänidataa kerätään tyypillisesti puheluista, soittokeskuksista tai asiakaspalvelusta (Akter & Wamba, 2016).

4 MASSADATAN JA MASSADATA-ANALYTIIKAN HYÖDYNTÄMINEN VERKKOKAUPPOISSA

Tässä viimeisessä sisältöluvussa käsitellään massadatan ja massadata-analytiikan hyödyntämistä verkkokauppakehityksessä. Akter ja Womba (2016) havaitsivat tutkimuksessaan kuusi keskeistä tapaa hyödyntää massadata-analytiikkaa verkkokaupoissa. Näihin tapoihin syvennytään tässä luvussa tarkemmin ja esitellään niiden tarjoamia liiketoiminnallisia hyötyjä verkkokaupoille. Lisäksi tässä luvussa on tarkoituksena vastata tässä tutkimuksessa esitettyihin tutkimuskysymyksiin.

4.1 Personointi ja suosittelujärjestelmät

Personointi tarkoittaa henkilökohtaisen palvelun tai räätälöityjen tuotteiden tarjoamista asiakkaille (Akter & Wamba, 2016). Henkilökohtaiset ja räätälöidyt tuotteet ja palvelut valitaan personoinnissa yksittäisen asiakkaan ominaisuuksien perusteella (Kaptein & Parvinen, 2015). Personointi perustuukin asiakkailta tai käyttäjiltä kerättyihin tietoihin, joita kerätään asiakkailta monella tapaa riippuen käyttötarkoituksesta. Personointi on keskeinen osa verkkokauppakehitystä, sillä tutkimuksissa on havaittu asiakkaiden tyypillisesti haluavan tehdä ostoksia samalla jälleenmyyjällä (Akter & Wamba, 2016).

Personointia voidaan soveltaa verkkokauppa kehityksessä monella tavalla. Eräs tyypillisin tapa käyttää personointia on erilaiset suosittelujärjestelmät, jonka vuoksi tässä tutkielmassa syvennytään näihin järjestelmiin tarkemmin. Suosittelujärjestelmät valitsevat tuotteita tai palveluita yksittäiselle asiakkaalle perustuen hänen arvioituihin tai pääteltyihin kiinnostuksenkohteisiinsa (Kaptein & Parvinen, 2015). Tämän jälkeen sivuston sisältöä mukautetaan asiakkaalle sopivaksi, esimerkiksi verkkokaupan aloitussivustolla näytetään asiakkaan mielenkiinnonkohteiden mukaisia tuotteita. Suosittelujärjestelmät voidaan jakaa

perinteisesti neljään ryhmään: sisältöperusteiset, yhteistoiminnalliset, hybridit ja tietopohjaiset suosittelujärjestelmät (Lu, Wu, Mao, Wang & Zhang 2015).

Sisältöperusteisessa suosittelujärjestelmässä suositellaan asiakkaille tuotteita tai palveluita perustuen hänen aikaisempaan toimintaansa, kuten ostoihin. Sisältöperusteinen suosittelujärjestelmä analysoi asiakkaan aiempia ostoksia ja suosittelee tuotteita, jotka muistuttavat attribuuteiltaan mahdollisimman paljon aikaisemmin ostettuja tuotteita tai palveluita. (Lu ym., 2015.)

Yhteistoiminnallisessa suosittelujärjestelmässä keskeisessä roolissa ovat muut asiakkaat. Yhteistoiminnallinen suosittelujärjestelmä suosittelee tuotteita tai palveluita sen perusteella mitä muut saman tyyppisistä asioista kiinnostuneet asiakkaat ovat ostaneet. (Lu ym., 2015.)

Tietopohjaisissa suosittelujärjestelmissä oletetaan, että asiakkaat, joilla on sama demografia, kuten ikä tai sijainti, ovat kiinnostuneista saman tyyppisistä asioista. Sekä yhteistoiminnallisessa, että tietopohjaisessa suosittelujärjestelmässä suositellaan siis tuotteita tai palveluita asiakkaan ja muiden ryhmien käyttäjien kiinnostuksenkohteiden perusteella. (Lu ym., 2015.)

Viimeinen suosittelujärjestelmäryhmä on hybridit suosittelujärjestelmät. Nimensä mukaisesti hybridit suosittelujärjestelmät yhdistävät kahta tai useampaa aikaisemmin mainittua tekniikkaa ja käyttää niitä yhdessä. (Lu ym., 2015.)

Schaferin, Konstanin & Riedlin (2001) mukaan suosittelujärjestelmät parantavat verkkokauppojen myyntiä kolmella tavalla: muuttamalla selaajat ostajiksi, lisäämällä ristiin myyntiä ja rakentamalla uskollisuutta kauppaa kohtaan. Verkkokaupoissa vierailee päivittäin lukuisia selailijoita ilman, että he lopulta ostavat mitään. Suosittelujärjestelmät auttavat muuttamaan nämä selailijat ostaviksi asiakkaiksi auttamalla heitä löytämään heidän tarpeisiinsa sopivia tuotteita tai palveluita. (Schafer ym., 2001.)

Suosittelujärjestelmät lisäävät myös ristiin myyntiä. Suosittelujärjestelmät suosittelevat tilaukselle täydentäviä tuotteita tai palveluita. Mikäli suosittelujärjestelmä toimii hyvin, niin tyypillisesti keskimääräisen ostoksen koko pitäisi kasvaa. Suosittelujärjestelmät siis parantavat myyntiä lisämyynnin kautta. (Schafer ym., 2001.) Esimerkiksi sivusto saattaisi suositella kassalla asioita, joita muut saman tuotteen ostaneet asiakkaat ovat myös ostaneet.

Viimeinen keskeinen tapa lisätä myyntiä on asiakkaan uskollisuuden rakentaminen yritystä tai verkkokauppaa kohtaan. Suosittelujärjestelmät parantavat asiakkaan uskollisuutta verkkokauppaa kohtaan luomalla arvonnäköistä sivuston ja asiakkaan välillä. Verkkokaupat luovat arvonnäköistä investoimalla asiakkaidensa oppimiseen, suosittelujärjestelmien käyttöön ja mukauttamaan käyttäjäliittymät vastaamaan asiakkaan tarpeita. Asiakkaat taas palaavat sivustoille, jotka palvelevat heidän tarpeitansa parhaiten. Kuten aiemmin mainittiin, niin kulluttajat myös tyypillisesti suosivat samaa jälleenmyyjää. (Schafer ym., 2001.) Esimerkiksi on havaittu, että Amazonin asiakkaat eivät halua vaihtaa toiseen verkkokauppaan, sillä he hyötyvät Amazonin tarjoamista suosituksista merkittävästi (Bradlow, Gangwar, Kopal & Voleti, 2017).

4.2 Dynaaminen hinnoittelu

Dynaaminen hinnoittelu tarkoittaa hinnoittelustrategioita, jossa hinnat muuttuvat ajan myötä joko kuluttajien tai tuotteiden välillä. Dynaamisessa hinnoittelussa tuotteesta tai palvelusta saatava paras hinta vaihtelee siis ajan tai asiakkaan mukaan. Hintoja saatetaan päivittää jopa reaaliajassa. (Kannan & Kopalle, 2001.)

Dynaamiseen hinnoitteluun kuuluu Naraharin, Rajun, Ravikumarin & Shahin (2005) mukaan kaksi ulottuvuutta: hintahajonta (*engl. price dispersion*) ja hintadifferointi (*engl. price discrimination*). Hintahajonta voi olla joko alueellista tai ajallista. Alueellisessa hintahajonnassa useat kaupat tarjoavat samaa tuotetta eri hinnoin. Ajallisessa hintahajonnassa taas kauppa määrittelee tuotteen tai palvelun hinnan ajan myötä perustuen myyntitiheeseen ja kysyntään ja tarjontaan. Hinta saattaa myös muuttua asiakaskohtaisesti, jolloin kyseessä on hintaerottelu. Hintadifferoinnista on tunnistettu kolme toimintamallia. (Narahari ym., 2005).

Ensimmäisessä hintadifferointimallissa myyjä hinnoittelee tuotteen tai palvelun asiakkaan maksukyvyyn mukaan. Tällöin tuote tai palvelu myydään sellaiselle henkilölle, joka arvostaa sen hinnan korkeimmalle. Toista mallia kutsutaan myös epälineaariseksi hinnoitteluksi. Tässä mallissa tuotteen tai palvelun hinta määräytyy asiakkaan ostokäyttäytymisen mukaan. Myyjä myy tuotetta tai palvelua samaan hintaan kaikille asiakkaille, mutta hinta muodostuu ostettavan määrän mukaan. Esimerkiksi paljousalennukset ovat tämän mallin mukaista dynaamista hinnoittelua. Kolmannessa ja viimeisessä mallissa tuotteen tai palvelun hinta määräytyy asiakassegmentin perusteella. Hintojen eriyttäminen saadaan hyödyntämällä asiakkaiden arvostuseroja. Hinta määräytyy siis esimerkiksi segmentin ostovoiman perusteella. Esimerkkinä tämän mallin dynaamisesta hinnoittelusta on ryhmälennukset, kuten opiskelija- ja eläkeläisalennukset. (Narahari ym., 2005.)

Digitalisaatio ja massadata ovat antaneet verkkokaupparyityksille mahdollisuuden seurata ja analysoida niin asiakkaidensa käytöstä, kuin heidän halukkuuttansa maksaa erilaisista asioista (Hinz, Hann & Spann, 2011). Dynaaminen hinnoittelu ja hinnoitteluratkaisut ovat tärkeässä roolissa verkkokaupoissa, sillä verkko-ostajat ovat keskimäärin tarkempia hinnoista, kuin kivijalkakauppojen asiakkaat (Degeratu, Rangaswamy & Wu, 2000). Tämän vuoksi dynaaminen hinnoittelu on keskeinen työväline verkkokaupoille (Degeratu ym., 2000). Dynaamisen hinnoittelun on todettu tutkimuksissa esimerkiksi tuovan voittoa jopa 33 % enemmän verrattuna staattiseen hinnoitteluun (Wu, Li & Da Xu, 2014).

4.3 Asiakaspalvelu

Laadukkaat palvelut ovat kriittisen tärkeä tekijä asiakasuskollisuudessa, asiakas-tyytyväisyydessä ja verkkokaupan käytön lisäämisessä (Palese & Usai, 2018). Tämän vuoksi verkkokauppojen asiakaspalvelulla on merkittävä rooli

onnistuneessa asiakaskokemuksessa. Massadata ja massadata-analytiikka tarjoavat uudenlaisia mahdollisuuksia ja työkaluja myös verkkokauppojen asiakaspalveluun.

Perinteisesti asiakaspalvelussa on ollut yrityksen näkökulmasta kaksi ongelmaa: asiakaspalvelijat vastaavat toistuvasti samoihin kysymyksiin ja yrityksen on haastavaa ylläpitää vuorokauden ympäri toimivia palveluita (Le & Liaw, 2017). Lisäksi Gupta, Borkar Mello, & Patil (2015) mainitsevat verkkokaupoille erääksi tyypilliseksi ongelmaksi sekavan navigoinnin verkkosivuilla, jonka vuoksi asiakkaiden saattaa olla haastavaa löytää haluttua tietoa. Ratkaisuksi näihin ongelmiin Le ym. (2017) ja Gupta ym. (2015) esittävät virtuaalisia asiakaspalvelijoita chattibotteja. Chattibotit tai virtuaaliset assistentit ovat tietokoneohjelma, joka on suunniteltu stimuloimaan älykästä keskustelua yhden tai useamman ihmiskäyttäjän kanssa käyttäen joko auditiivisia- tai tekstimenetelmiä (Gupta ym., 2015). Chattibottia voisikin kuvailla massadata-analyysia hyödyntäväksi työvälineeksi. Chattibotteja on kehitetty erilaisiin tarkoituksiin, esimerkiksi henkilökohtaiset mobiiliassistentit (kuten Applen kehittämä Siri) löytyvät nykyään lähes kaikista moderneista älypuhelimista. Chattibotit ovat löytäneet myös tiensä kulluttajien suosioon, sillä Waghmare (2019) mukaan ihmisistä jopa 70 % valitsee mieluummin chattibotilta tulleen viestin asiakaspalveluun soittamisen sijaan.

Chattibotit tarjoavat verkkokauppakäytössä monenlaisia hyötyjä yrityksille ja heidän asiakkailleen. Chattibotit toimivat ja tarjoavat palvelua vuorokauden ympäri ja ne kykenevät suorittamaan monimutkaista vuorovaikutusta asiakkaiden kanssa laajassa mittakaavassa (Moriuchi, Landers, Colton & Hair, 2021). Chattiboteilla on myös etunaan nopeus, sillä ne kykenevät vastaamaan asiakkaiden kysymyksiin lähes välittömästi. Samaan aikaan sellaiset asiakkaat, jotka tarvitsevat asiakaspalveluhenkilön apua, saavat sitä myös nopeammin. (Lei Cui, Huang, Wei, Tan, Duan & Zhou, 2017). Chattibotit vapauttavat täten asiakaspalvelijat haastavimpiin tehtäviin. Lisäksi Hildebrand & Bergner (2017) havaitsivat tutkimuksessaan, että chattibotit kykenevät myös tekemään lisämyyntiä ja myymään asiakkaalle harkittua kalliimman tuotteen.

Massadata-analyysin avulla voidaan myös mitata ja arvioida asiakkaiden uskollisuutta ja tyytyväisyyttä. Näitä asioita voidaan tutkia sosiaalisen median analytiikan kautta. Sosiaalisen median analytiikka on sosiaalisesta mediasta kerätyn strukturoimattoman ja strukturoidun massadatan analysointia. Anshari kollegoineen (2019) nostavat sosiaalisen median analytiikalle monia etuja. Sosiaalisen median analytiikan etuna verrattuna perinteisiin menetelmiin on se, että palautteen saaminen on nopeampaa, sillä yrityksen ei tarvitse odotella myynnin raportteja tehdäkseen päätelmiä. Massadata helpottaa myös asiakaspalveluhenkilökunnan työtä, sillä he näkevät asiakkaidensa tietoja etukäteen. Nämä tiedot esimerkiksi helpottavat asiakkaiden käsittelyä ristiriitatilanteissa. Henkilökunta voi myös tarjota lisäpalveluita potentiaalisille asiakkaille hänen kiinnostuksenkohteidensa ja käyttäytymisen perusteella. Asiakas voi myös valittaa saamastaan palvelusta esimerkiksi jollain sosiaalisen median alustalla tai valituslomakkeen kautta. Henkilökuntaa helpottaa, kun he näkevät etukäteen asiakkaan taustatiedot, sillä kun asiakas soittaa asiakaspalveluun, niin tilannetta on helpompi

käsitellä. Tämä saa asiakkaan tuntemaan olonsa myös arvostetuksi. (Anshari ym., 2019.)

Massadata mahdollistaa myös monikanavaisen vuorovaikutuksen. Esimerkiksi mikäli autoteollisuus julkaisee uuden auton ja he ovat huolestuneita asiakkaiden ja kilpailijoiden vastaanotosta, he voivat seurata ja analysoida sosiaalisen median reagoitua ja parantaa tuotetta näiden tietojen pohjalta. Massadata-analytiikkaa voidaan käyttää siis asiakasymmärryksen lisäämiseen ja markkinatutkimukseen. (Anshari ym., 2019.)

4.4 Toimitusketju ja sen läpinäkyvyys

Toimitusketjun parantamisesta on tullut verkkokaupoille elintärkeä asia, jotta tavara saadaan liikkumaan mahdollisimman tehokkaasti ja kustannusystävällisesti (Yu, Wang, Zhong & Huang, 2017). Verkkokauppojen täytyy valita toimitusketju rakentaessa kahdesta jakelunhallintamallista. Yritys voi joko rakentaa itse oman logistiikkajakeluvuoston, joka täyttää yrityksen omat jakeluvaatimukset tai vaihtoehtoisesti yritys ostaa jakelupalvelut kolmannelta osapuolelta, eli esimerkiksi logistiikkayhtiöltä (Zheng, Zhang & Song, 2018).

Zheng ym. (2020) mukaan oman jakelumallin valitsemisessa etuna on esimerkiksi hyvä ajanhallinta, parannettu käyttäjäkokemus, asiakasuskollisuus, tuotteiden laadun tehokas seuranta ja järkevä resurssien jako. Toisaalta heidän mukaansa tällä mallilla on ongelmana se, että yritykset joutuvat toimimaan heille tuntemattomalla alueella logistiikan parissa, jolloin esimerkiksi johtamisen kanssa voi olla haasteita. Oman logistiikan ja jakelun hallinnointi on myös kallista, mikä saattaa johtaa suuriin paineisiin ja aiheuttaa taloudellisia menetyksiä (Yu ym., 2017). Viime vuosina esimerkiksi suuryritykset AliExpress ja Alibaba ovat investoineet vahvasti oman logistiikkajärjestelmän rakentamiseen.

Verkkokaupat voivat myös vaihtoehtoisesti valita ostaa logistiikan kolmannelta osapuolelta. Tällöin kolmas osapuoli, eli tyypillisesti logistiikkayhtiö, hoitaa tavaran säilyttämiseen, varastointiin ja kuljetukseen liittyvän hallinnan (Zheng ym., 2020). Tällainen malli tarjoaa monia etuja. Tutkimusten mukaan se esimerkiksi auttaa vähentämään ostajan, eli tässä tapauksessa verkkokaupan, riskejä (Govindan & Chaudhuri, 2016) ja tasapainottamaan innovaatioiden ja resurssien kohdentamisen välisiä kompromisseja (Sinkovics, Kuivalainen & Roath, 2018).

Logistiikan ostamisessa kolmannelta osapuolelta on kuitenkin myös heikkoutensa. Kun asiakas tekee tilauksen verkkokauppaan, niin hän tyypillisesti odottaa yritysten tarjoavan hänelle palvelun, jolla voi seurata tilauksen tilaa ja sen lähetyksen etenemistä (Akter & Wamba, 2016). Asiakas odottaakin tietoa asioista kuten tarkasta toimitusajasta, nykyisestä tilasta ja lähetyksen sijainnista. Kuitenkin mikäli logistiikka on kolmannen osapuolen vastuulla, niin näitä tietoja ei välttämättä ole tarjolla asiakkaalle (Zheng ym., 2018), jolloin asiakaskokemus heikkenee. Massadata-analytiikalla on toimitusketjussa avainrooli, sillä sen

avulla voidaan kerätä tietoa useilta eri osapuolilta ja näin ollen voidaan tarjota asiakkaalle arvioitu toimitusaika (Akter & Wamba, 2016).

Massadataa ja massadata-analytiikkaa voidaan käyttää myös oman toimitusketjun parantamiseen. Esimerkiksi kiinalainen suuryritys JD.com analysoi oman logistiikkaketjunsä jakeluhenkilöstöä, varastoja ja käyttäjien välisiä maantieteellisiä etäisyyksiä, jotta he voivat tarjota mahdollisimman optimaalisen ja nopean jakelukanavan asiakkailleen (Zheng ym., 2020). Datan onnistuneella keräämisellä ja analysoimalla JD.com onkin saanut rakennettua maineensa nopean toimituksen varaan (Yu ym., 2017). Analysoimalla dataa toimitusketjujen eri osia ja niiden välisiä suhteita voidaankin parantaa liiketoiminnan suorituskykyä toimitusketjujen osalta.

4.5 Turvallisuus ja petoksien havainnointi

Maksuvälinepetoksien lukumäärä on suuri. Vuonna 2014 maksuvälinepetoksien summaksi on arvioitu 16 miljardia dollaria globaalilla tasolla (Patil, Nemade & Soni, 2018). Massadatan ja massadata-analytiikan avulla voidaan parantaa turvallisuutta ja havaita esimerkiksi maksuvälinepetoksia.

Maksuvälinepetokset voidaan jakaa kahteen luokkaan: offline- ja online-petoksiin (Carta, Fenu, Recupero & Saia, 2016). Verkkokaupoissa tapahtuvat maksut ovat online-maksuja ja niiden määrä on noussut radikaalisti vuosien saatossa verkkokauppojen yleistymisen myötä. Verkkomaksuissa pankki- ja luottokortit ovat virtuaalikortteja (Dai, Yan, Tang, Zhao & Guo, 2016). Virtuaalikorteilla on huomattavasti helpompi tehdä maksuvälinepetoksia, sillä rikollinen ei tarvitse fyysistä korttia maksutapahtuman suorittamiseen (Dai ym., 2016). Virtuaalikortista riittää muutama tieto, kuten kortin numero. Online-maksuissa on isona riskinä myös se, että rikoksen uhri ei tajua joutuneensa maksuvälinepetoksen uhriksi (Dai ym., 2016).

Maksuvälinepetoksien estämiseen on kehitetty lukuisia keinoja, kuten erilaiset signeeraukset, varmistusnumerot ja tunnuslukutaulukot. Nämä keinot eivät kuitenkaan riitä enää estämään maksuvälinepetoksia, jonka vuoksi yritykset ovat alkaneet käyttämään petoksien havaitsemisjärjestelmiä. Järjestelmät keräävät valtavan määrän massadataa asiakkaidensa maksuista, maksusijainneista ja muista tiedoista, jonka jälkeen tätä dataa analysoidaan ja verrataan asiakkaan aiempaan kulutuskäyttäytymiseen. Mikäli järjestelmä havaitsee jonkin poikkeaman käyttäytymisessä, niin järjestelmä merkitsee profiilin epäilyttäväksi ja tarpeen tullen estää maksun tapahtumasta. (Abdallah, Maarof & Zainal, 2016.)

Massadatan avulla maksuntarjoajat voivat siis reaaliajassa yhdistää transaktioihin liittyvän datan asiakkaan ostohistoriaan, lokitietoihin ja mobiililaitteesta saatavaan maantieteelliseen sijaintiin. Esimerkiksi Visa on asentanut ison massadataan pohjautuvan petostenhallintajärjestelmän, jonka avulla on mahdollista tarkistaa 500 eri transaktioon liittyvää näkökohtaa (Akter & Wamba, 2016). Tämä järjestelmä säästää arviolta 2 miljardia dollaria mahdollisia tappiota

vuosittain (Akter & Wamba, 2016). Verkkokaupoissa petosten ehkäiseminen tapahtuu tyypillisesti maksuntarjoajien järjestelmien kautta. Verkkokaupat voivatkin parantaa turvallisuutta esimerkiksi valitsemalla vakaan ja luotettavan maksuntarjoajan.

4.6 Ennustavat analytiikat

Ennustavat analytiikat viittaavat tapahtumien tunnistamiseen ennen niiden tapahtumista massadatan avulla (Akter & Wamba, 2016). Yksinkertaisimmillaan ennustavat analytiikat ovat siis datan muuttamista ennusteiksi, jolloin verkkokaupat pystyvät hyödyntämään tätä tietoa päätöksenteossa.

Ennustavat analytiikat tarjoavatkin monia etuja verkkokaupoille. Ennustavalla analytiikalla saatavat tiedot parantavat ja nopeuttavat yritysten päätöksentekoa (Ram, Zhang, Changyu & Koronios, 2016) ja auttavat laatimaan tarkemman ja paremman budjetin (Akter & Wamba, 2016). Ennustavat analytiikat helpottavat myös tuotteiden ja palveluiden optimoimista, sillä verkkokaupat voivat optimoida esimerkiksi tuotteidensa varastomäärät perustuen asiakkaiden hakuihin ja käyttäytymiseen (Le & Liaw, 2017). Varastomäärien optimointi taas auttaa verkkokauppoja välttämään tuotteiden loppumisen varastosta ja täten asiakkaiden menettämisen (Akter & Wamba, 2016). Hauista ja asiakkaiden käyttäytymisestä pystytään löytämään myös esimerkiksi trendejä (Le & Liaw, 2017).

Verkkokauppa Amazon on eräs suuri massadatan ja massadata-analytiikan hyödyntäjä. Amazon käyttää massadataan jäljittämään ja turvaamaan valikoimissa olevaa 1,5 miljardia tuotetta, joita on noin 200 varastossa ympäri maailmaa. Amazon käyttää ennustavia analytikoita heidän kehittämässään ennakoivassa toimituksessa (*engl. anticipatory shipping*). Amazonin ennakoivassa toimituksessa analyysit ennustavat milloin asiakas ostaa tuotteen ja lähettää sen valmiiksi sellaiselle varastolle, joka on lähellä sen lopullista määränpäättä. Kun asiakas tekee lopullisen tilauksen, niin toimitusaika on lyhentynyt. (Zakir, Seymour & Berg, 2015.) Amazonin ennakoiva toimitus onkin hyvä esimerkki ennustavan analytiikan hyödyntämisestä toimitusketjun tehostamiseen.

5 YHTEENVETO JA POHDINTA

Datan määrä on kasvanut viimeisten vuosien aikana suurella määrällä. Samaan aikaan, kun dataa kertyy koko ajan lisää, myös hyödyttömänä pidetyn datan määrä on kasvanut. Tämän vuoksi massadataa hyödyntävien yritysten ja erityisesti verkkokauppojen täytyy pystyä erottelemaan massadatatista yritykselle hyödyllinen informaatio ja tehdä päätöksiä tämän pohjalta. Kuitenkin, mikäli massadataa hyödyntävä taho saa eroteltua datasta oleellisen informaation tai sovellettua massadata-analytiikkaa muilla tavoin, tarjoaa massadata lukuisia mahdollisuuksia niin asiakaspalvelun parantamisen, myynnin lisäämisen kuin turvallisuuden parantamisenkin kohdalla.

Kuten tutkielmassa havaittiin, niin massadatan määritelmä ei ole yksinkertainen. Siihen liittyy kuitenkin oleellisesti tiettyjä elementtejä, kuten suuri koko ja hajanaisuus. Englanninkielinen termi « big » data kuvastaakin hyvin sitä, että massadatatassa oleellista on tietynlainen paljous – dataa on paljon, sitä kertyy nopeasti ja sitä on monen tyyppistä. Kuitenkaan koko ei riitä ainoaksi määrittäväksi tekijäksi, vaan V-mallin mukaisesti oleellista massadatatassa on myös muut elementit, eli vaihtelevuus ja vauhti. Massadatalle on ominaista se, että sen datan laatu on vaihtelevaa. Lisäksi massadataan liittyy oleellisesti myös vauhti, eli se, että sitä kertyy nopeasti lisää. 3V-malliin on myös lisätty viime vuosina muita ominaisuuksia, joista käytetyimpiä ovat joidenkin tutkijoiden mukaan arvo ja todenmukaisuus. Todenmukaisuus viittaa siihen, että massadataa kertyy vaihtelevista lähteistä. Arvo taas korostaa massadatatista saatavia hyötyjä. Tässä tutkielmassa keskityttiin etsimään vastausta sille, millaista liiketoiminnallista arvoa massadata tarjoaa verkkokaupoille.

Massadata-analytiikka on merkittävä ja kenties tärkein osa massadata-analytiikan arvoketjua. Massadata-analytiikkaa voidaan tehdä niin historiaan pohjautuvan datan pohjalta, kuin myös tulevaisuuteen keskittyvää ennustavaa analytiikkaa. Kuten tutkielmassa huomattiin, niin verkkokaupat pystyvät hyödyntämään useampaa analyysin mallia. Esimerkiksi ennustavilla analytiikoilla voidaan yrittää ennustaa asiakkaiden tulevaisuuden ostokäyttäytymistä.

Massadatan tavoin tutkielmassa havaittiin, että myöskään verkkokauppaa ei pysty määrittelemään yksiselitteisesti. Verkkokaupan määritelmä riippuu

esimerkiksi näkökulmasta. Verkkokaupan voi kuitenkin yksinkertaisesti kuvastaa olevan internetin välityksellä ostamista ja myymistä. Tutkielmassa keskityttiin B2C-verkkokauppaan, eli tarkasteltiin yritysten ja kuluttajien välistä kauppaa. Kauppaa voidaan tehdä myös yritykseltä yritykselle (B2B). Yritysten välisessä kaupassa on jotakin eroavaisuuksia yritys-kuluttaja-kauppaan verrattuna, kuten ostojen määrä ja koko. Jatkotutkimuskysymyksenä voisikin syventyä tarkemmin nimenomaan yritysten väliseen B2C-kauppaan ja massadatan mahdollisuuksiin (ja haasteisiin) yritysten välisissä kaupoissa.

Tutkimuksessa käsiteltiin myös lyhyesti verkkokaupan käytettävyyttä ja mitä asioita asiakkaat kokevat tärkeinä. Verkkokauppojen määrän ollessa nykyään suuri ja koko ajan kasvava, on käytettävyys on tärkeässä osassa verkkokaupakehitystä. Asiakkaiden tyytymättömyys myös korostaa massadatan tarjoamien mahdollisuuksien hyötyjä.

Tässä kirjallisuuskatsauksena toteutetussa kandidaatintutkielmassa oli tarkoituksena vastata mahdollisimman kattavasti seuraaviin tutkimuskysymyksiin:

- Kuinka massadataa ja massadata-analytiikkaa voidaan hyödyntää verkkokaupoissa?
- Mitä hyötyä massadatan ja massadata-analytiikan käyttäminen tarjoaa verkkokaupoille?

Tutkielman ydintulokset voisi tiivistää siten, että massadataa ja massadata-analytiikkaa voidaan hyödyntää varsin monipuolisesti verkkokaupoissa. Massadata tarjoaa mahdollisuuksia ja luo arvoa monella osa-alueella ja tässä tutkielmassa tarkasteltiin tarkemmin näistä kuutta: personointia, dynaamista hinnoittelua, asiakaspalvelua, toimitusketjua, turvallisuutta ja ennustavia analyytikoita. Massadatan ja massadata-analytiikan hyödyntäminen näillä osa-alueilla tarjoaa verkkokaupoille etuja monella eri tapaa, kuten esimerkiksi lisäämällä myyntiä, nopeuttamalla asiakaspalvelua ja parantamalla maksuturvallisuutta.

Tässä tutkimuksessa jätettiin kokonaan tarkastelematta esimerkiksi massadatan keräämisessä esiintyvät mahdolliset haasteet ja ongelmat, kuten eettisyys ja tietoturvallisuus. Ongelmat ja haasteet ovat kuitenkin kiistatta eräs keskeinen osa massadataa, jonka vuoksi niistä saisi muodostettua tärkeän jatkotutkimuskysymyksen B2B-kaupan tarkastelun rinnalle.

LÄHTEET

- Abdallah, A., Maarof, M. A., & Zainal, A. (2016). Fraud detection system: A survey. *Journal of Network and Computer Applications*, 68, 90-113.
- Akter, S., & Wamba, S. F. (2016). Big data analytics in E-commerce: a systematic review and agenda for future research. *Electronic Markets*, 26(2), 173-194.
- Anagnostopoulos, I., Zeadally, S., & Exposito, E. (2016). Handling big data: research challenges and future directions. *The Journal of Supercomputing*, 72(4), 1494-1516.
- Anshari, M., Almunawar, M. N., Lim, S. A., & Al-Mudimigh, A. (2019). Customer relationship management and big data enabled: Personalization & customization of services. *Applied Computing and Informatics*, 15(2), 94-101.
- Bidgoli, H. (2002). *Electronic commerce: principles and practice*. Academic Press.
- Bradlow, E. T., Gangwar, M., Kopalle, P., & Voleti, S. (2017). The Role of Big Data and Predictive Analytics in Retailing. *Journal of Retailing*, 93(1), 79-95.
- Carta, S., Fenu, G., Recupero, D. R., & Saia, R. (2019). Fraud detection for E-commerce transactions by employing a prudential Multiple Consensus model. *Journal of Information Security and Applications*, 46, 13-22.
- Chaffey, D. (2007). *E-business and E-commerce Management: Strategy, Implementation and Practice*. Pearson Education.
- Chen, M., Mao, S., & Liu, Y. (2014). Big data: A survey. *Mobile networks and applications*, 19(2), 171-209.
- Clarke, R. (2016) Big data, big risks. *Info Systems J*, 26: 77- 90.
- Cui, L., Huang, S., Wei, F., Tan, C., Duan, C., & Zhou, M. (2017, July). Superagent: A customer service chatbot for e-commerce websites. In *Proceedings of ACL 2017, System Demonstrations* (pp. 97-102).
- Dai, Y., Yan, J., Tang, X., Zhao, H., & Guo, M. (2016). Online Credit Card Fraud Detection: A Hybrid Framework with Big Data Technologies. *IEEE Trustcom/BigDataSE/ISPA*, 1644-1651.
- Davenport, T. (2014). Big data at work: dispelling the myths, uncovering the opportunities. *Harvard Business Review Press*.
- Davenport, T. H. (2012). The human side of Big Data and high-performance analytics. *International Institute for Analytics*, 1(1), 1-13.
- Davenport, T. H., Harris, J. G., Jones, G. L., Lemon, K. N., Norton, D., & McCallister, M. B. (2007). The dark side of customer analytics. *Harvard business review*, 85(5), 37.

- De Mauro, A., Greco, M., & Grimaldi, M. (2016). A formal definition of Big Data based on its essential features. *Library Review*.
- Degeratu, A. M., Rangaswamy, A., & Wu, J. (2000). Consumer choice behavior in online and traditional supermarkets: The effects of brand name, price, and other search attributes. *International Journal of Research in Marketing*, 17(1), 55-78.
- Faroukhi, A. Z., El Alaoui, I., Gahi, Y., & Amine, A. (2020). Big data monetization throughout Big Data Value Chain: a comprehensive review. *Journal of Big Data*, 7(1), 1-22.
- Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137-144.
- Google trends. (2021). Big data. Viitattu 4.11.2021, haettu osoitteesta: <https://www.google.com/trends/explore?date=all&q=big%20data>
- Govindan, K., & Chaudhuri, A. (2016). Interrelationships of risks faced by third party logistics service providers: A DEMATEL based approach. *Transportation Research Part E: Logistics and Transportation Review*, 90, 177-195.
- Gupta, S., Borkar, D., Mello, C. D., & Patil, S. (2015). An E-Commerce Website based Chatbot. 6, 3.
- Hildebrand, C. & Bergner, A. (2019). Ai-driven sales automation: Using chatbots to boost sales. *NIM Marketing Intelligence Review*, 11(2), 36-41
- Hinz, O., Hann, I.-H., & Spann, M. (2011). Price Discrimination in E-Commerce? An Examination of Dynamic Pricing in Name-Your-Own Price Markets. *MIS Quarterly*, 35(1), 81-98.
- Hu, H., Wen, Y., Chua, T. S., & Li, X. (2014). Toward scalable systems for big data analytics: A technology tutorial. *IEEE access*, 2, 652-687.
- Johnson, J. E. (2012). Big data + big analytics = big opportunity. *Financial Executive*, 28, 50-53.
- Kalakota, R., & Whinston, A. B. (1997). Electronic commerce: a manager's guide. *Addison-Wesley Professional*.
- Kannan, P. K., & Kopal, P. K. (2001). Dynamic pricing on the internet: importance and implications for consumer behavior. *International Journal of Electronic Commerce*, 5, 63-83.
- Kaptein, M., & Parvinen, P. (2015). Advancing E-Commerce Personalization: Process Framework and Case Study. *International Journal of Electronic Commerce*, 19(3), 7-33.
- Kohavi & F. Provost (Toim.), Applications of Data Mining to Electronic Commerce (ss. 115-153). *Springer US*.

- Le, T. M., & Liaw, S.-Y. (2017). Effects of Pros and Cons of Applying Big Data Analytics to Consumers' Responses in an E-Commerce Context. *Sustainability*, 9(5), 798.
- Lu, J., Wu, D., Mao, M., Wang, W., & Zhang, G. (2015). Recommender System Application Developments: A Survey.
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Hung Byers, A. (2011). Big data: The next frontier for innovation, competition, and productivity. *McKinsey Global Institute*.
- Manzoor, A. (2010). E-commerce: An Introduction. *Amir Manzoor*.
- McAfee, A., Brynjolfsson, E., Davenport, T. H., Patil, D. J., & Barton, D. (2012). Big data: the management revolution. *Harvard business review*, 90(10), 60-68.
- Moriuchi, E., Landers, V. M., Colton, D., & Hair, N. (2021). Engagement with chatbots versus augmented reality interactive technology in e-commerce. *Journal of Strategic Marketing*, 29(5), 375-389.
- Mourya, S. K., & Gupta, S. (2014). E-Commerce. *Alpha Science International*.
- Narahari, Y., Raju, C. V. L., Ravikumar, K., & Shah, S. (2005). Dynamic pricing models for electronic business. *Sadhana*, 30(2-3), 231-256.
- Nielsen, J. (1994). Usability Engineering. *Morgan Kaufmann*.
- Nielsen, J., & Loranger, H. (2006). Prioritizing Web Usability. *Pearson Education*.
- Niranjanamurthy, M., Kavyashree, N., Jagannath, S., & Chahar, D. (2013). Analysis of e-commerce and m-commerce: advantages, limitations and security issues. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(6), 2360-2370.
- Ohlhorst, F. J. (2012). Big data analytics: turning big data into big money (Vol. 65). *John Wiley & Sons*.
- Palese, B., & Usai, A. (2018). The relative importance of service quality dimensions in E-commerce experiences. *International Journal of Information Management*, 40, 132-140.
- Patil, S., Nemade, V., & Soni, P. K. (2018). Predictive modelling for credit card fraud detection using data analytics. *Procedia computer science*, 132, 385-395.
- Posti. 2020. Suuri verkkokauppatutkimus 2020. Viitattu 9.11.2021, haettu osoitteesta: https://minun.posti.fi/hubfs/Tutkimukset/Suuri-verkkokauppatutkimus-2020_Posti.pdf#_ga=2.66485612.313805965.1617786317-780347764.1617786317
- Rajaraman, V. (2016). Big data analytics. *Resonance*, 21(8), 695-716.

- Ram, J., Zhang, Changyu., & Koronios, A. (2016). The Implications of Big Data Analytics on Business Intelligence: A Qualitative Study in China. *Procedia Computer Science*, 87, 221–226.
- Ramaswamy, S. (2013). What the Companies Winning at Big Data Do Differently. *Harvard Business Review*.
- Sagiroglu, S., & Sinanc, D. (2013, May). Big data: A review. In 2013 international conference on collaboration technologies and systems (CTS). 42-47. *IEEE*.
- Salo, I. (2014). Big data & pilvipalvelut. *Docendo*, Jyväskylä.
- Schafer, J. B., Konstan, J. A., & Riedl, J. (2001). E-Commerce Recommendation Applications.
- Silahtaroglu, G., & Donertasli, H. (2015). Analysis and prediction of E-customers' behavior by mining clickstream data. 1466–1472.
- Simon, P. (2013). Too big to ignore : The business case for big data. *Hoboken, N.J.:John Wiley & Sons*.
- Sinkovics, R. R., Kuivalainen, O., & Roath, A. S. (2018). Value co-creation in an outsourcing arrangement between manufacturers and third party logistics providers: Resource commitment, innovation and collaboration. *Journal of Business & Industrial Marketing*, 33(4), 563–573.
- The Economist. (2017). The world's most valuable resource is no longer oil, but data. Viitattu 3.12.2021, haettu osoitteesta:
<https://www.economist.com/leaders/2017/05/06/the-worlds-most-valuable-resource-is-no-longer-oil-but-data>
- Waghmare, C. (2019). Business Benefits of Using Chatbots. *Introducing Azure Bot Service: Building Bots for Business* (ss. 147–165). A-press.
- Wu, J., Li, L., & Da Xu, L. (2014). A randomized pricing decision support system in electronic commerce. *Decision Support Systems*, 58, 43-52. ISO 690.
- Yu, Y., Wang, X., Zhong, R. Y., & Huang, G. Q. (2017). E-commerce logistics in supply chain management: Implementations and future perspective in furniture industry. *Industrial Management & Data Systems*, 117(10), 2263–2286.
- Zakir, J., Seymour, T., & Berg, K. (2015). Big Data Analytics. *Issues in Information Systems*, 16(2).
- Zheng, K., Zhang, Z., & Song, B. (2020). E-commerce logistics distribution mode in big-data context: A case analysis of JD.COM. *Industrial Marketing Management*, 86, 154–162.