

VAASAN YLIOPISTO  
TEKNIIKAN JA INNOVAATIOJOHTAMISEN YKSIKKÖ  
TIETOJÄRJESTELMÄTIEDE

Kalle-Tuomas Rantalainen

**NEUROVERKKOJEN JA KONEOPPIMISEN HYÖDYNTÄMINEN  
VAHINKOVAKUUTUSYHTIÖN PUHELINPALVELUKESKUKSEN  
MYYNTIPROSESSEISSA**

Tietojärjestelmätiede  
Pro gradu -tutkielma

VAASA 2020

---

**VAASAN YLIOPISTO****Tekniikan ja innovaatiojohtamisen yksikkö**

<b>Tekijä:</b>	Kalle-Tuomas Rantalainen
<b>Tutkielman nimi:</b>	Neuroverkkojen ja koneoppimisen hyödyntäminen vahinkovakuutusyhtiön puhelinpalvelukeskuksen myyntiprosesseissa
<b>Ohjaaja:</b>	Tero Vartiainen
<b>Tutkinto:</b>	Kauppätieteiden maisteri
<b>Oppiaine:</b>	Tietojärjestelmätiede
<b>Aloitusvuosi:</b>	2015
<b>Valmistumisvuosi:</b>	2021

**Sivumäärä: 119**

---

**TIIVISTELMÄ:**

Opinnäytetyössä tarkoituksena on selvittää koneoppimisen ja neuroverkkojen hyödyntämispotentiaalia vahinkovakuutusyhtiön puhelinpalvelukeskuksen yksityisasiakkaille suuntaamassa myyntityössä. Tutkimuksen tavoitteena on kehittää toiminnan suunnittelututkimukselliseen menetelmään pohjautuva artefakti, tässä tapauksessa taulukko teorian tietoon pohjautuvista agenttien ja asiakkaiden ominaisuuksista, joita voidaan hyödyntää osana tekoälyohjatun ACPS (Agent Customer Pairing System) -järjestelmän agenttien ja asiakkaiden profilointia, parempien myyntitulosten saavuttamiseksi. Artefakti tulee kehittää niin että se huomioi EU:n yleisen tietosuoja-asetuksen (2016/679) sen käytölle mahdollisesti asettamat rajoitteet.

Tutkimus tehtiin toiminnan suunnittelututkimuksellisella otteella, käyttäen sen pohjana Seinin, Hendfridssonin, Puraon, Rossin ja Lindgrenin (2011) kehittämää ADR-metodia. Tutkimus suoritettiin tutkimusmetodille ominaisessa, läheisessä yhteistyössä kohdeorganisaation kanssa, jossa kohdeorganisaatio pääsee tutkijan kanssa vastavuoroisesti osallistumaan lopullisen artefaktin muokkaamiseen. Tutkimuksen teoreettisen osan muodostaa vakuutustoimintaa, tekoälyä, koneoppimista, neuroverkkoja, myyntiä, markkinointia, asiakkaiden profilointia sekä tietosuojalainsäädäntöä käsittelevä koti- ja ulkomainen kirjallisuus. Tutkimusympäristöstä kerättävänä aineistona toimii teemahaastatteluin kerätty aineisto sekä kohdeorganisaation kanssa yhteisen tutkimusprosessin aikana kertynyt tieto.

ACPS-järjestelmässä käytettävien asiakkaiden ja agenttien profiilien suunnittelussa pääasiallinen fokus oli myyntitapahtuman toteutumisen todennäköisyyden kasvattamisessa. Profiilien suunnittelussa keskityttiin sellaisiin saatavilla oleviin asiakkaiden ja agenttien ominaisuuksiin, jotka kategorisoituvat kuluttaja-asiakkaiden päätöksentekoprosessin lopputulokseen vaikuttavien tekijöiden luokkiin, joko ostotilannetyypin, henkilökohtaisten vaikutteiden tai sosiaalisten vaikutteiden alle, ja joilla voi tätä kautta olla vaikutusta ostopäätöksen syntyyn. ACPS-järjestelmän kannalta kriittisiä elementtejä havaittiin olevan asiakastietokannan sisältämän tiedon määrä sekä sen laatu. Kuluttajien identiteetin liittyvän tiedon sijaan, tulisi profiloinnissa käytettävien ominaisuuksien osalta painottaa varsinaiseen asiakaskäyttäytymiseen liittyvää tietoa. Jotta henkilötietoa voidaan käyttää ACPS-järjestelmän ominaisuuksina, on sen käsittelyn ja keräämisen täytynyt täyttää Tietosuoja-asetuksen (2016/679) määrittelemistä kuudesta perusteesta vähintään yhden, eikä se saa sisältää minkäänlaista automaattista päätöksentekoa eli esimerkiksi oikeusvaikutuksia henkilöihin, joista tietoa on kerätty.

---

**AVAINSANAT:** koneoppiminen, neuroverkot, vahinkovakuuttaminen, puhelinpalvelukeskus, profilointi

---

**UNIVERSITY OF VAASA**  
**School of technology and innovation**

**Author:** Kalle-Tuomas Rantalainen  
**Topic of Master's Thesis:** Neuroverkköjen ja koneoppimisen hyödyntäminen vahinkovakuutusyhtiön puhelinpalvelukeskuksen myyntiprosesseissa  
**Name of the Supervisor:** Tero Vartiainen  
**Degree:** Master of Science in Economics and Business Administration  
**Major Subject:** Master's Programme in Information Systems Science  
**Year of Entering the University:** 2015  
**Year of Completing the Thesis:** 2021 **Pages: 119**

---

**ABSTRACT:**

The thesis investigated utilizing potential of machine learning and neural networks in private customer focused sales work in indemnity insurance company's call center department. Focus of the thesis is to develop action design research based artefact, in this particular case study a theory based table, about agent and customer attributes which can be exploited in agent and customer profiling, as a part of the Agent Customer Pairing System (ACPS). Goal of the system is to achieve better results in sales compared to current state. Artefact has to be developed in a manner that takes into consideration of all possible restrictions that European Union's General Data Protection Regulation (2016/679) may cause for its use.

The research was carried out as an action design research, using ADR-method developed by Sein, Hendfridsson, Purao, Rossi and Lindgred (2011) as its basis. Research was carried out in close co-operation with target organization, where organization is allowed to mutually participate in the shaping of the final artefact. The theoretical basis of the thesis was based on literature that covered insurance business, artificial intelligence, machine learning, neural networks, sales, marketing, customer profiling and data protection legislation. Data from the research environment was collected by theme interviews and it also accumulated during the mutual research project alongside with the target organization.

Main focus in customer and agent profiling used in ACPS-system, was to increase probability of the sales transaction. Profile design process was focusing especially such available customer and agent attributes, that was categorized to the classes, containing factors that affect end result consumer-customers decision making process, and which could therefore have effect on purchase decision formation. Main classes consisted of the *purchase circumstance type*, *personal influences* and *social influences*. Perceived critical elements in ACPS-system was quality and quantity of the customer data contained in main data base and that instead of emphasising solely on data concerning identity of the consumers, the actual consumer behaviour, should be emphasised. So that personal data can be used as attributes of the ACPS-system, its handling and collecting process have to fulfill at least one of the six principles defined in GDPR (2016/679). Personal data used in the system can't either contain any kind of automatic decision making which could for example have legal effects for the persons from which data have been collected.

---

**KEY WORDS:** machine learning, neural networks, insurance business, call center, customer profiling

## SISÄLLYSLUETTELO

LYHENTEET JA TERMIT	7
1. JOHDANTO	8
1.1 Tutkimuksen aihe ja tavoite	8
1.2 Tutkimusongelma ja tutkimuskysymykset	10
1.3 Tutkimusmenetelmät ja -aineisto	11
2. VAKUUTUSTOIMINTA	14
2.1 Vakuutus	14
2.2 Vakuutusyhtiö	16
2.3 Vakuutustuotteiden myynti	17
2.4 Vakuutusyhtiön puhelinpalvelukeskus	18
2.4.1 Puhelinpalvelukeskuksen agentti ja asiakas	18
2.4.2 Inbound	19
2.4.3 Outbound	19
2.4.4 Puhelinpalvelukeskuksen kautta myytävät tuotteet ja tuoteryhmät	23
3. TEKOÄLY, KONEOPPIMINEN JA NEUROVERKOT	24
3.1 Koneoppiminen	25
3.1.1 Ohjattu oppiminen	27
3.1.2 Ohjaamaton oppiminen	28
3.1.3 Vahvistusoppiminen	28
3.2 Neuroverkot	29
3.3 Koneoppimisen ja neuroverkkomenetelmien sovelluksia	31
3.4 ACPS-järjestelmässä hyödynnettävät menetelmät	35

4.	VAIKUTTIMET ASIAKKAAN OSTOPÄÄTÖKSEN TAKANA	38
4.1	Ostotilannetyypit	38
4.1.1	Laajamittainen ongelmanratkaisu	38
4.1.2	Rajattu ongelmanratkaisu	39
4.1.3	Automaattinen vastaus	39
4.1.4	Asiakkaan osallistuvuus ostotilanteessa	40
4.2	Henkilökohtaiset vaikutteet	40
4.2.1	Persoonallisuus	40
4.2.2	Elämäntyyli	44
4.2.3	Muut henkilökohtaiset vaikutteet	45
4.3	Sosiaaliset vaikutteet	46
4.3.1	Sosiaalinen luokka	46
4.3.2	Viiteryhmä	47
4.3.3	Kulttuuri ja perhe	47
5.	ASIAKKAIDEN PROFILOINTI MARKKINOINNISSA	49
5.1	Kuluttajamarkkinoiden segmentointi	49
5.2	Asiakastietokannat ja tietokantamarkkinointi	52
5.3	Koneoppimisen hyödyntäminen asiakkaiden profiloinnissa	53
5.4	Asiakkaiden etsintä	55
5.5	Asiakkaan ja agentin merkityksellisiksi arvioidut ominaisuudet	56
5.6	Automaattiseen tietojen käsittelyyn perustuvan markkinoinnin rajoitteet	65
5.6.1	Henkilötietojen käsittely	65
5.6.2	Asiakkaiden profilointi	66
5.6.3	Automaattinen päätöksenteko	67
5.6.4	Automaattiseen tietojenkäsittelyyn perustuva markkinointi	68

6.	TOIMINNAN SUUNNITTELUTUTKIMUS	71
6.1	Ongelman määrittely	73
6.2	Rakentaminen, interventio ja evaluointi (RIE)	76
6.3	Reflektio- ja oppimisvaihe	79
6.4	Oppimisen formalisointivaihe	80
7.	PROFIILIEEN SUUNNITTELUPROSESSI	82
7.1	Ongelman määrittely	82
7.1.1	Tutkimusmahdollisuuden tunnistaminen ja käsitteellistäminen	82
7.1.2	Alustavien tutkimuskysymysten muodostaminen.	83
7.1.3	Tutkimusongelma kokonaisen ongelmia sisältävän luokan ilmentymänä.	84
7.1.4	Ongelmaan vaikuttava teoriaperusta ja aiempi teknologinen edistys.	84
7.1.5	Kohdeorganisaation pitkäaikainen sitoutuminen	85
7.1.6	Roolit ja vastuut.	85
7.2	Rakentaminen, interventio ja evaluointi	86
7.2.1	Tiedonluonti kohteen lopullinen selvittäminen.	86
7.2.2	RIE muodon valinta ja kustomointi.	87
7.2.3	RIE sykli(e)n toteutus.	88
7.2.3.1	Alpha -version suunnittelu	88
7.2.3.2	Alpha version evaluointi	91
7.2.3.3	Beta -version suunnittelu	93
7.2.3.4	Beta-version testaus sekä evaluointi	95
7.2.4	Mahdollisten lisäsyklien tarpeen arviointi ja niiden toistaminen.	95
7.2.5	Valmis artefakti	95
7.3	Reflektio- ja oppimisvaihe	97
7.3.1	Suunnittelun ja uudelleensuunnittelun reflektointi koko projektin ajan	97

7.3.2	Periaatteista kiinni pitämisen evaluointi	97
7.3.3	Interventiotuloksien analysointi määriteltyjen tavoitteiden mukaisesti	99
7.4	Oppimisen formalisointivaihe	100
7.4.1	Oppimisen abstrahointi konsepteiksi luokalle kenttäongelmia	100
7.4.2	Tuloksien ja tehtävien jakaminen käytännön toimijoiden kanssa	101
7.4.3	Tulosten viestiminen sanallisina suunnitteluperiaatteina	101
7.4.4	Oppimisen pukeminen sanoiksi valittujen teorioiden valossa	102
7.4.5	Tuloksien formalisointi levitystä varten	106
8.	<b>DISKUSSIO</b>	107
8.1	Tulosten arviointi ja suositukset	107
8.2	Tutkimuksen arviointi ja rajoitukset	109
8.3	Jatkotutkimusmahdollisuuksia	110
	<b>LÄHTEET</b>	111
	<b>LIITTEET</b>	117
	LIITE 1. Haastattelukysymykset Call Center -vastaavalle	117
	LIITE 2. Haastattelukysymykset tekniselle vastaavalle	119

## LYHENTEET JA TERMIT

DSR	Design Science Research, suunnittelutieteellinen tutkimus
ADR	Action Design Research, toiminnan suunnittelututkimus
EU	Euroopan Unioni
GDPR	General Data Protection Regulation, EU:n yleinen tietosuoja-asetus 2016/679
AI	Artificial Intelligence, tekoäly
ANI	Artificial Narrow Intelligence, kapea tekoäly
AGI	Artificial General Intelligence, yleinen tekoäly
ML	Machine Learning, koneoppiminen
DL	Deep Learning, syväoppiminen
ANN	Artificial Neural Network, keinotekoinen neuroverkko
ACPS	Agent Customer Pairing System, agentin ja asiakkaan paritusjärjestelmä
HITRATE	Osumatarkkuus, toteutuneet myyntitransaktiot jaettuna asiakaskontaktien määrällä.
ACORN	A Classification of Residential Neighbourhoods, asuinalueeseen perustuva kuluttajaluokitusjärjestelmä
RIE	Rakentaminen, Interventio ja Evaluointi, ADR metodin toisessa vaiheessa käytettävä sykli



# 1. JOHDANTO

## 1.1 Tutkimuksen aihe ja tavoite

*”Seuraavien vuosien aikana suurimmat hyödyt liiketoiminnassa tullaan kokemaan, kun oikea tieto saavuttaa oikeat ihmiset oikeaan aikaan. Se mitä olemme takavuosina saavuttaneet Business Intelligencen (BI) avulla, saa reilun kertoimen, kun koneoppiminen otetaan käyttöön. Datan järkevän käytön myötä toiminnanohjaus on tehokkaampaa, ja tuotanto ja palvelut seuraavat kysyntää aidosti.” (Merilehto 2018: 41)*

*”Päätökset, jotka vielä toistaiseksi ovat ihmisten vastuulla, hyötyvät merkittävästi siitä, että ongelmanratkaisun komponentit automatisoidaan ja päätöksenteon tueksi tuotetaan ajantasaista tietoa. Koneen ja ihmisen yhteistoiminta tulee auttamaan edelläkävijäyrityksiä saavuttamaan tavoitteet kilpailijoita nopeammin ja parantamaan markkina-asemaa” (Merilehto 2018: 42-43)*

Tutkimuksen aihealue, *koneoppimisen ja neuroverkkomenetelmien hyödyntäminen vahinkovakuutusyhtiön puhelinpalvelukeskuksen myyntiprosesseissa*, valikoitui niin vakuutusyhtiöissä, finanssialalla kuin yleisesti muuallakin yritysmaailmassa meneillään olevien, edellä olevissa lainauksissakin mainittujen, liiketoiminnan kehittämiseen tähtäävien trendien perusteella. Aihealue tulisi sopia hyvin kauppatieteen maisterin opinnoissa tietojärjestelmätieteen koulutusohjelman tutkimusaiheeksi koska se sisältää aspekteja niin liiketoiminnan kuin tietojärjestelmien näkökulmasta. Tutkijan koulutus, kokemus työskentelystä vakuutusyhtiössä sekä yleinen liikemaailmassa vallitseva, koneen ja ihmisen yhä kiihtyvän yhteistoiminnan lisääntymisen aiheuttama murros, vaikuttivat myös aiheen valintaan merkittävästi. (Merilehto 2018: 41-43)

Tutkimuksen varsinainen aihe liittyy laajempaan kohdeorganisaation projektiin, jonka tarkoituksena on selvittää nykyaikaisen tekoälyn, koneoppimisen ja erilaisten neuroverkkomenetelmien hyödyntämispotentiaalia vahinkovakuutusyhtiön yksityisasiakkaille suuntaamassa, puhelinpalvelukeskuksesta käsin suoritettavassa

asiakaspalvelussa ja myyntityössä. Tutkimus keskittyy erityisesti käyttötapaukseen, jossa vakuutusyhtiön kontaktoimia asiakkaita pyritään edellä mainittuja teknologioita hyödyntäen ohjaamaan automaattisesti, niin asiakkaan, kuin vakuutusyhtiön näkökannalta potentiaalisimmille vakuutusyhtiön edustajille.

Tutkimuksen tavoitteena on kehittää toiminnan suunnittelututkimukselliseen menetelmään pohjautuva artefakti, tässä tapauksessa listaus teorian tietoon pohjautuvista agenttien ja asiakkaiden ominaisuuksista, joita voidaan hyödyntää osana tekoälyohjatun ACPS (Agent Customer Pairing System) -järjestelmän agenttien ja asiakkaiden profilointia, parempien myyntitulosten saavuttamiseksi. Artefakti tulee kehittää niin että se huomioi EU:n yleisen tietosuoja-asetuksen (2016/679) sen käytölle mahdollisesti asettamat rajoitteet. Kohdeorganisaation tavoitteena on saada tutkimuksen kautta mahdollisesti uusia näkökulmia asiakkaiden ja agenttien profiloinnissa käytettävistä ominaisuuksista, joita tutkimuksessa pyritään erilaisten näkökulmien ja teorian tiedon valossa uuttamaan. Artefaktia on lisäksi tarkoitus testata tekoälyohjatulle sekä satunnaiselle ryhmälle suunnatulla testillä, joiden tuloksia verrataan keskenään. Mittarina testissä käytetään niin sanottua myynnin ”hitrate” -prosenttia, jossa toteutuneet myyntitransaktiot jaetaan asiakaskontaktien määrällä. (Tekninen vastaava 2020) Tuloksia arvioitaessa pyritään ensisijaisesti selvittämään, nostivatko teorian tiedon perusteella merkityksellisiksi arvioidut ja artefaktin Beta-versioon valikoituneet ominaisuudet myynnin hitratea. Lisäksi tutkimuksessa pyritään keräämään havaintoja sekä oppimaan asiakkaiden ja agenttien käyttäytymisestä, kuten esimerkiksi siitä mitkä yhdistelmät korreloivat ja resonoivat keskenään ja miksi? Tuloksia arvioitaessa pyritään myös etsimään parannus- ja kehityskohteita sekä kehittämään uusia mahdollisia sovellutuksia.

Tutkimusdokumentti koostuu johdannosta, teoriaosuudesta, profiilien suunnitteluprosessin kuvauksesta, tuloksista ja diskussiosta. Johdannossa kuvataan tutkimuksen tausta ja tavoitteet. Luvuissa kahdesta kuuteen käsitellään tutkimuksen taustalla vaikuttavat teoriat. Toisessa luvussa käsitellään vakuutustoimintaa ja tutkimuksen kohdeympäristöä. Kolmannessa luvussa käsitellään koneoppimista ja neuroverkkoja yleisesti, syvennyttään niiden tutkimuksen kannalta oleellisiin sovelluksiin lähemmin sekä käydään läpi ACPS-järjestelmässä käytettävät menetelmät. Neljännessä

luvussa käsitellään asiakkaan ostopäätöksen taustalla vaikuttavia tekijöitä. Viidennessä luvussa käsitellään asiakkaiden profilointia, pohditaan tutkimuskysymysten kannalta oleellisia ominaisuuksia sekä käydään läpi tietosuoja-asetuksen (2016/679) niiden käytölle asettamia rajoituksia. Kuudennessa luvussa käsitellään toiminnansuunnittelututkimusta ja sen eri vaiheita.

Seitsemännessä luvussa käsitellään tutkimusprosessin toteutusta, sen kulkua sekä tuloksia. Seitsemännessä luvussa esitellään myös lopulliset suunnitteluperiaatteet ja ratkaisut. Kahdeksas luku on diskussio, jossa arvioidaan tutkimusta, sen tuloksia ja niiden merkitystä, sekä käydään läpi mahdollisia jatkotutkimusmahdollisuuksia.

## 1.2 Tutkimusongelma ja tutkimuskysymykset

Tutkimusongelman määrittely sisältyy myöhemmin tutkimuksen teoriaosuudessa esiteltävään, toiminnan suunnittelututkimuksessa käytetyn ADR-metodin ensimmäisen vaiheen kahteen ensimmäiseen tehtävään; *Tutkimusmahdollisuuden tunnistamiseen ja käsitteellistämiseen* sekä *alustavien tutkimuskysymysten muodostamiseen*. (Sein ym. 2011: 40-41) Tutkimustehtävien ja ongelmien asettelussa on käytetty Hirsjärven, Remeksen ja Sajavaaran (2009: 126) Tutki ja kirjoita -teoksessa esitettyä lähestymistapaa, jossa muotoillaan aluksi pääongelma ja sitä analysoimalla jaetaan se useampiin osaongelmiin.

Tutkimuksen pääongelma 1. muotoiltiin seuraavasti: *Miten vahinkovakuutusyhtiön puhelinpalvelukeskus pystyisi neuroverkkoja ja koneoppimista hyödyntämällä ohjaamaan asiakkaitaan, niin asiakkaan kuin vakuutusyhtiönkin näkökulmasta potentiaalisimmille agenteille?*

Osaongelmat jaettiin seuraavasti: 1.1. *Miten asiakkaat ja vakuutusyhtiöin edustajat profiloitetaan ja kategorisoidaan?* 1.2 *Mitä tietoja asiakkaista ja edustajista on saatavilla ja mitä niistä voidaan käyttää?* 1.3. *Millainen tieto pitäisi teoriaan pohjautuen olla merkityksellistä tavoitteen toteutumisen kannalta?* 1.4 *Kuinka paljon parempiin*

*myyntituloksiin (hitraste%) päästään löydettyjä ominaisuuksia käyttävällä, tekoälyohjatulla agentti–asiakas parituksella?*

### 1.3 Tutkimusmenetelmät ja -aineisto

Koska tutkimusongelma sijaitsee todellisessa kohdeympäristössä, kohdeyrityksen Call Center -keskuksessa, ja koska siihen liittyvät IT-artefaktin kehittäminen haluttiin tehdä tiiviissä yhteistyössä kohdeorganisaation kanssa, päädyttiin tutkimuksessa käyttämään toiminnan *suunnittelututkimuksellista lähestymistapaa*. Tutkimuksen teoreettisen osan muodostaa *vakuutustoimintaa, tekoälyä, koneoppimista, neuroverkkoja, myyntiä, markkinointia, asiakkaiden ja myyjien profilointia* sekä *tietosuojalainsäädäntöä* käsittelevä koti- ja ulkomainen kirjallisuus sekä tutkimusaineisto. Tutkimuksen empiirisenä, tutkimusympäristöstä kerättävänä aineistona toimii teemahaastatteluin kerätty aineisto sekä artefaktille suoritettavasta testistä saadut tulokset.

Tutkimuksen tavoitteena on tuottaa tietoa tutkimusongelman ratkaisemiseen tähtäävien käytäntöjen suunnitteluun ja ohjaamiseen tavalla, jossa tutkimusympäristön todellisuus ilmenee osana tutkimusprosessia. Tutkimusmetodina päädyttiin täten käyttämään Seinin, Hendfridssonin, Puraon, Rossin ja Lindgrenin (2011) kehittämää ADR-metodia, joka valikoitui parhaan soveltuvuutensa takia tutkimusta ohjaavaksi menetelmäksi. (Sein ym. 2011: 40-45)

Tutkimuksen empiirinen aineistonkeruu päätettiin suorittaa kvalitatiivisin eli laadullisin tutkimusmenetelmin. (Hirsjärvi ym. 2009: 204-220) Kvalitatiivisen menetelmän todettiin soveltuvan parhaiten eritoten Hevnerin ym. (2004: 80) tietojärjestelmätutkimuksen viitekehyksessä mainittujen liiketoiminnan tarpeiden selvittämisessä, sekä Seinin ym. kehittämän ADR-metodin ensimmäisen vaiheen ensimmäistä periaatetta (käytännön inspiroiva tutkimus) noudattavassa käytännön ongelmiin liittyvien ja myöhemmin kokonaiseen ongelmien luokkaan, liittyvien tutkimusmahdollisuuksien hahmottamisessa. (Sein ym. 2011: 40) Tutkimusongelman sijaitessa todellisessa kohdeympäristössä, koettiin tutkimuksen kannalta tarpeelliseksi kerätä relevanttia tietoa sen aiheeseen

liittyvästä ympäristöstä sekä sen artefaktille asettamista vaatimuksista. Tutkimuksen kannalta oli kiinnostavaa saada erityisesti kokemuskohtaista tietoa ympäristön tämänhetkisestä yleisestä toiminnasta ja vallalla olevista käytännöistä, jotta tekoälyohjattua järjestelmää varten luotavan artefaktin kehitystyö tapahtuisi mahdollisimman aidossa, pragmaattiseen tietoon nojaavassa viitekehyksessä. (Hirsjärvi 2008: 156-160; Tiainen ym. 2015: 11; Järvinen 2018: 106) Tutkimuksen kannalta oli myös tärkeää saada tarkkaa tietoa tutkimusympäristön raameista, kuten organisaatorakenteesta, käytettävissä olevasta tiedosta, järjestelmistä ja muista käytännön seikoista. Koska tutkimusmahdollisuudet haluttiin kartoittaa käytännön lähtökohdista, valikoitui tiedonkeruumetodiksi teemahaastattelu. (Hirsjärvi 2008: 202-207)

Tutkimuksen kvalitatiivinen osa koostuu kahdesta linjasta teemahaastatteluita, joista toisessa kerätään aineistoa Call Center ympäristöstä ja toisessa teknisestä ympäristöstä. Koska tutkijalla oli valmiina tiettyjä aiheeseen liittyviä spesifejä kysymyksiä, mutta toisaalta aihetta ei haluttu lukita liiaksi, päädyttiin tutkimuksen molemmissa teemahaastattelulinjoissa käyttämään puolistrukturoitua rakennetta. (Hirsjärvi 2008: 202-207) Haastattelut päätettiin tehdä kasvotusten, kohdeyrityksen toimitiloissa. Koska tiedonkeruun fokus oli osittain ympäristön objektiivisissa raameissa ja osittain vakuutusyhtiön edustajien subjektiivisessa käytännön kokemuksessa, käytettiin haastattelussa avoimia kysymyksiä. Haastattelut kirjataan myöhempää analyysia varten.

Haastattelujen analyysivaiheeseen valittiin lähestymiskulma, jossa tutkija pyrkii ymmärtämään haastateltujen näkökannat, vertailemaan niitä teoriaan ja tekemään niihin perustuvia johtopäätöksiä. (Hirsjärvi 2008: 193-194; 202-207; 217-225) (Hevner 2004: 80) Kyseisen metodin luetettavuus ei ole kovin korkea koska se keskittyy yksittäisen haastateltavan kokemukseen tietyissä olosuhteissa, tietyinä aikana. Tulokset eivät tästä syystä ole kovin hyvin toistettavia. Yksilöllisissä puolistrukturoiduissa haastatteluissa haastattelutapahtuma, haastateltavan tunnetila ja lukuisat muut seikat voivat vaikuttaa lopputulemaan. Kerätty tieto voi näin ollen sisältää mielipiteitä ja muita seikkoja, jotka voivat vaihdella eri olosuhteissa. Kyseinen metodi pitäisi kuitenkin olla validi ja palvelu tarkoitusiaan koska suunnittelutoimintatutkimukseen pohjautuva artefakti rakennetaan

joka tapauksessa osittain todellisessa spesifissä ympäristössä havaittujen ongelmien pohjalta, jonka tilasta paras tieto löytyy siellä toimivilta yksilöiltä. Teemahaastattelun matala luotettavuus tulee ottaa huomioon artefaktia kehitettäessä ja siksi haastattelutietoa tulee aina verrata ja analysoida suhteessa muuhun teorian tietoon. (Hirsjärvi 2008: 226-228)

## 2. VAKUUTUSTOIMINTA

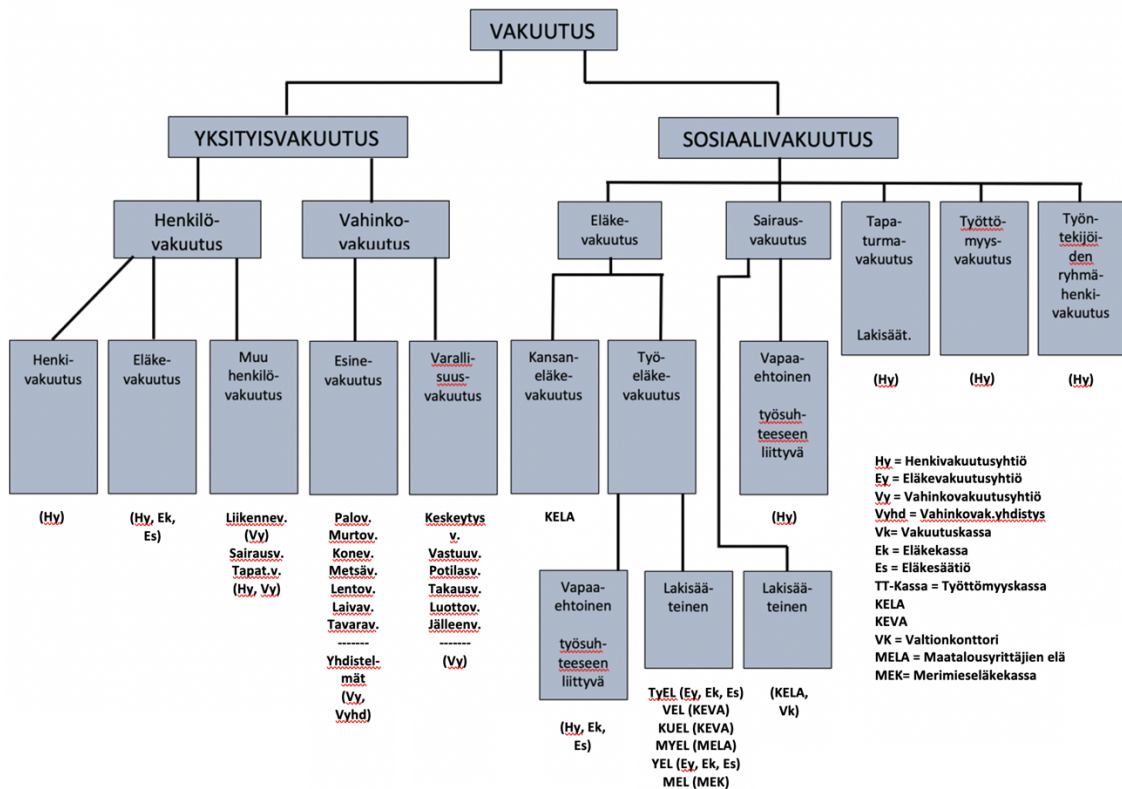
Niin liikeyritysten toimintaan kuin yksityisten ihmisten elämään liittyy monenlaisia epävarmuus- ja vaaratekijöitä. Näitä edellä mainittuja vahingonvaaroja kutsutaan vakuutusalan sisäisessä kielessä *riskeiksi*. Esimerkkejä yritystoimintaa uhkaavista riskeistä voi olla vaikkapa toimitilassa tapahtuva tulipalo tai liiketoiminnan keskeytyksen aiheuttava tuotantokoneen rikko, yksityishenkilöiden riskien liittyessä taas tilanteisiin kuten sairastuminen, kodin tulipalo tai autokolari. (Rantala ym. 2018: 61-62)

*Vakuutustoiminta* perustuu ideaan riskien uhkaamien yhteisöiden tai henkilöiden sopimuksesta niiden aiheuttamien vastuiden yhteiseksi tasaamiseksi ja kantamiseksi. Esimerkkinä ajatuksen taustalla voisi toimia tilanne, jossa rajattu ryhmä kiinteistönomistajia sopivat keskenään, että tulipalon sattuessa kenelle tahansa heistä syntynyt vahinko tasataan kustannettavaksi yhteisesti, vaikkapa samassa suhteessa omaisuusarvojen kanssa. Kullekin korvattavaksi tuleva osuus vahingosta jää tällöin yleensä siedettäväksi, korvauksen saajan vältyessä vahingon ylenpalttisilta seuraamuksilta. *Vakuutus* ja *vakuutustoiminta* saivat yleiset nimityksensä, kun vahingon varalle kerättäviä varoja alettiin kerätä ennakolta ”rahastoiksi”, joista vahingonkorvaus pystyttiin maksamaan välittömästi. Laitosta, joka perustettiin varojen kokoamista ja vahinkojen maksamista varten alettiin nimittää myöhemmin *vakuutuslaitokseksi*. Vakuutuksen toimintaperiaate nykymuodossaan on käytännössä tilanne, jossa vakuutuslaitos kerää *vakuutusmaksua* kaikista *vakuutuskohteistaan*, jolloin kertyneitä varoja käytetään harvojen joissain tapauksissa erittäin suurtenkin vahinkojen korvaamiseen. (Rantala ym. 2018: 69-71)

### 2.1 Vakuutus

Suomalaisen vakuutustoiminnan perinteinen jaottelu perustuu lainsäädännössä määriteltyihin vakuutusalan keskeisimpiin käsitteisiin, EU-direktiiveihin sekä alan yleiseen käytäntöön. Vakuutus -käsite jaetaan siinä kahteen alaluokkaan, *yksityis-* ja *sosiaalivakuutuksiin*, jotka jakautuvat edelleen lukuisiin eri aliluokkiinsa.

*Yksityisvakuutus* pohjautuu *vakuutuksenantajan* ja *vakuutuksenottajan* keskenään solmimiin sopimuksiin. Niiden sisältöä ei ohjata ja valvota laeilla, lukuun ottamatta niitä koskevia yleisiä määräyksiä. Esimerkkejä yksityisvakuutuksista ovat henki- tai esinevakuutus. Sosiaalivakuutus taas perustuu lainsäädäntöön tai vähintäänkin sen toimintaa ohjaillaan laein. Esimerkkejä sosiaalivakuutuksista ovat lakisääteiset tapaturmavakuutukset tai työeläkevakuutus. Rantala ja Kivisaari avaavat teoksessaan ”Vakuutusoppi” (2014: 81) Suomessa perinteisesti käytetyn jaotellun alla olevassa kuvassa.



**Kuva 1.** Vakuutusten ja vakuutuslaitosten jaottelu suomessa (Rantala ym. 2014: 81)




## 2.2 Vakuutusyhtiö

Vakuutuslaitostyyppit jakautuvat *vakuutusyhtiöihin, vakuutusyhdistyksiin, eläkesäätiöihin ja -kassoihin, muihin vakuutuskassoihin, ulkomaisiin vakuutuslaitoksiin sekä lailla perustettuihin vakuutuslaitoksiin.* (Rantala ym. 2014: 210)

*Vakuutusyhtiöt* ovat vakuutuslaitoksia, joiden perustamisesta, järjestysmuodosta ja toiminnan peruslinjoista on säädetty vakuutusyhtiölaissa (VYL 521/2008), jossa säännellään vahinko-, henki ja jälleenvakuutusyhtiöiden toimintaa. Vakuutusyhtiölain mukaan suomalainen vakuutusyhtiö voi olla yhtiömuodoltaan joko *keskinäinen vakuutusyhtiö* tai *vakuutusosakeyhtiö*, joihin molempiin sovelletaan myös osittain, joko suoraan tai välillisesti, osakeyhtiölain (OYL 624/2006) säännöksiä. (Rantala ym. 2014: 210)

Vakuutusyhtiön omistajina toimivat sen osakkaat, keskinäisen vakuutusyhtiön osakkaiden ollessa vakuutuksenottajat ja vakuutusosakeyhtiön osakkaiden taas ollessa osakkeenomistajat. Keskinäisen vakuutusyhtiön ollessa hallinnolliselta rakenteeltaan lähellä osuustoiminnallisia laitoksia, on vakuutusosakeyhtiö taas oikeudelliselta rakenteeltaan normaalien osakeyhtiöiden kaltainen. (Rantala ym. 2014: 211)

Suomalaisilla vakuutusmarkkinoilla toimivat suurimmat vakuutusyhtiöt on jaoteltu alla niiden 2018 markkinaosuuksien mukaan (Finanssiala Ry 2014: 8)



**Kuva 2.** Suomessa 2018 toimivat vakuutusyhtiöt markkinaosuuksien mukaan (Finanssiala Ry 2018: 8)

### 2.3 Vakuutustuotteiden myynti

Vakuutustuotteiden myyntiä tapahtuu Suomessa vakuutusyhtiöiden omien jakelukanavien, kuten sähköisten kanavien, puhelinpalvelukeskuksista suoritettavan etämyynnin ja myyntikonttorien, sekä lukuisten muiden eri toimijoiden kautta. Vakuutustuotteiden myynnissä on huomioitava vakuutussopimukseen vaikuttavat yleiset lait kuten kuluttajalainsäädäntö, vahingonkorvausoikeuden johtavat periaatteet, laki vakuutusedustuksesta (570/2005) sekä suuri määrä muita lakeja. Lisäksi on huomioitava vakuutussopimuslain asettamat vaatimukset, kuten lait vakuutuksen voimaantulosta tai vakuutuksenantajan tiedonantovelvollisuudesta. (Rantala ym. 2014: 213-2014)

Lähes kaikki erityyppiset vakuutuksia tarjoavat toimijat, kuten *meklarit*, *asiamiehet*, *vakuutusyrietykset* *kaikkine jakelukanavineen*, *vakuutusedustusta harjoittavat pankit*, *matkatoimistot* ja *autovuokraamot* kuuluvat nykyisin Euroopan parlamentin ja neuvoston vakuutusten tarjoamisesta (EU 2016/97) säätämän direktiivin soveltamisalaan. Tämä niin

kutsuttu IDD (Insurance Distribution Directive) -direktiivi tuli voimaan 23.2.2016 ja sen soveltaminen alkoi 1.10.2018. Direktiivillä pyritään vakuutusten ja jälleenvakuutusten tarjoamista koskevien, eri EU-jäsenvaltioiden kansallisten säännöksiä vähimmäistason yhdenmukaistamiseen, niin että se ei kuitenkaan estä jäsenvaltioita ottamasta käyttöön sitäkin tiukempia kuluttajien suojaamiseksi tähtääviä säännöksiä. (Finanssivalvonta 2019; Rantala 2014: 214)

Laissa vakuutusedustuksesta säädetään jaosta *asiamiesten ja vakuutusmeklarien* välillä. Asiamiehen päämiehenä toimii vakuutusyhtiö, asiamiehen kuuluessa näin ollen vakuutusyhtiön myyntiverkostoon. Tällöin Vakuutusyhtiö vastaa asiamiehen toiminnasta. Vakuutusmeklarin päämiehenä toimii taas asiakas, jolloin vakuutusmeklari on itse vastuussa toiminnastaan suhteessa asiakkaaseen. Vakuutusmeklarin saadessa palkkion asiakkaaltaan ja asiamiehen vakuutusyhtiöltä, katsotaan meklarin olevan näin ollen asiakkaan palveluksessa, asiamiehen taas palvellessa vakuutusyhtiötä. (Rantala ym. 2014: 213; 308-319; 320-344)

## 2.4 Vakuutusyhtiön puhelinpalvelukeskus

Vakuutusyhtiön puhelinpalvelukeskusta kuvaavassa osiossa käytettiin kohdeorganisaation puhelinpalvelukeskuksen toiminnasta vastaavalta henkilöltä teemahaastattelussa saatuja tietoja organisaation yleisestä toiminnasta. Kuvatut käytännöt ovat tietyssä määrin organisaatiospesifejä mutta suurelta osin myös yleistettävissä vakuutusyhtiöiden puhelinpalvelukeskuksiin yleisesti. (Kotler ym. 2016: 435-436)

### 2.4.1 Puhelinpalvelukeskuksen agentti ja asiakas

Puhelinpalvelukeskus on vahinkovakuutusyhtiön puhelimitse tarjottavasta asiakaspalvelusta sekä puhelimitse tehdystä myynnistä vastaava osa. Puhelinpalvelukeskuksen puhelinpalvelutyötä suorittavia työntekijöitä kutsutaan yleisesti *agenteiksi* ja riippuen tarkemmasta tehtävänkuvasta myös esimerkiksi *myyjiksi* tai

*asiakaspalvelijoiksi.* Puhelinpalvelukeskus palvelee yleisesti kahdenlaisia asiakasryhmiä. *Ensimmäinen ryhmä* koostuu asiakkaista, jotka soittavat itse vakuutusyhtiön palvelunumeroon ilmoittaakseen vahingosta, tehdäkseen muutoksia olemassa oleviin vakuutuksiin, hankkiakseen uusia vakuutuksia tai kysyäkseen tietoja vakuutuksista. Vakuutusyhtiöön itse yhteydessä olevien asiakkaiden palvelemiseen tarkoitettua puhelinpalvelukeskuksen osaa kutsutaan *inboundiksi*. *Toinen asiakasryhmä* koostuu asiakkaista, joihin ollaan yhteydessä vakuutusyhtiön puhelinpalvelukeskuksesta käsin. Tätä vakuutusyhtiön puhelinpalvelukeskuksen osaa kutsutaan *outboundiksi*. Puhelinpalvelukeskuksen erillisenä osana toimii myös *korvauspalvelu*, jonka tarkoituksena on vastaanottaa vakuutuskorvauksiin liittyviä ilmoituksia ja muita yhteydenottoja. (Call Center vastaava 2020)

#### 2.4.2 Inbound

*Inbound* on puhelinpalvelukeskuksen osa, joka ottaa vastaan asiakkaiden puheluita ja hoitaa näin ollen vakuutusyhtiöön yhteydessä olevien asiakkaiden vakuutuksiin liittyviä asioita. Tällaisia asioita ovat yleisimmin erilaiset laskutukseen, päättämisiin tai muihin vakuutuksia koskeviin selvityksiin liittyvät asiat. Vakuutusasioiden hoidon yhteydessä inboundissa pyritään tekemään usein myös *lisämyyntiä* eli olemassa olevien ratkaisujen laajennoksia sekä niin kutsuttua *ristiin myyntiä*, eli uusien vakuutuslajien myyntiä, hoidettavien asioiden yhteydessä. (Call Center vastaava 2020)

#### 2.4.3 Outbound

*Outbound* on puhelinpalvelukeskuksen osa, josta soitetaan asiakkaille päin ja joka keskittyy lähes yksinomaan myyntityöhön. Yhteydenotoilla voidaan tavoitella joko *lisämyyntiä* olemassa oleviin asiakuuksiin tai kokonaan uusia asiakkaita. *Lisämyyntiä* tekevien ryhmien kohteilla on olemassa joku vakuutus kohdeyhtiössä. Pääsääntöisesti *lisämyyntikohderyhmissä* asiakas on tullut hiljattain kohdeorganisaation asiakkaaksi jossain tuotekategoriassa. Tyypillisiä esimerkkejä tästä on autoliikkeestä, verkkokaupasta

tai inboundista asiakkaan itse hankkima yksittäinen vakuutus. Outbound soittaa yleensä tällaisille asiakkaille pikaisesti myydäkseen myös muita kokonaistarjoaman ratkaisuja. (Call Center vastaava 2020)

Outboundin yhteydenotot liittyvät useimmiten erilaisiin indikaatioihin, jotka viittaavat kontaktoitavien asiakkaiden uuteen vakuutustarpeeseen, tai sen muuttumiseen. Tällaisia indikaatioita voivat olla vaikkapa ajoneuvon vaihto, muutto, lapsen syntymä, kesken jäänyt ostos vakuutusyhtiön verkkokaupassa tai joku muu vastaava uuteen vakuutustarpeeseen tai sen muutokseen viittaava tekijä. Indikaatiotietoja ajankohtaisista tapahtumista kerätään eri lähteistä. Esimerkiksi tieto muutosta voidaan saada postin tai maistraatin kautta asiakkaan tehtyä ennakoilmoituksen, tai muuta kautta tullessa tietona osoitteen muutoksesta. Indikaationa voi toimia myös vaikkapa vakuutuskantaan tullut uusi autovakuutus tai tieto asiakkaasta, joka on jättänyt verkkokaupassa jonkin oston kesken, jolloin pystytään myös etukäteen näkemään minkälaisen tuotteen ostamista, asiakas on suunnitellut. (Call Center vastaava 2020)

Asiakkaita kontaktoidaan joko yksittäin, yksittäisten indikaatioiden johdosta, tai useimmiten joukoittain erilaisten kampanjoiden muodossa. Tietyille asiakasjoukolle suunnattu kampanja voi liittyä erilaisiin ajankohtaisiin aiheisiin, kuten vaikkapa venevakuutuksiin, jolloin niiden hankkimiseen otollisena aikana kontaktoidaan erikseen kerätty joukko asiakkaita, jotka vakuutusyhtiön hankkimien tietojen mukaan omistaa veneen. (Call Center vastaava 2020)

Outboundin toimintaa voidaan organisoida yleisesti monin erilaisin tavoin. Kohdeorganisaatiossa outboundin myyntivoima piti haastatteluhetkellä sisällään 95 henkilöä, jotka jakautuivat 8 tiimiin. Kaikki outboundissa työskentelevät agentit tekivät proaktiivista myyntiä, seitsemän 15 hengen tiimin keskittyessä lisämyynnin tekemiseen ja yhden 15 hengen tiimin keskittyessä uusmyyntiin. Jokaisella myyntitiimillä oli lisäksi esimies (yhteensä 8), jotka vastasivat omien tiimiensä toiminnasta. Aikaisemmin kohdeorganisaation outboundin agenteilla on ollut myös erikoistuneita tehtäviä. Viimeisen kahden vuoden aikana kohdeorganisaatiossa on kuitenkin siirrytty pääsääntöisesti niin kutsuttuun *generalistimalliin*, jossa seitsemän lisämyyntiä tekevän

tiimin kohteet tulevat kaikki samasta kohdeorganisaation omia asiakkaita sisältävästä jonosta ja yhden uusasiakashankintaa tekevän tiimin soittokohteet jonosta, joka sisältää yhteistyötahona toimivan pankin soittopyyntöjä sekä muita uusmyyntikohteita. Välillä kohdeorganisaatiossa soitetaan kampanjan muodossa myös vuodenaikasidonnaisia kohteita, kuten moottoripyörä-, vene- tai muita taktisia asiakasryhmiä. Tällaisiin soittokampanjoihin saatetaan, poiketen generalistimallista, kerätä tilanteen mukaan oma taktinen soittoryhmä, niin että esimerkiksi sellaiset agentit, jotka ovat kiinnostuneita veneistä, soittavat kyseiselle asiakasryhmälle. (Call Center vastaava 2020)

Tällaisilla taktiikoilla on käytännössä havaittu saatavan hyviä tuloksia. Tällaista niin kutsuttua *iskuryhmää* oli käytetty muun muassa potentiaalisille omakotitaloasiakkaille suunnatussa kampanjassa, joilla osoitteen perusteella oli tulkittu olevan omakotitalo, joka ei kuitenkaan ole vakuutettu kohdeorganisaatiossa. Soittokampanjaa varten oli kaksi kertaa koottu 15 hengen oma agenttiryhmä, joka oli ennakkoon saanut erityistä valmennusta, koulutusta ja tukea myyntitehtävän suorittamista varten. Kokemukset myynnin hitraten suhteen olivat näiden ryhmien käytön osalta hyviä. (Call Center vastaava 2020)

Toinen esimerkki vastaavanlaisesta agenttiryhmien käytöstä löytyi vuodelta 2019, jolloin keväällä soitettiin potentiaalisten veneasiakkaiden ryhmä läpi kaikkien toimesta. Syksyllä samaan tehtävään päätettiin kerätä edellä mainitun kaltainen 10 hengen vapaaehtoisuuteen perustuva ryhmä, jossa tärkeimpänä agenteja yhdistävänä ominaisuutena oli kiinnostus veneilyä kohtaan. Ryhmää myös valmennettiin erikseen tehtävää varten. Syksyn 10 hengen ryhmän myynnin tehokkuuden havaittiin olevan noin tuplasti parempi kuin kevään ryhmässä. (Call Center vastaava 2020)

Kohdeorganisaatiossa on myös tehty myynnin tehokkuuteen liittyviä kokemuspohjaisia havaintoja erilaisten *agentti-asiakas* yhdistelmien toimivuudesta. On muun muassa yleisesti havaittu, että naisen soittaessa miehelle, ja toisin päin, myynnin tehokkuus on usein parempi. Myös pitemmän elämäkokemuksen omaavien agenttien on havaittu olevan keskimäärin parempia myymään laajoja henkilöturvia. Näistä havainnosta ei ole kuitenkaan virallisia mittauksia. (Call Center vastaava 2020)

Agenttien personointiin tai muihinkaan ominaisuuksiin liittyvää profilointia ei kohdeorganisaatiossa ole tehty asiakastyötä varten. Niin kutsuttu *Disc analyysi* (Discprofiili 2019) on tehty muutamalle tiimille, sen liittyessä kuitenkin enemmän sisäisen toiminnan ja ryhmädynamiikan parantamiseen, sekä ymmärryksen lisäämiseen siitä että ihmiset ovat erilaisia. Tätä ei ole kuitenkaan pyritty hyödyntämään kohdeohjauksessa resurssienkin puutteen vuoksi.

Ajatuksia niin asiakkaiden kuin agenttienkin profiloinnista on outboundissa käyty kohdeorganisaatiossa läpi, mutta mitään konkreettisia, suurempia toimenpiteitä asian suhteen ei ole tehty. Kohdeorganisaatiossa on esimerkiksi pohdittu, että koska erilaiset ammattiliitot kuten Ekonomiliitto, Insinööriiliitto tai Tehy sisältävät ehkä keskimäärin profiililtaan samankaltaisia ihmisiä, kuitenkin huomioiden, että ryhmät pitävät sisällään myös hyvin erilaisia ihmisiä, voisiko ammattiliittotieto toimia yhtenä asiakkaiden profiilia kartoittavana ominaisuutena. Toiveena outboundista vastaavalla esimiehellä oli, että agenteja pystyttäisiin profiloimaan myös esimerkiksi tuoteryhmäkohtaisesti. Parhaiden myyjien on useimmiten havaittu olevan parhaita myyjiä kaikessa, mutta tästä voisi olla apua eritoten ala- ja keskikastin myyntitulosten parantamisessa. (Call Center vastaava 2020)

Asiakkaiden profilointia tehdään tällä hetkellä kohdeorganisaatiossa ainoastaan CRM osastolla, jonka kautta Outboundiin tulee valmiita soittolistoja, usein erilaisten kampanjoiden muodossa. CRM osaston ottaessa soittolistoille niin sanottuja geneerisesti poimittuja kohteita, on kohdeorganisaation CRM osastolla käytössä pisteytysjärjestelmä, joka perustuu lukuisiin asiakkaiden ominaisuuksiin ja muihin kriteereihin. Pisteytys mittaa asiakkaiden ostopotentiaalia muun muassa eri tuoteryhmissä. Soittolistat ladataan CRM osastolta automaattipuhelinkoneelle, joka tällä hetkellä jakaa soittokohteet vapaille agenteille täysin sattumanvaraisesti. (Call Center vastaava 2020)

#### 2.4.4 Puhelinpalvelukeskuksen kautta myytävät tuotteet ja tuoteryhmät

Vakuutusyhtiön kotisivuilla henkilöasiakkaille suunnatut vakuutukset jakautuvat viiteen tuotekategoriaan: *Koti ja omaisuus-, ajoneuvot-, matka-, henkilö- ja eläinvakuutuksiin.* (IF 2020) Tuotekategoriat taas pitävät sisällään lukuisia eri vakuutuksia, joista tärkeimmät lueteltuna alla esitettyssä taulukossa:

**Taulukko 1.** Tärkeimmät tuotekategoriat ja niihin sisältyvät vakuutukset (IF 2020)

Tuotekategoria	Vakuutukset
Koti- ja omaisuus	kerrostalo, rivitalo, omakotitalo, paritalo, erillistalo, mökki, sijoitusasunto, metsä, vene, nuorisopaketti (irtaimistovakuutus kodin yhteydessä)
Ajoneuvot	henkilöauto, pakettiauto, moottoripyörä, mopo, matkailuauto, matkailuvaunu, moottorikelkka, mönkijä, perävaunu, vene, traktori, kuorma-auto, museoajoneuvo, muut moottoriajoneuvot
Matka	matkavakuutus
Henkilöt	vauvavakuutus (raskaus), lapsivakuutus (7vrk – 14 v), sairaus ja tapaturmavakuutus (aikuinen), henkivakuutus, vakavan sairauden turva, urheiluvakuutus, nuorisopaketti (18 – 28 v.)
Eläimet	koira, kissa, hevonen

Vaikka tuotekategoriat ja niiden sisältämät vakuutukset voivat poiketa vakuutusyhtiöiden kesken jokseenkin toisistaan, ovat ne pääpiirteissään samankaltaisia toistensa kanssa. Edellä kuvatun lainen tuotteiden kategorisointi on myös kohdeorganisaation puhelinpalvelukeskuksen käytössä ja sieltä myös myydään kaikkia eri kategorioiden sisältämiä tuotteita. (Call Center vastaava 2020)



### 3. TEKOÄLY, KONEOPPIMINEN JA NEUROVERKOT

Antti Merilehto kuvaa kirjassaan *”Tekoäly. Matkaopas johtajalle”* tekoälyn olevan:

*”...koneen suorittamaa toimintaa, joka ihmisen tekemänä olisi älykästä. Tekoäly ei kuitenkaan rajoitu ihmisen tasoon. Toimintoja ovat muun muassa päättely, oppiminen, ennakointi, päätöksenteko, näkö ja kuulo”* (Merilehto 2018: 18)

*Koneoppiminen* ja oppimiseen tähtäävät, ihmisaivojen toimintamalleja jäljittelevät *neuroverkot* ovat merkittäviä ja olennaisia laajemman kokonaisuuden eli *tekoälyn* komponentteja. Yksi älykään järjestelmän keskeisimmistä tunnusmerkeistä on sen kyky oppia ja sopeutua sekä toimia itsenäisesti ja älykkäästi muuttuvassa ympäristössä, mistä syystä koneoppiminen ja keinotekoiset neuroverkot integroituvat tekoälyn toimintaan olennaisella tavalla. (Alpaydin 2014: 3; Merilehto 2018: 47)

Tekoälyä pyrittiin alun perin kehittämään sellaiseksi, että se tuottaisi ihmisen tavoin päätteleviä ja ajattelevia koneita. Tällaisen kaiken kattavan tekoälyn, eli AGI:n (Artificial General Intelligence) kehittämisen osoittaututtua äärimmäisen haasteelliseksi ja tähän päiväänkin mennessä saavuttamattomaksi tehtäväksi, ovat tutkijat suuntautuneet voimakkaammin niin kutsutun *kapean älykkyyden* eli kapeiden ongelmien ratkaisuun tähtäävän tekoälyn, eli ANI:n (Artificial Narrow Intelligence) kehittämiseen. ANI on tekoälyä, *joka suoriutuu sille määritellyistä yksittäisistä tehtävistä varsin hyvin, mutta on kykenemätön laajentamaan osaamistaan muille aloille.* (Merilehto 2018: 23)

Yhtenä esimerkkinä tällaisista rajatuista, mutta samalla äärimmäisen tärkeänä pidetyistä tekoälyn ja koneoppimisen tutkimusalueista mainittakoon erilaiset pelit, kuten esimerkiksi shakki, joka sisältää ainoastaan pienen määrän sääntöjä mutta toisaalla suuren määrän mahdollisia siirtoja eri tilanteissa. Tämän kaltaisten pelien kuvaaminen on helppoa mutta toisaalla niiden pelaaminen menestyksekkäästi saattaa olla hyvinkin haastavaa. Peleihin onnistuneesti kehitettyjä algoritmeja on usein mahdollista hyödyntää myös liiketoiminnallisissa sovelluksissa. Tästä syystä koneoppimissovellusten kehittämisen, pelien pelaamaan oppimisen yhteydessä, voidaan nähdä äärimmäisen

hyödyllisenä testikenttänä niin sanottujen todellisessa maailmassa sijaitsevien ongelmien ratkaisemiseen. (Alpaydin 2014: 13)

### 3.1 Koneoppiminen

Menneisyudessa lähinnä yritykset sekä muut niiden kaltaiset organisaatiot tuottivat, pitivät hallussaan ja käsittelivät dataa tietokonekeskuksissaan. Henkilökohtaisten tietokoneiden, tietoverkkojen, internetin sekä myöhemmin erilaisten langattomien teknologioiden myötä suuresta osasta globaalia väestöä on tullut datan tuottajia ja kuluttajia. Koska lähes kaikki nykyaikainen sähköinen kommunikaatio tuottaa dataa, muodostuu ja tallentuu sitä jatkuvasti erilaisiin datavarastoihin suunnattomia määriä. Esimerkiksi markkinoiden näkökulmasta dataa tuottavat valtavia määriä päivittäin pelkästään asiakkaiden ja yritysten väliset transaktiot. Sekä yritykset, että asiakkaat hyödyntävät muodostunutta dataa; yritykset tyypillisesti myynnin ja voittojen kasvattamiseen, asiakkaat tarpeidensa tyydyttävien tuotteiden ja palveluiden löytämiseen. Olemassa olevan tiedon hyödyntäminen vaatii erilaisten säännönmukaisuuksien ja kaavojen löytämistä käsillä olevasta datasta. Mikäli tehtävään käytetään tietokonetta, vaatii se ongelman ratkaistakseen *algoritmin*, ketjun ohjeita, jotka suorittamalla se kykenee muuttamaan niin sanotun *syöteen* (Input) käyttökelpoisessa muodossa olevaksi *tulosteeksi* (Output). Yksinkertaisimmillaan tällainen voi tarkoittaa vaikkapa syötetyn tiedon järjestämistä tai jäsentämistä paremmin hyödynnettävään muotoon. (Alpaydin 2014: 1-2)

Perinteisessä tietojenkäsittelyssä algoritmin kehittäjänä toimii ihminen. Joidenkin ongelmien ratkaisuun liittyvissä tapauksissa valmista algoritmia ei kuitenkaan välttämättä ole saatavilla ja sen kehittäminenkin voi olla äärimmäisen hankalaa tai mahdotonta, joista esimerkkeinä Alpaydin (2014: 2) mainitsee asiakkaiden käyttäytymisen ennustamisen tai roskapostien erottelun aidoista. Tällaisissa tapauksissa tiedetään syöte ja haluttu tavoitetuloste mutta ei tapaa, jolla syöte saadaan muutettua tulosteeksi. *Koneoppiminen* (Machine Learning) on tekniikka, jossa kone valjastetaan määrittämään suuren syötedatamäärän perusteella algoritmi tehtävän suorittamiseksi. Koneoppiminen soveltuu

tästä syystä lukuisiin tapauksiin, joista on olemassa paljon dataa mutta ei algoritmia. Prosessille on tällöin usein ominaista, että se ei välttämättä ole täysin tunnistettavissa tai sen tulos selitä kaikkea, mutta mahdollistaa kuitenkin ”hyvän ja käyttökelpoisen approksimaation rakentamisen käsillä olevasta tapauksesta.” (Alpaydin 2014: 2) Alpaydinin mukaan koneoppimisen niin sanottu *niche*, onkin juuri näiden tiettyjen prosessia ymmärtämään auttavien kaavojen ja säännöllisyyksien tunnistamisessa (pattern recognition) sekä sen hyväksikäytössä erilaisten ennusteiden tekemiseen. Esimerkkinä tällaisista koneoppimisen sovellutuksista käyvät vaikkapa puheen tai kasvojen koneellinen tunnistus. (Alpaydin 2014: 3)

Koneoppimisen soveltamista suuriin tietokantoihin kutsutaan *tiedonlouhinnaksi* (data mining), jossa suuria datamääriä prosessoidaan yksinkertaisen, käyttökelpoisen ja mahdollisimman tarkkaan ennustavan mallin rakentamiseksi. (Alpaydin 2014: 2-3) Koneoppimisen sovelluskohteet ovat tänä päivänä lukuisat useilla eri toimialoilla, joissa tiedonkäsittelyn suorittaminen manuaalisesti on datan määrän takia mahdotonta. Esimerkiksi finanssialalla koneoppimista käytetään muun muassa erilaisten luotto-, sekä pörssi- ja markkinasovellusten mallien luontiin, käsillä olevaa valtavaa datamäärää hyödyntämällä. (Alpaydin 2014: 2-3) Yritysten markkinointiponnisteluissa tiedonlouhinta on käyttökelpoinen työkalu erityisesti asiakassuhteiden johtamiseen, yritysten vakiintuneiden asiakkaiden toimiessa sen arvokkaimpana datalähteenä. Tiedonlouhinta voidaan käyttää tässä yhteydessä esimerkiksi sovelluksissa kuten: *kampanjoiden ja asiakkaiden yhdistämisessä, asiakaskunnan segmentoinnissa, luottoriskien vähentämisessä, asiakasarvon määrittämisessä tai ristiin- ja lisämyynnin lisäämiseen tähtäävien toimenpiteiden määrittelyssä tai niihin liittyvien suositusten tekemisessä.* (Berry ym. 2004: 110-116)

Alpaydin (2014: 3) kuvaa koneoppimisen ”*tietokoneiden ohjelmoinniksi optimoimaan itsenäisesti annetun tehtävän vaatimat suorituskriteerit perustuen esimerkkidataan (example data) tai aikaisempaan kokemukseen.*” Toisin sanoen oppiminen on tässä yhteydessä tietokoneohjelman suorittamista mallin parametrien optimoimiseksi, käyttäen tehtävässä hyödyksi *harjoitusdataa* (training data) sekä aiemmin opittua. Koneoppimista hyödyntäen tuotettu malli voi Alpaydinin (2014: 3) mukaan olla ennustava, kuvaava tai

yhtä aikaa molempia. *Ennustavaa mallia* käytetään nimensä mukaisesti ennusteiden laatimiseen, kun taas *kuvaava malli* lisää tietoa itse datasta (Alpaydin 2014: 3)

Koska koneoppimisen tärkein tehtävä on tehdä päätelmiä erilaisista näytteistä ja otoksista, hyödynnetään sen rakentamisessa matemaattisissa malleissa tilastollista teoriaa. (Alpaydin 2014: 3) Alpaydinin mukaan tietojärjestelmätieteen rooli on tässä yhteydessä kaksiosainen. Harjoitusvaiheessa tarvitaan ensinnäkin tehokkaat algoritmit optimointiongelman ratkaisuun sekä yleensä valtavan datamäärän varastointiin ja prosessointiin. Toiseksi opitun mallin representaatiota ja päätelmien tekemistä varten suunniteltujen algoritmiin liittyvien ratkaisuiden täytyy olla yhtä lailla tehokkaita. Tietyissä sovelluksissa oppivan tai päätelmiä tekevän algoritmin tehokkuutta pidetään jopa yhtä tärkeänä kuin sen tekemien ennusteiden tarkkuutta. (Alpaydin 2014: 3-4)

### 3.1.1 Ohjattu oppiminen

*Ohjatussa oppimisessa* pääpainona on oppia kuvaus (malli) tapahtumasta, jossa syöte yhdistyy oikeaan, ennalta tiedossa olevaan, valvojan tarjoamaan tulosteeseen. (Alpaydin 2014: 11) Toisin sanoen ohjatussa oppimisessa *koneelle annetaan oikea vastaus opetusdatassa*. (Merilehto 2018: 19) Niin myöhemmin läpikäytävät *regressio* kuin *luokittelukin* ovat ohjattuun oppimiseen liittyviä ongelmia, missä molemmissa on olemassa ennalta tiedossa olevat syöte (X) sekä tuloste (Y) ja varsinaisena tavoitteena oppia malli, jolla syöte muuttuu tulosteeksi. (Alpaydin 2014: 9) Ongelmaa lähestyessä voidaan näin ollen muotoilla tietyin parametrijoukoin määritelty oletusmalli:

$$y = g(x | \theta)$$

Tässä kaavassa  $g(\cdot)$  on itse malli ja  $\theta$  sen parametrit. Regressio-ongelmissa  $y$  on numeerinen arvo,  $g(\cdot)$ :n ollessa *regressiofunktio*. Luokitteluongelmissa  $y$  edustaa taas luokkakoodia (esimerkiksi 0/1),  $g(\cdot)$ :n edustaessa *diskriminanttifunktiota*, jonka tehtävänä on erottaa eri luokkiin kuuluvat tapaukset. Koneoppimissovellus pyrkii molemmissa ongelmissa optimoimaan parametrit  $(\theta)$ , minimoimalla

approksimaatiovirheen niin että saadut arviot ovat niin lähellä harjoitusdatan sisältämiä oikeita arvoja kuin mahdollista. (Alpaydin 2014: 9-10)

### 3.1.2 Ohjaamaton oppiminen

*Ohjatun koneellisen oppimisen* keskittyessä syötteestä, valvojan tietämien oikeiden tulosteiden muuttumisen kuvauksen oppimiseen, *ohjaamattomassa koneoppimisessa* lähtötilanteessa on olemassa ainoastaan syötteet, ilman valvojaa ja tulosteita. Ohjaamattomassa oppimisessa tavoitteena on löytää syötteistä säännöllisyyksiä, jotka ilmenevät niiden rakenteellisessa tilassa toisiaan useammin esiintyvänä kaavoina ja joiden perusteella pystytään havaitsemaan mitä yleensä tapahtuu ja mitä ei. Kone suorittaa tällöin asioiden päättelyä datassa ilmenevien suhteiden ja säännönmukaisuuksien pohjalta. (Merilehto 2018: 19) Tilastotieteessä tätä kutsutaan *tiheyden arvioinniksi* (density estimation), jonka metodeita on esimerkiksi *ryhmittely* (clustering) jossa pyritään löytämään erilaisia syöteryhmiä. (Alpaydin 2014: 11-13)

### 3.1.3 Vahvistusoppiminen

*Vahvistusoppimisessa* (reinforcement learning) koneoppimissovellus pyrkii alituiseen käsillä olevassa tehtävässä kehittymiseen, jatkuvan syötedatan avulla tapahtuvan oppimisen ja erehdyksen kautta. (Alpaydin 2014: 13-14) Tällöin koneelle ei anneta oikeita vastauksia vaan palautetta siitä, kuinka onnistuneesti se eri tilanteissa toimii. (Merilehto 2018: 19) Sovelluksen tuloste on tällöin sekvenssi toimintoja. Tämän tyyppisessä koneoppimisessa yksittäiset toimenpiteet eivät ole kovinkaan tärkeitä vaan suurin kiinnostuksen kohde on tehtävässä suoriutumiseen vaadittavien oikeiden toimenpiteiden muodostama ketju eli sen kokonaisvaltainen toimintaperiaate. Tehtävän välivaiheille ei tällöin ole olemassa parhaita yksittäisiä toimintoja vaan yksittäiset toiminnot nähdään hyvinä ja soveltuvina ainoastaan, mikäli ne toimivat osana hyvää toimintatapaa. Tässä yhteydessä oppimismetodina käytettyjen *vahvistusoppimisalgoritmien* tulisi näin ollen pystyä arvioimaan toimintatapojen

hyvyyttä, oppimaan menneistä hyväksi ja huonoiksi havaituista toimintoketjuista ja tuottamaan tätä kautta paranneltu toimintatapa. (Alpaydin 2014: 13-14)

Esimerkkeinä vahvistusoppimisen sovellutuskohteista Alpaydin (2014: 13-14) mainitsee pelien, kuten shakin pelaamisen, jossa yksittäiset siirrot eivät näyttele niin suurta osaa kuin oikeiden siirtojen ketjut sekä määräsijaintia etsivän robotin, jonka testiajojen jälkeen tulisi oppia tehokkain toimintojen ketju tavoitesijaintiin löytämiseksi esteisiin törmäämättä. Molemmissa esimerkeissä yksittäisten tehtävien välivaiheiden toiminnot ovat hyviä ainoastaan silloin kun ne sopivat tavoitetta palvelevaan toimintatapaan. Koska vahvistusoppiminen nojaa vahvasti jatkuvaan syötteeseen, voi syötteiden epäluotettavuus vaikeuttaa oppimista merkittävästi. Esimerkkinä Alpaydin (2014: 14) mainitsee tästä edellä mainitun robotin, jonka oppimista sen saama ainoastaan osittainen ja huonolaatuinen sensoridata heikentää merkittävästi. Vahvistusoppimisen vaikeustasoa voi nostaa myös rinnakkaisten yhteistä tehtävää suorittavien agenttien määrä, kuten esimerkiksi tilanne, jossa joukkue robotteja pelaa jalkapalloa. (Alpaydin 2014: 13-14)

### 3.2 Neuroverkot

*Keinotekoisiksi neuroverkoiksi*, eli ANN:ksi (Artificial Neural Network) kutsutaan tekoälyn haaraa, jonka tutkimuksen tavoitteena on biologisten neuroverkkojen toimintaa matkimalla simuloida älykäästä käyttäytymistä. Ensimmäiset askeleet keinotekoisten neuroverkkojen pohdinnassa otettiin jo 1940-luvulla, jolloin suurin piirtein toiminnaltaan tunnetulle biologiselle neuronille lähdettiin kehittämään elektronista vastinetta neurofysiologi Warren McCullohin (1898-1969) ja loogikko Walter Pitts Jr.:n (1923-1969) toimesta. Neuroverkkojen kehityksen varhaisesta vaiheesta on tultu nykypäivään monien käänteiden saattamana ja niille on tänä päivänä olemassa jo useita käytännön sovellutuksia. Aidosti ihmisen lailla ajattelevan koneen rakentaminen ei kuitenkaan vielä ole mahdollista, johtuen eritoten useista kognitioon liittyvistä haasteista. (Haikonen 2017: 63-76; Livingstone 2009: V; Merilehto 2018: 20; 45-50)

Suurin ero muiden tämän päivän tekoälyn menetelmien ja neuroverkkojen välillä ilmenee siinä, että muiden metodien pyrkiessä jäljentämään ihmisälykkyyttä imitoimalla ”*mitä ihmiset tekevät*”, pyrkivät keinotekoiset neuroverkot reproduksoimaan pikemminkin ”*tapaa, jolla ihmiset tekevät*”. Neuroverkko koostuu joukosta operoivia, toisiinsa kytkettyjä, keskenään kommunikoivia, havainnoimalla oppimaan kykeneviä ja sitä kautta tiettyjä tavoitteita saavuttavia yksinkertaisia prosessoreita. Näitä matemaattisia yksiköitä kutsutaan *neuroneiksi*. (Livingstone 2009: V; Merilehto 2018: 20; 45-50)

Kokonainen keinotekoinen neuroverkko muodostuu suurella datamäärällä tehdyn harjoittelun perusteella toisiinsa kytkettyneiden neuronien joukosta. *Syväoppimisella* tarkoitetaan yhdessä toimivissa syvissä neuroverkkokerroksissa tapahtuvaa oppimista ja niiden optimointia haasteellisten ongelmien ratkaisemiseksi. Laskentatehon ja kapasiteetin alati kasvaessa myös neuroverkkojen kehittyminen on jatkuvaa. Verrattuna moniin muihin koneoppimismalleihin, ovat neuroverkot laajasti sovellettavia koska arkkitehtuurisesti samankaltaiset verkot ovat käytettävissä monien erilaisten ongelmien ratkaisuun. Erilaisissa sovelluksissa verkkoja voivat tällöin erottaa toisistaan pelkästään opetuksen seurauksena saadut painokertoimet. (Livingstone 2009: V; Merilehto 2018: 20; 45-55)

Neuroverkkojen, erityisesti syvien neuroverkkojen, oppimistulokset paranevat niillä käytössä olevan datan määrän kasvaessa. Niiden avulla on mahdollista saada hyviä tuloksia ilman ennen opetusta tehtävää datan luonteeseen liittyvien oletusten sisällyttämistä verkon rakenteeseen. Neuroverkolle ei toisin sanoen tarvitse kertoa, *mitkä asiat vaikuttavat ja mihin suuntaan*, sen antaessa tuloksena annetulle syötteelle vasteen (tulosteen). Neuroverkkojen hyödyt tulevat esiin ainoastaan sellaisissa tapauksissa, joissa sille kyetään syöttämään riittävän paljon dataa. Neuroverkkojen tapauksessa puhutaan tällöin suuruusluokaltaan yleensä vähintään kymmenistä tai sadoistatuhansista esimerkeistä. (Livingstone 2009: V; Merilehto 2018: 20; 45-55)

### 3.3 Koneoppimisen ja neuroverkkomenetelmien sovelluksia

Koneoppimista ja neuroverkkoja hyödynnetään nykyään monissa eri sovelluksissa. Tässä luvussa käydään läpi koneoppimisen sekä neuroverkkomenetelmien eri tyyppisiä sekä niiden sovelluskohteita.

*Oppimisassosiaatioilla* (learning associations) tarkoitetaan koneoppimisen yhteydessä koneellista assosiaatioiden etsimistä ja löytämistä asioiden, esimerkiksi erilaisten asiakkaiden ostamien tuotteiden välillä. Tällaista vähittäiskaupassa käytettävää koneoppimisen sovellutusta kutsutaan korianalyysiksi (basket analysis) ja sitä hyödynnetään muun muassa erilaisten asiakkaiden ostopotentiaalin tunnistamisessa, tavoitteena esimerkiksi ristiin myynnin lisääminen. Koneoppiminen keskittyy tällöin *assosiaatiosääntöjen* etsimiseen. Kiinnostuksen kohteena voi olla vaikkapa ehdollinen todennäköisyys tilalle  $P(Y | X)$  missä  $Y$  on tuote joka halutaan asettaa ehdoksi tuotteelle  $X$  joka taas on yksittäinen tuote tai joukko tuotteita jotka asiakas on jo aiemmin ostanut. Läpikäydyn datan perusteella saadun ehdollisen todennäköisyyden ollessa vaikkapa 0,3, voidaan muodostaa sääntö jonka perusteella 30 % asiakkaista jotka ostivat tuotetta  $Y$ , ostavat myös tuotetta  $X$ . Asiakkaiden joukossa on myös mahdollista tehdä tarkempaa erottelua arvioimalla  $P(Y | X, D)$  missä  $D$  on joukko asiakkaisiin liittyviä attribuutteja kuten vaikkapa asuinpaikka, ikä tai sukupuoli. Assosiaatiosääntöjä voidaan hyödyntää lukuisilla toimialoilla, perinteisestä vähittäismyynnistä Web-portaaleihin tai esimerkiksi vakuutusverkkokauppaan. (Alpaydın 2014: 4)

*Luokittelulla* (classification) tarkoitetaan koneoppimisen sovellusta, jossa asioita, esimerkiksi asiakkaita, jaetaan erilaisiin luokkiin, joko ennustavan, kuvaavan tai molempiin tarkoituksiin tuotetun mallin produsoinniksi. (Alpaydinin 2014: 3, 5-6) Tällöin valitut asiakastiedot attribuutteineen toimivat syötteinä koneelliselle luokittelijalle, jonka tehtävänä on siirtää harjoitusdatalla tehdyn oppimisen avulla muodostetun luokittelusäännön perusteella, kukin yksittäinen syöte omaan ennalta määriteltyyn luokkaansa. Esimerkiksi asiakkaita kahteen erilaiseen riskiluokkaan (korkea riski ja matala riski) jakavassa luottoyhtiön sovelluksessa opittu luokittelusääntö voisi muodostua datalla harjoittelun jälkeen vaikkapa seuraavan laiseksi:



**IF tulot >  $\theta$  1 AND säästöt >  $\theta$  2 THEN low-risk ELSE high-risk.**

(Alpaydin 2014: 5)

Muuttujat *tulot* ja *säästöt* ovat esimerkiksi luottoyhtiön saatavilla olevia asiakastietoja ja luvut  $\theta$  1 ja  $\theta$  2 tilanteeseen sopivia arvoja, joiden avulla muodostetaan koneoppimista hyödyntäen yleinen sääntö asiakkaan attribuuttien ja riskin välisen assosiaation ohjelmoinniksi menneen datan perusteella. Tällaista koneoppimisen toiminnallisuutta, jonka tehtävänä on erotella eri luokkien esimerkit, kutsutaan *diskriminantiksi*. Kyseisen esimerkin pääsovellusalue on ennusteiden tekemisessä. Logiikka ennusteiden taustalla perustuu siihen, että kun on olemassa menneisyyteen sopiva sääntö ja tulevaisuutta pidetään samankaltaisena menneen kanssa, oikeansuuntaisia ennusteita voidaan tällöin tehdä myös täysin uusissa tapauksissa. (Alpaydin 2014: 5-6)

Luokittelua voidaan lähestyä myös *oppimisassosiaatioiden* ja *todennäköisyyksien* näkökulmasta. Pelkän 0/1 (matala riski / korkea riski) päätelmän sijaan voidaan laskea todennäköisyys  $P(Y | X)$ , missä  $X$  sisältää asiakkaan attribuutit ja  $Y$  tiedon 0/1 tiedon riskistä. Luokittelu voidaan nähdä tällöin  $X$ :n ja  $Y$ :n välisen assosiaation oppimisena. Jos esimerkiksi  $X = x$  ja  $P(Y = 1 | X = x) = 0.7$  voidaan asiakkaan sanoa kuuluvan korkean riskin luokkaan 70% varmuudella. Luoton myöntämiseen liittyvä ratkaisu voidaan tehdä tällöin vertaamalla tappioiden ja voittojen mahdollisuuden todennäköisyyttä keskenään. (Alpaydin 2014: 5-6)

Useita koneoppimisen sovelluksia käytetään myös niin kutsuttuun *mallien tunnistamiseen* (pattern recognition). (Alpaydin 2014: 5) Esimerkiksi lääketieteellisessä diagnostiikassa koneoppimissovelluksen syötteet voivat pitää sisällään olennaista potilastietoa kuten sukupuoli, oireet, testitulokset, hoitohistoria ja ikä, luokkien taas toimiessa erilaisina sairauksina ja tauteina. Koska kaikkea olennaista tietoa ja testituloksia ei välttämättä ole saatavilla etukäteen ja koska väärät päätelmät voivat johtaa vääränlaisiin hoitoihin ja jopa ihmishenkien menetykseen, on esimerkkinä mainitussa lääketieteellisessä diagnostiikassa usein suositeltavaa, että koneellinen luokittelija siirtää päätöksen lopullisesta diagnoosista ihmisasiantuntijalle, etenkin mikäli siihen liittyy

yhtään epävarmuutta. (Alpaydin 2014: 7) Sääntöjen löytäminen ja oppiminen datasta mahdollistaa myös uuden *tiedon tuottamisen* (knowledge extraction). Säännön ollessa yksinkertainen dataa selittävä malli, voidaan mallia tarkastelemalla tuottaa selitys sen alla toimivalle prosessille. Esimerkki tällaisen tiedon tuottamisesta on matalan ja korkean riskin asiakkaiden ominaisuuksien oppiminen, näitä erottavan diskriminantin oppimisen jälkeen. Havaittuja ominaisuuksia voidaan myöhemmin käyttää esimerkiksi mainonnan kohdentamiseen matalarikisille asiakkaille. (Alpaydin 2014: 8)

Koneoppimista käytetään myös niin *poikkeavien havaintojen* tunnistamiseen (outlier detection) kuin *uutuuden tunnistamiseen* (novelty detection). Poikkeavien havaintojen tunnistamisella tarkoitetaan sellaisten tapausten löytämistä, jotka eivät noudata yleistä sääntöä ja ovat näin ollen poikkeuksia. Tyypillisten tapausten jakaessa tiettyjä helposti todettavia tunnusmerkkejä, voidaan selvästi erottuvat, tunnusmerkeiltään erilaiset tapaukset näin ollen erotella joukosta epätyypillisinä. Tällöin yleensä pyritään löytämään mahdollisimman yksinkertainen sääntö, joka kattaa niin suuren osuuden tyypillisistä tapauksista kuin mahdollista. (Alpaydin 2014: 9) Erotetut tapaukset voivat olla myös uusia ennennäkemättömiä mutta silti valideja tapauksia, jolloin voidaan *poikkeavan havainnon tunnistamisen* sijaan käyttää tapauksesta kuvausta *uutuuden tunnistaminen*. (Alpaydin 2014: 9)

*Regressio* (regression) on koneoppimisen sovellus, jota voidaan käyttää vaikkapa minkä tahansa attribuutteja sisältävän käytetyn esineen hinnan ennustamisessa. Regressio ongelmien olennaisin tunnusmerkkejä ovat attribuutteja sisältävät syötteet sekä erityisesti numeerisessa muodossa oleva tuloste. Esimerkkinä regressio ongelmasta Alpaydin (2014: 9) mainitsee käytettyjen autojen hinnan ennustamisen, syötteenä käytettyjen auton arvoon vaikuttavien attribuuttien kuten ikä, merkki, ajomäärä tai moottorin tyyppi, avulla. Kuvatun laisissa regressio-ongelmissa koneoppimissovellukselle voidaan kerätä harjoitusdataksi tietoja menneistä transaktioista, joille ohjelma sovittaa funktion oppiakseen hinnan (Y) auton attribuuttien (X) funktiona. Yksinkertaisia esimerkkejä tällaisesta funktiosta voisi olla vaikkapa lineaarinen malli  $y = wx + w_0$ , sopivin  $w$  ja  $w_0$  arvoin tai tarvittaessa mikä tahansa parhaiten tilanteeseen sopiva epälineaarinen syötteen funktio, kuten neliöllinen  $y = w_2 x^2 + w_1 x + w_0$ . (Alpaydin 2014: 9-10)

Autonomisesti toimivien robottien, kuten auton, navigointi voi perustua myös regressioon. Tällöin tulosteena on ohjaimen kulloinenkin asento, joka pyrkii pitämään robotin halutulla reitillä, törmäämättä esteisiin. Syötteet saadaan tällöin sensoreilta kuten GPS tai videokamera ja harjoitusdata voidaan kerätä havainnoimalla ja keräämällä ihmisohjaajan toimenpiteitä vastaavanlaisessa tehtävässä. (Alpaydin 2014: 10-11)

*Ryhmittely* (clustering) on koneoppimisen sovellus, jossa tavoitteena on löytää klustereita tai ryhmiä syötedatasta. Tutkimuksenkin kannalta kiinnostavana esimerkkinä ryhmittelyn käytöstä Alpaydin (2014: 11-12) mainitsee yrityksen, jolla on hallussaan menneisyydessä kerättyä demografista sekä yhtiön ja asiakkaiden välisiä transaktioita sisältävää asiakasdataa, jonka perusteella yritys haluaa selvittää asiakkaidensa profiilien jakaumaa, saadakseen tietoonsa usein esiintyviä asiakastyyppejä. Ryhmittelymalli allokoii tällöin attribuuteiltaan samankaltaiset asiakkaat omiin luonnollisiin, yrityksen kannalta kiinnostaviin asiakassegmentteihinsä jatkotoimenpiteitä kuten strategian, palveluiden, tuotteiden kullekin erilliselle segmentille tehtävää suunnittelua eli asiakassuhteiden johtamista varten. Ryhmittely mahdollistaa yritykselle myös poikkeavien ja erilaisten asiakkaiden havaitsemisen, joka voi auttaa löytämään erityisiä ja uusia tulevaisuudessa mahdollisesti hyödynnettävissä olevia markkinarakoja. Muina edellä mainitun metodin käytännön käyttökohteina Alpaydin (2014: 11-13) mainitsee muun muassa kuvien pakkaamisen, dokumenttien ryhmittelyn sekä bioinformatiikkaan ja molekyylibiologiaan liittyvän DNA ketjujen ryhmittelyn. Berryn ym. (2014: 111) mukaan epäsuorien ryhmittelytekniikoiden ongelmana on, että ne johtavat kyllä samankaltaisten asiakkaiden ryhmiin, mutta näiden ryhmien relevanssia liiketoiminnalle on usein vaikeaa ymmärtää. (Alpaydin 2014: 11-13; Berry ym. 2004: 111)

*Päätöspuita* (decision trees) voidaan käyttää suurten tietuejoukkojen jakamisessa peräkkäisiksi pienemmiksi tietuejoukoiksi soveltamalla sekvenssiä yksinkertaisia päätäntäsääntöjä. Jokaisen peräkkäisen jakautumisen jälkeen, tuloksena olevat joukot tulevat yhä enenemässä määrin toistensa kaltaisiksi. (Berry ym. 2004: 166) Päätöspuu on hierarkkinen ohjatun oppimisen malli, jota voidaan käyttää sekä luokitteluun että regressioon. (Alpaydin 2014: 213) Päätöspuita voidaan soveltaa lukuisissa tilanteissa

kuten käyttökelpoisten muuttujien poimimiseen suuria datajoukkoja tutkimalla tai suunnattujen asiakasryhmien muodostamiseen esimerkiksi suositusjärjestelmää varten. (Berry 2004: 203) Liiketoimintaympäristössä segmentointi halutaan yleensä suorittaa niin että jokainen asiakas saadaan sijoittumaan helposti määriteltävissä oleviin, markkinoinnin tavoitteita tukeviin segmentteihin. (Berry ym. 2004: 112) Berryn ym. (2004: 112) mukaan päätöspuu -sovellus on ideaali tällaiseen segmentointiin, mikä tekee myös päätöspuista tutkimuksen kannalta kiinnostavan koneoppimisen sovelluksen.

#### 3.4 ACPS-järjestelmässä hyödynnettävät menetelmät

Kohdeorganisaatiossa on käytettävissä suuri määrä erilaisia koneoppimisen ja neuroverkkojen sovelluksia. Tekstianalytiikan malleja ei kuitenkaan tällä hetkellä ole mahdollista käyttää muistin loppumisen takia. Tutkimuksen käyttötapauksessa käytettävässä sovelluksessa on kuitenkin kyseessä numeroanalytiikka. Kohdeorganisaation ympäristössä on tähän mennessä käytetty menestyksellisesti ainakin kolmea erilaista koneoppimisen menetelmää: *Multilayer Perceptron -neuroverkkoa*, *Random Forest -luokittelijaa* sekä *Support Vector Machinea*. (Tekninen vastaava 2020)

Kyseessä olevan käyttötapauksen kannalta parhaimmaksi vaihtoehdoksi kohdeorganisaation tekninen vastaava arvioi Multilayer Perceptron -neuroverkon. Monikerroksinen perseptroniverkko on keinotekoinen neuroverkkoarkkitehtuuri. Se on epäparametrinen estimaattori, jota voidaan käyttää erityisesti *regressioon* ja *luokitteluun*. Monikerroksisen perseptroniverkon kouluttamisessa eri sovelluksiin käytetään niin kutsuttua vastavirta-algoritmia (backpropagation algorithm). Monikerroksiseen perseptronineuroverkkoon tulee sisään useampi piilotettu kerros (layer), joina käsillä olevassa käyttötapauksessa toimisivat nimenomaan valitut profiloinnissa käytettävät ominaisuudet (syötteet). (Alpaydin 2014: 267; 279-281; Tekninen vastaava 2020)

Toinen käyttötapaukseen mahdollisesti sopiva, kohdeorganisaation käytössä oleva sovellus, oli teknisen vastaavan mukaan *satunnainen metsä* (random forest), päätöspuu perusteinen luokittelija, joka perustuu useiden erillisten oppijien yhdistämiseen. Satunnainen metsä on lukuisista päätöspuista koostuva kokonaisuus, jossa useita päätöspuita koulutetaan yhtä aikaa erilaisilla satunnaisilla harjoitusosajoukoilla tai osajoukoilla syötteiden ominaisuuksia. Lopulta käytettyjen päätöspuiden ennusteet yhdistetään, jolloin lopullisen saatavan ennusteen tarkkuus voi merkittävästi kasvaa. (Alpaydin 2014: 234-235; Tekninen vastaava 2020)

Teknisen vastaavan mukaan, kohdeorganisaation ympäristössä oli mahdollista käyttää myös ohjattuun oppimiseen pohjautuvaa *tukivektorikone* (support vector machine) -sovellusta, joka sopii erityisen hyvin asioiden kategorisointiin. Tukivektorikoneen toimintaperiaate on muodostaa kahta ryhmää erottava raja, käytetyn harjoitusdatajoukon perusteella. Se toimii paikantamalla harjoitusdatan kahteen kategoriaan jakamaan pyrkivän päätösfunktion, joka valitaan siten että sen etäisyys lähimpään pinnan kummalla tahansa puolella esiintyvään harjoitusdataan maksimoidaan. Mikäli datan lineaarisesti jakamaan kykenevää päätösfunktiota ei ole, käytetään datan kartoittamiseen eri ulotteiseen tilaan erityyppisiä niin kutsuttuja Kernelin muunnosfunktiota. Tällöin data voidaan jakaa edelleen lineaarisesti käyttämällä standardeja tukivektorikone päätösfunktiotekniikoita. Mikäli Kernelin muunnosfunktioiden avulla dataa ei saada täysin jaettua, voidaan datan erotteluun käyttää höllempää virhemuuttujaa luomaan pehmeämmän marginaalin päätösfunktio. (Boyle 2011: 14; Tekninen vastaava 2020)

Kaikkien edellä mainittujen kolmen menetelmän käyttöön on teknisen vastaavan mukaan hyvät valmiudet koska tekniikka, ympäristö ja osaaminen ovat valmiina. Kyseisten sovellusten käyttöä varten ei näin ollen tarvita käytännössä muuta kuin luokittelumääritelmät ja datat. (Tekninen vastaava 2020)

Valitun menetelmän kouluttamista varten, kohdeorganisaation käytössä on dataa sadoista tuhansista kaupoista, joista nähdään mitä kukakin on tehnyt. Dataa löytyi lisäksi valmiiksi lukuisista asiakkaiden ominaisuuksista. Datavarastosta on ladattavissa lisäksi

monipuolisesti tietoa agenttien ominaisuuksista. Agenttien hitrate -prosentit olivat ladattavissa niin yleisesti kuin myös tuotealueittain. (Tekninen vastaava 2020)

Teknisen vastaavan mukaan järjestelmä käyttää tavallisia taulukoita, joten myös artefakti olisi hyvä tuottaa taulukkomuodossa niin että sekä agenteille että asiakkaille on oma taulukkonsa, joista löytyy sarakkeet valittaville ominaisuuksille. Tähän mennessä tehdyissä testeissä on käytetty 300 ominaisuutta. Ominaisuuksia voi siis olla paljonkin, mutta tutkimuksessa voidaan keskittyä niin moneen kuin teoretiedon perusteella on löydettävissä, ilman että tutkimus laajenee liikaa. Tutkimuksen kautta uutettavien ominaisuuksien määrä rajattiin tästä syystä *noin kolmeenkymmeneen asiakkaan sekä agentin attribuuttiin*. Kohdeorganisaation toimijoiden kanssa asetettujen tavoitteiden mukaisesti, tärkeintä tutkimuksen kannalta on pyrkiä löytämään uusia näkökulmia ominaisuuksien määrittämiseen sekä mahdollisesti uusia sellaisia ominaisuuksia, joita ei vielä ole käytetty. (Tekninen vastaava 2020)

Lopullisen menetelmän valinta tehdään artefaktin alpha -version evaluoinnin yhteydessä, tutkimuksessa käytettäväksi valittavien agenttien ja asiakkaiden ominaisuuksien perusteella. Sopivimman menetelmän valinnasta vastaa kohdeorganisaation tekninen vastaava. Ominaisuuksien vaihteluvälien määritys sovittiin jätettävän kohdeorganisaation teknisen sekä CRM-vastaavan vastuulle. Ominaisuuksien vaihteluvälit päätetään artefaktin Beta-version valmistumisen jälkeen, ennen agenteilla suoritettavaa testivaihetta. (Tekninen vastaava 2020)

## 4. VAIKUTTIMET ASIAKKAAN OSTOPÄÄTÖKSEN TAKANA

Asiakkaan ostopäätökseen vaikuttavista tekijöistä on olemassa lukuisia teorioita. Tässä tutkimuksessa päädyttiin käyttämään niistä seuraavaa:

Jobberin ja Lancasterin (2009: 85-92) mukaan kuluttaja-asiakkaiden päätöksentekoprosessin lopputulokseen vaikuttavat tekijät voidaan luokitella kolmen otsakkeen; (1) Ostotilanteen, (2) Henkilökohtaisten vaikutteiden, ja (3) Sosiaalisten vaikutteiden, alle.

### 4.1 Ostotilannetyypit

Jobberin ja Lancasterin (2009: 85) mukaan Howard & Sheth (1969) ovat yksilöineet kolme erilaista ostotilannetyppiä, joihin liittyy joko; *laajamittainen ongelmanratkaisu*, *rajattu ongelmanratkaisu* tai *automaattinen vastaus*. Ahearne, Manning ja Reece (2012: 189-190) jakavat vastaaviin ostotilannetyyppeihin liittyvät ostopäätökset: *monimutkaisiksi*, *vaihtelua etsiviksi* tai *tavanomaisiksi* ostopäätöksiksi.

#### 4.1.1 Laajamittainen ongelmanratkaisu

Ongelman tai tarpeen ollessa täysin uusi, sen ratkaisemisen ollessa kallista tai epävarmuuden tason ollessa korkea, suorittaa asiakas usein *laajamittaisen ongelmanratkaisun*, joka pitää sisällään paljon tiedonhakua sekä vaihtoehtoisten ratkaisuiden tarkkaa tutkimista. Asiakkaan suorittaa tällöin *monimutkaisen ostopäätöksen*, johon liittyy tyypillisesti korkea asiakkaan osallistuvuus. Kohdatessaan tällaisen ostajan myyjä voi luoda ostajalle välitöntä liikearvoa tarjoamalla relevanttia informaatiota sekä arvioimalla tuotevalikoiman vaihtoehtoja sen suhteen, kuinka hyvin niiden edut sopivat asiakkaan tarpeisiin. Tällä tasolla hyvän myyntihenkilön mahdollisuudet ansaita asiakkaan luottamus ja vaikuttaa ostopäätökseen ovat suuret. Myyntihenkilön tässä vaiheessa hyvin suorittamalla myyntityöllä on saavutettavissa

myös läheisiä asiakassuhteita, joissa ostaja säilyy uskollisena myyjälle, vielä siirryttyään seuraavaan ostotilannetyypin. (Jobber ym. 2009: 86, Ahearne ym. 2012: 190.)

#### 4.1.2 Rajattu ongelmanratkaisu

*Rajattua ongelmanratkaisua* suoritetaan tilanteessa, jossa asiakkaalla on jonkin verran kokemusta käsillä olevasta tuotteesta tai palvelusta. Asiakas suorittaa tällöin useimmiten kohtuullisen määrän informaation etsimistä ja evaluointia, ikään kuin tarkistaakseen, että tekee oikean päätöksen valinnan suhteen. Osallistuvuuden ollessa keskimääräistä matalampaa tasoa on asiakkaan tekemä ostopäätös tällöin usein *vaihtelua etsivä*. Myyjä voi taivutella rajattua ongelmanratkaisua suorittavaa asiakasta tarjoamalla esimerkiksi oleellista vertailevaa tietoa, riskiä pienentäviä takeita tai muita vastaavia etuja. Pikemminkin vaihtelun kuin pettymyksen vuoksi tehtävä tuotebrändin vaihtaminen ei ole tällöin tavatonta. Tällaisessa tilanteessa asiakas saattaa kuitenkin kallistua helposti aikaisemmin ostettuun brändiin, prosessin tarjotessa myyjälle rajallisemmat mahdollisuudet houkutella asiakas vaihtamaan kilpailevaan tuotteeseen. (Jobber ym. 2009: 86, Ahearne ym. 2012: 190.)

#### 4.1.3 Automaattinen vastaus

*Automaattinen vastaus* kuvaa tilannetta, jossa asiakas ei juurikaan etsi tuotteesta tai palvelusta tietoa, vaan tekevät ostopäätöksen automaattisesti. Varsinkin ison brändin rakentaneet yritykset toivovat usein voivansa muuttaa asiakkaidensa ostotilannetyypin juuri automaattiseksi vastaukseksi. Mainonnan ja muiden markkinointitoimenpiteiden pitäessä brändin asiakkaan mielessä ja vahvistamalla jo ennestään suosiollista asennetta sitä kohtaan, jää henkilökohtainen myyntityö ostopäätöksen teon kannalta lähes tarpeettomaksi. Tässä ostotilannetyypissä asiakkaan osallistuvuuden taso on erittäin matala ja ostopäätös on *tavanomainen*. (Jobber ym. 2009: 86, Ahearne ym. 2012: 190.)



#### 4.1.4 Asiakkaan osallistuvuus ostotilanteessa

Tärkein vaikutin kaikkien ostotilanteiden taustalla on asiakkaan ostotapahtumaan liittyvä *osallistuvuuden taso*. Korkea osallistuvuuden taso liittyy yleisesti asiakkaalle tärkeisiin ostoihin, jotka pitävän sisällään *suuren henkilökohtaisen relevanssin*. Korkean osallistuvuuden ostoihin liittyy yleisesti vaikutus ostajan minäkuvaan, korkea hinta, suuri riski, sosiaalinen vaikutus (status) ja/tai mahdollisuus suuren mielihyvän saantiin. Osallistuvuuden tason ollessa korkea asiakas etsii päätöksentekonsa tueksi aktiivisesti tietoa, jota myös myyntihenkilön täytyy olla valmiina tarjoamaan syvällisesti. Ostotilanteeseen liittyvän henkilökohtaisen relevanssin pienentyessä myös osallistuvuuden taso mataloituu ja asiakkaan tiedonhakuun käyttämä aktiivisuus vähenee. Asiakkaan ollessa passiivinen tiedonhakija, toimii toisteinen mainonta usein tehokkaasti ostopäätöstä kohti vievänä vaikuttimena. (Jobber ym. 2009: 86, Ahearne ym. 2012: 190.)

#### 4.2 Henkilökohtaiset vaikutteet

Toinen ryhmä asiakkaan ostopäätökseen vaikuttavista seikoista pitää sisällään joukon yksilötasolle ulottuvia psykologisia käsitteitä, jotka liittyvät ostajan *persoonallisuuteen, motiiviin, perseptioon, oppimiseen* sekä *elämäntyyliin*. (Jobber 2009: 86-90)

##### 4.2.1 Persoonallisuus

*Persoonallisuuden* selittäessä eroja eri ostajien ostokäyttäytymisen välillä, on sen minkäänlainen tarkka määrittely tai vaikuttavuuden arviointi erittäin haastavaa edes alan ammattilaisille. *Brändipersoonallisuudella* tarkoitetaan brändien karakterisointia sen perusteella millaisia tunnusmerkkejä asiakkaat eri brändeihin liittävät. Tutkimuksissa (Ackoff ja Emsott; Olut) on havaittu, että asiakkailla on taipumuksena suosia omaan persoonallisuuteensa täsmäävää brändipersoonallisuutta. (Jobber 2009: 86-89)

Jobberin ja Lancasterin (2009) mukaan myös myyjien on syytä olla tietoisia ostajien persoonallisuustyypeistä ja käyttävät niiden jaottelussa Buzzottan, Leftonin ja Sherbergin kaksiulotteista lähestymistapaa ostopsykologian ymmärtämiseen. Tässä lähestymistavassa ostajien, kuten kaikkien muidenkin ihmisten, väitetään olevan kallistuneita persoonallisuudeltaan vihamielisen tai lämminhenkisen sekä dominoivan tai alistuvan puolelle. Vaikka näiden persoonallisuustaipumusten aste voi vaihdella paljon, pitävät Buzzotta, Lefton ja Sherberg yksilöiden sijoittamista nelijakoiseen matriisiin hyödyllisenä kunkin yksilön kohdalle sopivan myyntitavan määrittelemiseksi. Menetelmässä yksilöiden käyttäytymismallit määritellään seuraavalla tavalla:

1. Dominoivuus. Kasvokkain tapahtuvissa tilanteissa dominoivuus on pyrkimystä kontrolloida muita. Se näkyy erityisesti tarpeina ottaa johto henkilökohtaisissa kohtaamisissa, omata tilanteiden kontrolli ja olla itsenäinen. (Jobber 2009: 87)
2. Alistuvuus. Alistuvuus viittaa taipumukseen antaa toisten ottaa johdon. Se näkyy erityisesti haluna tulla kontrolloiduksi, tarpeena mukautua toisten toiveisiin ja haluna välttää yhteenottoja. (Jobber 2009: 87)
3. Lämminhenkisyys. Lämminhenkisyys ilmenee toisten huomioon ottamisena. Lämminhenkistä henkilöä kuvataan usein seurallisena, huumorintajuisena, optimistisena ja luottavaisena muita kohtaan. (Jobber 2009: 87)
4. Vihamielisyys. Vihamielisyys ilmenee välinpitämättömyytenä muita kohtaan. Vihamielistä henkilöä kuvataan usein kylmänä, epäluotettavana ja halveksivana. Vihamieliset henkilöt haluavat olla asemassa, jossa voivat sanoa, ”Minähän sanoin sinulle.”. (Jobber 2009: 88)

Buzzotta, Lefton ja Sherberg esittävät ostokäyttäytymisen ulottuvuuksien mallin alla kuvatun kaltaisena nelijakoisena matriisina:

Dominoiva	Q1	Q4
Alistuva	Q2	Q3
	Vihamielinen	Lämminhenkinen

**Kuva 3.** Buzzotta, Lefton ja Sherbergin ostokäyttäytymisen ulottuvuuksien malli (Jobber 2009: 88)

Buzzottan, Lefton ja Sherbergin mukaan ihmisten välisistä lukemattomista eroavaisuuksista huolimatta, jokainen ostaja on luokiteltavissa kuuluvaksi johonkin edellä kuvatuista neljästä ryhmästä. Eri persoonallisuustyyppien jakautuminen edellä mainittuihin ryhmiin onnistuu tunnistamalla ostajissa kutakin ryhmää leimaavia perusominaisuuksia:

Q1 eli *Dominoiva-Vihamielinen -ryhmään* kuuluvat henkilöt ovat kovaäänisiä, puheliaita, vaativia ja toimissaan vahvoja. Näitä henkilöitä kuvataan taipumattomiksi, itsepäisiksi, aggressiivisiksi, hyökkääviksi ja määrätietoisiksi. Q1 ryhmään kuuluvien henkilöiden kanssa on yleensä vaikeaa tulla toimeen, ja he eivät yleensä luota myyntihenkilöihin. (Jobber 2009: 88)

Q2 eli *Alistuva-Vihamielinen -ryhmään* kuuluvat henkilöt ovat kylmiä, varautuneita, vähäpuheisia, taipumuksiltaan erakkoja ja työskentelevät yleensä sellaisten tehtävien parissa, jotka vaativat keskittymistä sosiaalisen kanssakäymisen sijaan. Vastatessaan kysymyksiin nämä Q2 henkilöt ovat lyhytsanaisia ja töksäytteleviä. Nämä henkilöt mieluiten välttelevät myyntikeskusteluja ja joutuessaan myyntitilanteisiin ovat yleensä passiivisia melkeinpä tilanteesta lähes irtautumiseen asti. Q2 henkilöille luonteenomaisia työpaikkoja ovat esimerkiksi tutkimustyö, kirjanpito ja ohjelmointi. (Jobber 2009: 88)

Q3 eli *Alistuva-Lämminhenkinen -ryhmään* kuuluvat henkilöt ovat ekstrovertejä, ystävällisiä, ymmärtäviä, puheliaita, positiivisia mutta eivät luonnostaa johtajatyyppejä. He ostavat yleensä sellaisilta myyjiltä, joista pitävät ja näkevät koko myyntikeskustelun tyypillisesti sosiaalisena tapahtumana. Q3 henkilöt hyväksyvät yleensä kaiken mitä myyntihenkilö heille kertoo mutta tuntiessaan yhtään epäilystä lykkäävät ostopäätöstä. Ryhmään kuuluvat henkilöt hakevat tyypillisesti lykätyn ostopäätöksen jälkeen vielä tukea ja neuvoja ystäviltään. (Jobber 2009: 88)

Q4 eli *Dominoiva-Lämminhenkinen -ryhmään* kuuluvat henkilöt ovat sopeutuvia ja avomielisiä mutta eivät pelkää ilmaista ajatuksiaan ja mielipiteitään. Q4 henkilöt haluavat myyntiargumentteja tukevia todisteita ja tulevat kärsimättömiksi epämääräisistä vastauksista. Nämä henkilöt ostavat epäröimättä, mikäli heille kyetään tyydyttävällä tavalla todistamaan tuotteen tai palvelun ostolla saavutettava hyöty. Q4 henkilöt neuvottelevat mielellään liike-elämälle ominaisella tyylillä ja voivat olla myyntitilanteessa haastavia ja vaativia. (Jobber 2009: 88)

Decormierin ja Jobberin mukaan myyntihenkilöiden tulisi sopeuttaa käyttäytymistään soveltuvaksi eri persoonallisuustyyppiryhmiin kuuluvien ostajien ehdoilla. Eri persoonallisuustyypeille soveltuvat myyntitavat on jaoteltu seuraavasti:

Q1 eli *Dominoiva-Vihamielinen -ryhmään* kuuluvien henkilöiden kohdalla kunnioituksen saavuttaminen on tärkeää. Myyntihenkilön tulisi nostaa oman dominanssinsa taso ostajan tasolle. Käyttäytyminen edellyttää istumista suorassa, katsekontaktin säilyttämistä, kunnioittavaa ja passiivista kuuntelemista sekä vastaamista suoraan kysymyksiin. Tähän ryhmään kuuluvan ostajan ymmärtäessä, että myyjä on psykologisella tasolla samanveroinen kuin hän itse, voi merkityksellinen keskustelu alkaa. (Jobber 2009: 88-89)

Q2 eli *Alistuva-Vihamielinen -ryhmään* kuuluvien henkilöiden kohdalla myyntihenkilön ei tule pyrkiä dominoivaan asemaan vaan pikemminkin voittamaan ostajan luottamus vähitellen. Myyntihenkilön tulisi säätää jälleen dominanssinsa taso vastaamaan ostajan tasoa. Myynnissä tulisi suosia avoimia kysymyksiä sekä hidasta ja pehmeää puhetapaa.

Kehonkieleltään myyntihenkilön tulisi mataloittaa ryhtiään pitäen silmät ja pää samalla tasolla ostajan kanssa. (Jobber 2009: 89)

Q3 eli *Alistuva-Lämminhenkinen -ryhmään* kuuluvien henkilöiden kohdalla myyntihenkilöiden tulisi tyydyttää heidän sosiaalisia tarpeitaan olemalla lämminhenkinen ja ystävällinen. Myyntihenkilön ei tule pyrkiä dominoimaan vaan pikemminkin jakamaan sosiaalinen kokemus ostajan kanssa. Kun Q3 henkilö pitää myyjästä ja on muodostanut luottamuksen, tulisi myyntihenkilön ohjata keskustelua kohti päätöksentekoa. (Jobber 2009: 89)

Q4 eli *Dominoiva-Lämminhenkinen -ryhmään* kuuluvien henkilöiden kohdalla myyntihenkilön tulisi keskittyä enemmän kunnioituksen kuin pitämisen saavuttamiseen. Kunnioituksen saavuttaakseen myyntihenkilön tulisi jälleen nostaa oman dominanssinsa taso ostajan tasolle, säilyttäen kuitenkin lämminhenkinen ilmapiiri. Myyntihenkilön tulisi esittää argumenttinsa tueksi todisteita aina kuin mahdollista. (Jobber 2009: 89)

Tutkimuksen kannalta mielenkiintoiseksi kysymykseksi nousi se, että kykenisikö historiadataalla koulutettu neuroverkko tunnistamaan ennalta määriteltyjen attribuuttien perusteella matriisin kaltaisia asiakkaiden sekä myyjien persoonallisuustyyppisiä ja yhdistämään tämän jälkeen kunkin asiakkaan luonnostaan tilanteeseen sopivimman myyntitavan omaavalle agentille. Suurimpana haasteena tässä havaittiin olevan persoonallisuustyyppien määrittely. Agenttien karkea persoonallisuustyyppien selvittäminen voisi erilaisin kyselyin olla jossain määrin mahdollista, mutta asiakkaiden osalta vaihtoehdon havaittiin olevan erittäin vaikea toteuttaa. Tästä syystä tutkimuksessa syvennyttiin siihen, voisiko jollain asiakkailta saatavilla ennakkotiedoilla olla selvitettävissä missään määrin edes karkeasti asiakkaiden sijoittumista edellä kuvattuun Buzzotta, Lefton ja Sherbergin nelijakoiseen matriisiin.

#### 4.2.2 Elämäntyyli

*Elämäntyyli* viittaa yksilön tapaan elää ja se ilmenee erilaisten siihen liittyvien yksilön toimintojen, kiinnostuksen kohteiden ja mielipiteiden kautta. Markkinointitutkijat kiinnittävät paljon huomioita näihin elämäntavan taustalla toimiviin malleihin, joiden tutkimista kutsutaan myös elämäntapa-analyysiksi tai psykografiaksi (englanniksi psychographics). Elämäntapa-analyysissä yksilöitä luokitellaan ryhmiin muun muassa uskomusten, aktiviteettien, arvojen ja demografisten tunnusmerkkien kuten koulutuksen tai tulojen perusteella. Elämäntyylin ja ostokäyttäytymisen korrelaation löydyttyä, elämäntapa-analyysia on käytetty yleisesti markkinoinnin suunnittelussa, esimerkiksi uskomuksiltaan ja arvoiltaan saman henkisen mainonnan kohdistamiseksi eri elämäntyylin omaksuneille ryhmille. (Jobber 2009: 89-90) Erilaiset usein elämäntapa-analyysihin liitettävät demografiset luokat kuten esimerkiksi: *Ikä, Tulotaso, koulutus, työtehtävä, perheen koko tai sukupuoli* voisivat sellaisenaan toimia hyvinä ACPS-järjestelmän attribuutteina, koska niitä varten vaadittavaa tietoa kumuloituu monipuolisesti vakuutusyhtiön asiakastietokantaan vakuutus sopimusten solmimisen yhteydessä. Joidenkin elämäntapa-analyysissä käytettävien luokkien kuten *uskomusten, arvojen ja asenteiden* selvittäminen taas vaatisi erilaisten asiakaskyselyjen suorittamista. Elämäntyyliin liittyvät attribuutit voisivat teoretiedon valossa sinällään olla merkittäviä järjestelmän ominaisuuksia, joiden perusteella saman kaltaiset myyjät ja agentit voisivat oletettavasti resonoida keskenään.

#### 4.2.3 Muut henkilökohtaiset vaikutteet

*Motiivi* asiakkaiden ostopäätösten taustalla voi vaikuttaa epämääräiseltä. Myyntihenkilö voi kuitenkin huolellisella kartoitustyöllä päästä usein selville ostajan todellisista ostomotiiveista. Motiivi liittyy tarpeisiin ja mitä paremmin tarve oivalletaan, sitä helpompaa sen täyttäminen on. Myyntihenkilö voi lisätä ostajan motivaatiota yllyttämällä tarpeen tunnistusta, osoittamalla tapoja tarpeen täyttämiseen ja yrittämällä ymmärtää niitä vaihtelevia motiiveja, jotka toimivat päätöksentekoprosessin taustalla. Esimerkkejä tällaisista vaikuttimista voivat olla ajan säästäminen tai vaikkapa statuksen kohottaminen. (Jobber 2009: 88) Koska kartoittaminen sisältyy myyntityössä vaiheeseen, jossa asiakkaan kanssa ollaan jo keskusteluyhteydessä, soveltuu se attribuuttina huonosti

prosessin vaiheeseen, jossa asiakas pyritään ennakkotietojen perusteella ohjaamaan oikealle myyjälle.

Asiakkaan *perseptio* on myös suuresti ostopäätökseen vaikuttava tekijä. Ostajan kulloinenkin käsitys ostotilanteesta voi vaihdella niin että toisen nähdessä myyntihenkilön luotettavana, toinen voi epäillä tilannetta. Kuluttajat voivat käydä tämän tiimoilta kolmenlaisia valikoivia prosesseja: *valikoivan altistuksen*, jolloin vain tietyt informaation lähteet havaitaan, *valikoivan havaitsemisen*, jolloin vain tietyt ideat, viestit ja tieto edellä mainituista lähteistä havaitaan, tai *valikoivan säilytyksen*, jolloin vain jotkut edellä mainituista muistetaan. Asiakkailta on yleisesti taipumus unohtaa tai välttää viestejä, jotka ovat olennaisesti erimielisiä vallitsevien asenteiden kanssa. (Jobber 2009: 88) Myös asiakkaan perseptio on haastavaa selvittää ennalta. Perseptio voi lisäksi vaihdella myyntitilanteen mukaan. Tästä syystä perseptio soveltuu huonosti ACPS – järjestelmän attribuutiksi.

*Oppiminen* on myös tärkeä osa ostajan päätöksentekoa ja viittaa kokemusten aiheuttamaan käytöksen muutokseen esimerkiksi siitä mikä brändi vihjaa laatuun tai kehen myyntihenkilöön voi luottaa. (Jobber 2009: 88) Oppimiseen liittyviä asiakkaan ominaisuuksia on myös vaikea selvittää ilman asiakaskyselyitä.

### 4.3 Sosiaaliset vaikutteet

Sosiaaliset vaikutteet ostopäätösten taustalla pitävät sisällään muun muassa *sosiaalisen luokat, viiteryhmät, kulttuurin ja perheen*. (Jobber 2009: 90)

#### 4.3.1 Sosiaalinen luokka

*Sosiaalista luokkaa* pidetään yleisesti tärkeänä ostokäyttäytymistä määräävänä tekijänä. Markkinoinnissa sosiaalisen luokan on perinteisesti määrittänyt talouden pään tai ansainnasta pääasiassa vastaavan henkilön ammatti. Sosiaalisen luokan käytännön

merkitys havainnollistuu parhaiten siten että markkinointitutkimuksissa vastaajat jaotellaan useimmiten sosiaalisen luokan mukaan ja että suurin osa mainosmedioista jakaa lukijakuntiin liittyvät luvut sosiaalisiin ryhmiin. Muuttujan käyttämistä ostokäyttäytymiseroja selittävänä tekijänä on kuitenkin kritisoitu, koska samassa sosiaalisessa luokassa olevilla yksilöillä on havaittu usein toisistaan poikkeavia kulutusmalleja. Nämä löydökset ovat johtaneet uuden, Isossa-Britanniassa käytettävän luokittelujärjestelmän, ACORN:in kehittämiseen. ACORN (A Classification of Residential Neighbourhoods) luokittelee yksilöt heidän asuinalueensa tyyppin mukaan ja sen on havaittu toimivan tarkemmin erilaisten elämäntyylien, ostamiseen liittyvien mallien ja eri medioille altistumista erottelevana järjestelmänä. (Jobber 2009: 90-91; CACI 2019)

#### 4.3.2 Viiteryhmä

*Viiteryhmillä* tarkoitetaan niitä joukkoja ihmisiä, jotka vaikuttavat yksilön asenteisiin ja käyttäytymiseen. Erityisesti silmiinpistäviä tuotteita hankittaessa, brändin tai tuotteen valintaan vaikuttaa merkittävästi yksilön kokemus oman viiteryhmänsä hyväksynnästä hankinnalle. Viiteryhmään kuuluvia henkilöitä voivat olla esimerkiksi yksilön työtoverit, perhe tai ystävät. Hyväksyntää ei tule sekoittaa tuotteen suosioon. Myyjän suositellessa tuotetta yleisesti suosittuna saattaa se sotia yksilön tarpeita vastaan, mikäli yksilön pohjimmainen halu on kuulua erityiseen, esimerkiksi eksklusiiviseen ryhmään kuluttajia. (Jobber 2009: 91)

#### 4.3.3 Kulttuuri ja perhe

*Kulttuurilla* tarkoitetaan niitä perinteitä, tabuja arvoja ja perusasenteita, jotka ovat vallalla siinä kokonaisessa yhteisössä johon yksilö kuuluu. Kulttuuri on merkittävä tekijä erityisesti kansainvälisessä markkinoinnissa. (Jobber 2009: 91)

*Perhettä* kutsutaan usein ensisijaiseksi viiteryhmäksi ja se näyttelee tärkeää osaa kuluttajan ostokäyttäytymisessä. Tuotteen tai brändin valinta voi olla viimekädessä



ryhmäpäättös, jossa jokaisen perheenjäsenen erillinen vaikutus on yhteydessä lopputulemaan. Ostoksen ollessa ryhmäpäättös, on myyntihenkilön viisasta käydä tuotteen hyödyt läpi jokaisen päätöksentekijän näkökannalta. (Jobber 2009: 91-92)

## 5. ASIAKKAIDEN PROFILOINTI MARKKINOINNISSA

Markkinoiden segmentoinnilla tarkoitetaan prosessia, jossa asiakkaat jaetaan erillisiksi ryhmiksi tai segmenteiksi, joissa samankaltaiset tunnusomaiset piirteet omaavat asiakkaat jakavat samankaltaiset tarpeet. Tällöin kukin asiakasryhmä voidaan pyrkiä saavuttamaan kohdentamalla niille erillinen kutakin ryhmää varten suunniteltu markkinointi-mix. Asiakasmarkkinat jaetaan tyypillisesti *kuluttajamarkkinoihin, yritysmarkkinoihin, globaaleihin markkinoihin* sekä *ei-voittoa-tavoitteleviin ja valtiollisiin markkinoihin*. (McDonald ym. 1995: 10; Kotler ym 2016: 30)

### 5.1 Kuluttajamarkkinoiden segmentointi

Tavallinen lähestymistapa kuluttajamarkkinoiden segmentointiin pitää sisällään asiakkaiden jakamista segmentteihin *demografisten, geografisten, geodemografisten, psykografisten* ja *käyttäytymiseen liittyvien* tunnusmerkkien perusteella. (McDonald ym. 1995: 54-59; Kotler ym. 268-282)

Yleisesti käytettyjä demografisia asiakkaisiin liittyviä erityispiirteitä ovat muun muassa asiakkaan: *Ikä, sukupuoli, sukupuoli, perheeseen liittyvä elämänvaihe, perheen koko, asuintyyppi, tulotaso, ammatti, koulutus, uskonto, etninen alkuperä, kansallisuus, sosio-ekonominen status, multi-demografinen status, riippuvuussuhde perheeseen (lapset, nuoret aikuiset), ennen perhettä oleva vaihe, asema perheessä tai perheen jälkeinen vaihe*. Demografiset erityispiirteet ovat usein saatavilla tai johdettavissa olemassa olevista asiakastiedoista, joista vakuutusyhtiöillä todennäköisesti on asiakkaiden kanssa solmittujen vakuutusten myötä dataa asiakastietokannoissaan. (McDonald ym. 1995: 54-56; Kotler ym. 271-280; 662-663)

Yleisesti käytettyjä geografisia erityispiirteitä ovat taas esimerkiksi asiakkaan: *Postinumero, Asuinkaupunki tai -kunta, sisämaa tai rannikko, asuinalue, asuinvaltio, talousalue, maanosa, asuinalueen väestötiheys, asuinalueen ilmasto*. Geografiset erityispiirteet ovat myös usein saatavilla tai johdettavissa olemassa olevista

asiakastiedoista, joista vakuutusyhtiöillä todennäköisesti on asiakkaiden kanssa solmittujen vakuutusten myötä dataa asiakastietokannoissaan. (McDonald ym. 1995: 56; Kotler ym. 268-271; 662-663)

Yleisesti käytettyjä psykografisia erityispiirteitä ovat taas asiakkaan esimerkiksi: *persoonallisuus, asenne, asiakasstatus, elämäntyyli tai moniulotteiset erityispiirteet*. Asiakkaan psykografisten erityispiirteiden selvittäminen vaatii yleensä erilaisten kartoitusten ja mielipidekyselyiden tekemistä. (McDonald ym. 1995: 57-59; Kotler ym. 280-281)

Yleisesti käytettyjä geodemografisia erityispiirteitä ovat taas esimerkiksi asiakkaan: *ACORN -segmentti*. ACORN on CACI Information Services Lts:n kehittämä kuluttajaluokitusjärjestelmä, joka luokittelee Iso-Britannian väestön erilaisiin geodemografisiin segmentteihin. ACORN:ia ei voida soveltaa Suomessa. (McDonald ym. 1995: 56-57; CACI 2019)

Yleisesti käytettyjä käyttäytymiseen liittyviä erityispiirteitä ovat taas esimerkiksi asiakkaan: *Tarpeet ja hyödyt, päätäntäroolit, käyttäjään ja käyttöön liittyvät muuttajat*. (Kotler ym. 269; 281-282)

Segmentoinnin tarkoituksena on tehostaa markkinointia räätälöimällä kullekin segmentille omat tuotteensa, palvelunsa sekä ennen kaikkea tavan, jolla segmenttiin kohdistetaan mahdollisimman tehokasta markkinointiviestintää. Asiakassegmentit ovat perustuneet perinteisesti *markkinatutkimukseen* sekä asiakkaiden *demografisiin* ominaisuuksiin. Segmenteille tyypillisesti keksitään myös niitä kuvaavat, niiden ominaispiirteisiin perustuvat nimitykset. Esimerkkeinä tällaisista segmenteistä voisi käydä vaikkapa *”Vaihtelua etsivät lähiöissä asuvat keski-ikäiset naiset”* tai *”Seikkailunhaluiset nuoret kaupunkilaiset”*. Markkinatutkimukseen perustuvan segmentoinnin ongelma Berryn ym. (2004: 111) mukaan piilee siinä, että sitä on äärimmäisen vaikeaa soveltaa niihin kaikkiin asiakkaisiin, jotka eivät olleet mukana, tai muusta syystä vastanneet markkinatutkimukseen liittyviin erilaisiin kartoituksiin ja kyselyihin, sen tarjotessa toisin sanoen *valtavasti tietoa yleensä vain harvoista*

*asiakkaista*. Pelkkiin demografisiin ominaisuuksiin nojaavien segmenttien ongelma on taas siinä, että ne eivät selitä juurikaan asiakkaiden mieltymyksiin, persoonallisiin piirteisiin tai käyttäytymiseen liittyviä tekijöitä kovinkaan hyvin. Esimerkiksi kaikki edellä mainitut lähiöissä asuvat keski-ikäiset naiset eivät lähestulkoonkaan aina etsi vaihtelua, vaan tämän demografisin perustein valitulla segmentin asiakkailla saattaa olla lukuisia eri mieltymyksiä asenteita ja persoonallisuuspiirteitä. (Berry ym. 2004:111-116)

Daniel Yankelovichin ja David Meerin (Harvard Business Review 2006: 1) mukaan markkinoiden segmentointi on vuosien saatossa suuntautunut kapeasti suurelta osin mainostamisen tarpeisiin, tuotteiden ja palvelujen räätälöinnin niitä todennäköisimmin ostaville ryhmille sijaan. Jo vuonna 1964 Harvard Business Review -julkaisuun Yankelovichin kirjoittaman artikkelin mukaan, perinteiset demografiset piirteet kuten ikä, koulutustaso tai sukupuoli eivät palvele enää tarkoitustaan hyvän markkinointistrategian perustana, todennäköisempien kuluttajien ostopäätöksiin vaikuttavien piirteiden ollessa ei-demografisia kuten *arvot*, *mieltymykset* tai *preferenssit*. Yankelovichin mukaan hyvän markkinointistrategian tulisikin olla riippuvainen potentiaalisesti tiettyyn brändiin tai tuotekategoriaan vastaanottavaisesti suhtautuvien segmenttien tunnistamisesta. (Yankelovich 2006: 1)

Yankelovichin mukaan segmentointia voidaan hyödyntää huomattavasti laajemmin kuin erilaisten psykografisten, usein liikanimin kuten ”Katri kaupunkilainen” tai ”Iiro insinööri” kutsuttavien ihmistyyppien määrittämisessä. Vaikka psykografian keinoin voidaan saavuttaa jossain määrin totuudenmukaista tietoa todellisten ihmisten asenteista, tavoitteista, elämäntavasta ja omakuvasta, antaa se kuitenkin on todella heikkoja tuloksia pyrittäessä ennustamaan, mitä kukakin näistä ihmisistä todennäköisesti tulee ostamaan kussakin erillisessä tuotekategoriassa. Psykografia antaa täten yrityspäätäjille hyvin vähän työkaluja niin uusien asiakkaiden hankkimiseen, kuin vanhojen säilyttämiseen. Yankelovichin mukaan oikein toteutettu, viisas segmentointistrategia on kuitenkin edelleen validi osa markkinointia. Yankelovich on lisäksi kehittänyt työkalun nimeltä ”Päätöskirjon vetovoima” (englanniksi *gravity of decision spectrum*) joka keskittyy yksinomaan *kuluttajien ja tuotteen*, tai *tuotekategorian väliseen suhteeseen*, kuluttajien

ystävien, työpaikkojen, perheen tai muiden elämäntapa-analyysiin kuuluvien elementtien sijaan. (Yankelovich 2006: 1-2)

Segmentoinnissa yleisimmin tapahtuvat virheet Yankelovich ym. jakavat kolmeen eri muotoon: 1. Liiallinen keskittyminen kuluttajien identiteettiin, joka vie markkinoijan huomioon pois niistä tuotteen ominaisuuksista, jotka ovat brändin tai tuotekategorian nykyisille ja potentiaalisille uusille asiakkaille merkityksellisimpiä. 2. Liian vähäinen varsinaisen asiakaskäyttämisen painottaminen. 3. Kohtuuton teknisten yksityiskohtien sulauttaminen segmenttien suunnitteluun. (Yankelovich 2006: 10)

## 5.2 Asiakastietokannat ja tietokantamarkkinointi

Koska markkinointia suorittaakseen yrityksen täytyy tuntea asiakkaansa, täytyy niiden kerätä asiakkaistaan tietoa ja tallentaa se. Tällaisesta asiakkaista kerätystä ajantasaisesta, saatavilla olevasta, organisoidusta ja ymmärrettävässä muodossa olevasta tiedosta muodostuu *asiakastietokanta*, jonka avulla markkinointia voidaan suorittaa. Esimerkkejä asiakastietokannan avulla tehtävistä markkinointitoimenpiteistä ovat asiakasvihjeiden luonti ja kvalifointi, tuotteiden tai palvelujen myynti, sekä asiakassuhteiden huoltaminen. (Kotler ym 2016: 662-669)

Asiakastietokannan sisältämä tieto kumuloituu normaalisti monin eri tavoin; kuten esimerkiksi tavallisten asiakaskontaktien, erilaisten transaktioiden, rekisteröintien, puhelinkyselyiden tai evästeiden kautta. Asiakastietokannan tulisi sisältää mahdollisimman monipuolista ja käyttökelpoista tietoa kuten ainakin asiakkaan; *nimen, osoitteen, puhelinnumeron, sähköpostiosoitteen, asiakkaan viimeisimmät ostokset*, sekä suuren määrän, *demografisia tietoja (kuten syntymäpäivä, ikä, sukupuoli, perheen koko), geografisia tietoja (kuten asuinpaikka, kunta, alue), psykografisia tietoja (kuten harrastukset, mielenkiinnon kohteet, asenteet) ja mediagrafisia tietoja (kuten suositusmedia)*. (Kotler ym 2016: 662)

Älykkäät yritykset pyrkivät keräämään tietoa lähestulkoon kaikista tapahtuneista asiakaskontakteista, olivatpa ne sitten soittoja yrityksen puhelinpalvelukeskukseen tai vaikkapa sähköisten palvelujen käyttöä. (Kotler ym 2016: 662)

### 5.3 Koneoppimisen hyödyntäminen asiakkaiden profiloinnissa

Erilaisia tiedonlouhintasovelluksia voidaan käyttää myös merkityksellisten kaavojen löytämiseen suuresta joukosta tietoa, kuten esimerkiksi asiakastietokannan sisältämästä datasta. (Berry ym. 2004: 111; 349) Asiakkaiden segmentointi on yleinen yritysten olemassa olevia asiakastietoja hyödyntävä tiedonlouhinnan sovellus. Tiedonlouhinnan lähestymistapa asiakassegmentteihin on käyttäytymiseen liittyvien segmenttien tunnistaminen. (Berry 2004: 111)

*Ryhmittely* (clustering) on koneoppimisen sovellus, jossa tavoitteena on löytää klustereita tai ryhmiä syötedatasta. Tutkimuksenkin kannalta kiinnostavana esimerkkinä ryhmittelyn käytöstä Alpaydin (2014: 11-12) mainitsee yrityksen, jolla on hallussaan menneisyydessä kerättyä demografista sekä yhtiön ja asiakkaiden välisiä transaktioita sisältävää asiakasdataa, jonka perusteella yritys haluaa selvittää asiakkaidensa profiilien jakaumaa, saadakseen tietoonsa usein esiintyviä asiakastyyppejä. Ryhmittelymalli allokoii tällöin attribuuteiltaan samankaltaiset asiakkaat omiin luonnollisiin, yrityksen kannalta kiinnostaviin asiakassegmentteihinsä jatkotoimenpiteitä kuten strategian, palveluiden, tuotteiden kullekin erilliselle segmentille tehtävää suunnittelua eli asiakassuhteiden johtamista varten. Berryn ym. (2014: 111) mukaan epäsuorien ryhmittelytekniikoiden ongelmana on, että ne johtavat kyllä samankaltaisten asiakkaiden ryhmiin, mutta näiden ryhmien relevanssia liiketoiminnalle on usein vaikeaa ymmärtää. (Alpaydin 2014: 11-13; Berry ym. 2004: 111)

*Päätöspuita* (decision trees) voidaan käyttää suurten tietuejoukkojen jakamisessa peräkkäisiksi pienemmiksi tietuejoukoiksi soveltamalla sekvenssiä yksinkertaisia päätäntäsääntöjä. Jokaisen peräkkäisen jakautumisen jälkeen, tuloksena olevat joukot tulevat yhä enenemässä määrin toistensa kaltaisiksi. (Berry ym. 2004: 166) Päätöspuu on

hierarkkinen ohjatun oppimisen malli, jota voidaan käyttää sekä luokitteluun että regressioon. (Alpaydin 2014: 213) Päättöspuita voidaan soveltaa lukuisissa tilanteissa kuten käyttökelpoisten muuttujien poimimiseen suuria datajoukkoja tutkimalla tai suunnattujen asiakasryhmien muodostamiseen esimerkiksi suositusjärjestelmää varten. (Berry 2004: 203) Liiketoimintaympäristössä segmentointi halutaan yleensä suorittaa niin että jokainen asiakas saadaan sijoittumaan helposti määriteltävissä oleviin, markkinoinnin tavoitteita tukeviin segmentteihin. (Berry ym. 2004: 112) Berryn ym. (2004: 112) mukaan päätöspuu -sovellus on ideaali tällaiseen segmentointiin, mikä tekee myös päätöspuista tutkimuksen kannalta kiinnostavan koneoppimisen sovelluksen.

Suoraan tiedonlouhintaan tarkoitettuja *neuroverkkoja* käytetään yleisimmin *luokitteluun* tai *ennustamiseen*. Neuroverkkojen soveltuessa hyvin erilaisten ongelmien arviointiin ja ennustamiseen, jakavat hyvät niillä ratkaistavissa olevat ongelmat kolme erityispiirrettä: 1. Ongelmaan liittyvät syötteet ovat ymmärrettäviä, niin että niihin liittyvät tärkeät ominaisuudet ovat hyvin tiedossa, vaikka siitä miten ne liittyvät toisiinsa ei välttämättä ole olemassa selkeää käsitystä. 2. Tuloste on ymmärrettävä, niin että tiedetään mitä pyritään mallintamaan. 3. Ongelmaan liittyvää kokemusta on saatavilla tarpeeksi, siten että käsillä on oltava riittävä määrä esimerkkejä, joiden syötteet ja tulosteet ovat tiedossa, verkon kouluttamiseksi. (Berry ym. 2004: 215-219)

Hyvän neuroverkon koulutusjoukon valinta on kriittinen osa tiedonlouhinta, neuroverkon toimivuuden kannalta. Hyvän koulutusjoukon valinnassa tulee huomioida ainakin seuraavia asioita: 1. Koulutusjoukon tulee kattaa kaikkien neuroverkon mahdollisesti kohtaamien ominaisuuksien arvoalueet, niin syötteiden kuin tulosteidenkin osalta. 2. Syötteen ominaisuuksien määrä vaikuttaa verkkoon kahdella tavoin. Mitä suurempi syötteen ominaisuuksien määrä, sitä suurempi verkon täytyy olla, joka lisää ylisovittamisen riskiä. Parhaiden muuttujien valinnassa voidaan käyttää hyödyksi edellä mainittuja *päättöspuita* tai niitä voidaan lähteä valitsemaan intuitiivisesti, aloittamalla mieluiten muutamista sellaisista muuttujista, jotka tuntuvat järkeviltä ongelman kannalta, kokeilemalla sen jälkeen uusia potentiaalisia muuttujia ja havainnoimalla mitkä niistä parantavat mallia. 3. Neuroverkon sisältämien ominaisuuksien määrä kasvattaa pääsääntöisesti sen koulutuksessa tarvittavien esimerkkien määrää, jotta datan

sisältämistä malleista saadaan tarpeeksi kattava kuva. Koulutusjoukon koon osalta ei kuitenkaan ole olemassa yksiselitteistä sääntöä siitä, kuinka suuri sen tulisi olla suhteessa ominaisuuksien määrään. Tavallisesti tähän tarvitaan minimissään muutamia satoja esimerkkejä, useiden tuhansienkin ollessa vielä kohtuuden rajoissa. 4. Tulosteiden osalta tulisi pyrkiä siihen, että kaikista niiden mahdollisista arvoista löytyisi lukuisia esimerkkejä, parasta olisi, mikäli esimerkkejä kustakin mahdollisesta tulosteen arvosta olisi kutakuinkin sama määrä. (Berry ym. 2004: 232-235)

#### 5.4 Asiakkaiden etsintä

Rudradeb Mitran kirjoittamassa artikkelissa (Medium 2019) avataan tutkimuksen kannalta mielenkiintoinen näkökulma asiakkaiden etsimiseen koneoppimista ja neuroverkkoja hyödyntäen. Mitran mukaan parhaat myyjät kykenevät tunnistamaan prospektit eli niin sanotut potentiaaliset asiakkaat, ennen kuin asiakkaat julkisesti antavat ymmärtää etsivänsä myytävää tuotetta tai palvelua ja alkavat etsiä ratkaisua kohtaamaansa ongelmaan. Potentiaalisilla asiakkailla tarkoitetaan tässä sellaisia asiakkaita, joiden tarpeisiin myyjä pystyy tarjoamallaan tuotteella tai palvelulla saavuttamaan selkeitä etuja suhteessa muihin toimijoihin markkinoilla. Asiakkaan tunnistaminen ja kontaktointi sekä myyntiprosessin avaaminen tässä vaiheessa antaa Mitran mukaan etumatkaa muihin kilpailijoihin ja vähentää muun muassa erilaisten alennusten tarvetta kaupan aikaansaamiseksi. Mitran mukaan yksi hyvä tapa parhaan markkinasoveltuvuuden löytämiseksi on tutkia myyjän olemassa olevia asiakkaita ja pyrkiä etsimään vastauksia kysymyksiin kuten *”Ketkä ovat parhaita asiakkaitasi?”*, *”Miksi heistä tuli asiakkaitasi?”*, *”Miksi he edelleen ostavat sinulta”* ja *”Miksi asiakkaat valitsivat sinut muiden vastaavien tuotteen tai palveluntarjoajien sijasta?”*. Näiden kysymysten perusteella myyjän tulisi tunnistamiensa attribuuttien perusteella luoda persoona ihanteelliselle asiakkaalleen ja etsiä sopiva kanava näiden saavuttamiseen. (Mitra 2019)

Olemassa olevien asiakkaiden tutkiminen voidaan suorittaa manuaalisesti, mutta toisaalla saman ongelman ratkaisemisessa voidaan käyttää Mitran mukaan koneoppimisen



sovelluksia kuten *neuroverkkoluokittelijaa*, joka luokittelee myyjän prospektit (syötteen) huonoon, hyvään tai muutamaa eri tasoiseen luokkaan, ihanneasiakkaan attribuuteilla tapahtuneen neuroverkon koulutuksen perusteella. Menetelmän käyttäminen sisältää neljä vaihetta: 1. *Ominaisuuksien uuttaminen*, jossa asiakkaan merkitykselliset ominaisuudet pyritään uuttamaan kysymyksiin saatujen vastausten perusteella. 2. *Datan etiketöinti* esimerkiksi sen mukaan tapahtuiko kaupan saavuttaminen nopeasti, keskimääräisesti, hitaasti vai eikö kauppaa saavutettu ollenkaan tai vaikkapa kaupan suuruuden perusteella 3. *Neuroverkon koulutus*, joka toteutetaan ohjatun oppimisen algoritmeilla tavanomaisen neuroverkkoluokittelijan kouluttamiseksi. 4. Neuroverkon testaaminen lopulla datalla. 5. Neuroverkon käyttö uuteen dataan. (Mitra 2019)

### 5.5 Asiakkaan ja agentin merkityksellisiksi arvioidut ominaisuudet

*Ostotilanteessa suoritettavaa ongelmanratkaisua* selittävät asiakkaan ominaisuudet vaikuttaisivat liittyvän osallistuvuuden tasoon sekä kokemuksen määrään käsillä olevasta ongelmasta, tässä tapauksessa vakuutus tuotteiden hankinnasta. Kokemusta vakuutus tuotteiden tuttuudesta voidaan etukäteen arvioida ainakin käyttäjään ja tuotteen käyttöön (Kotler ym. 269; 281-282) liittyvin muuttujin, kuten:

**Taulukko 2.** Esimerkki asiakkaan profiloinnissa käytettävistä ominaisuuksista.

Käyttäjätas	Ei-käyttäjä, entinen käyttäjä, potentiaalinen käyttäjä, ensikertalainen, tavallinen käyttäjä.
Käyttöaste	Kevyt, keskinkertainen, raskas
Lojaalisuusstatus	Ei-lojaali, keskinkertainen, vahva, absoluuttinen
Valmiustaso	Tietämätön, tietoinen, kiinnostunut, karkäs, ostopäätöksen tehnyt
Asenne tuotetta kohtaan	Vihamielinen, negatiivinen, välinpitämätön, positiivinen, innostunut

*Rajatun ongelmanratkaisun* suorittavalle toisen vakuutusyhtiön asiakkaalle tehtävä myynti on haastavinta ja vaatii agentilta eniten kokemusta, taitoa ja ponnistuksia. *Laajamittaisen ongelmanratkaisun* suorittavalle asiakkaalle myyminen on haastavaa, mutta ei taas toisaalla niin vaikeaa kuin rajatun ongelman ratkaisun suorittavalle. Myyjän mahdollisuudet vaikuttaa asiakkaaseen laadukkaasti tehdyn myyntityön kautta ovat tässä tapauksessa huomattavasti paremmat ja kaupan todennäköisyys suurempi. *Automaattisen vastauksen* suorittavalle asiakkaalle myyminen on helpointa, lähes automaattista, mistä syystä myyjän kokemus ja taidot eivät vaikuta lopputulokseen merkittävästi. Agentin valmiutta erilaisiin myyntitilanteisiin voidaan arvioida oletettavasti kokemusta ja taitoa mittaavin ominaisuuksin kuten esimerkiksi:

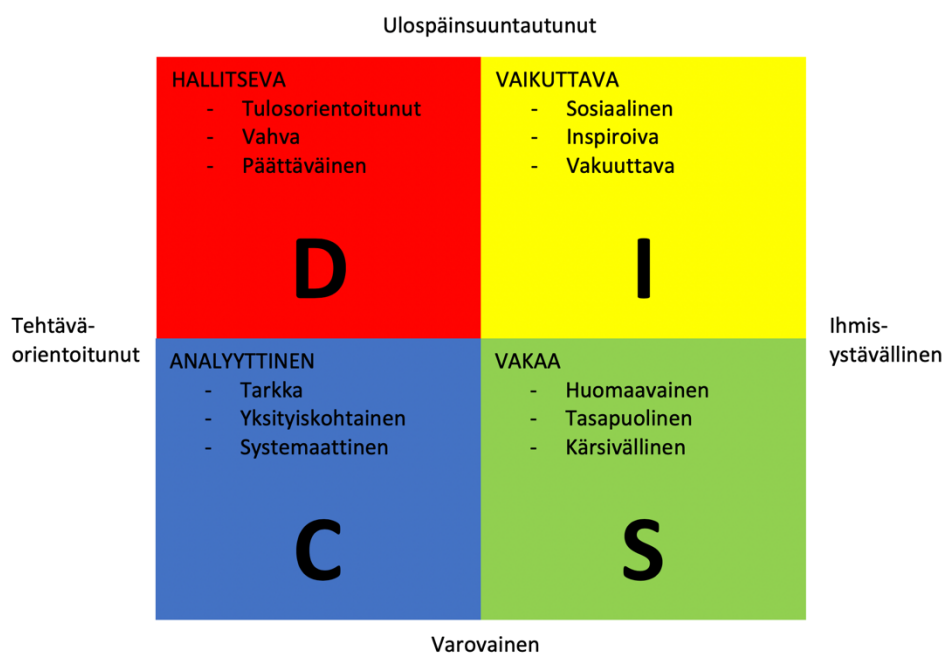
**Taulukko 3.** Esimerkki agentin profiloinnissa käytettävistä ominaisuuksista.

Työkokemus	0-2 vuotta, 3-5 vuotta, 6-10 vuotta, 10+ vuotta
Hitrate	Huono, välttävä, keskitaso, hyvä, erinomainen

Resurssienjaon kannalta oletettavasti tehokkainta olisi, mikäli asiakkaat jakautuisivat oikeille agenteille niiden haasteellisuustason mukaan. Kokemattomampien ja taitotasoltaan heikompien myyjien resurssit pystyttäisiin käyttämään helpompaan myyntityöhön, kokeneimpien ja taitavimpien myyjien resurssien kuluessa myynnin onnistumisen kannalta haasteellisempiin asiakkaisiin.

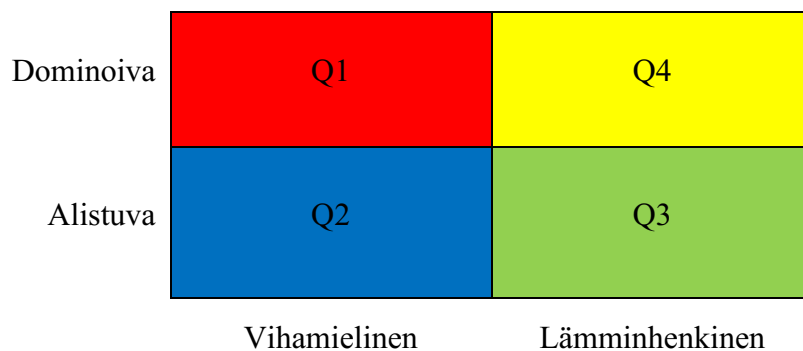
*Ostotilanteen henkilökohtaisia vaikutteita* selittävien, *persoonallisuuteen, motiiviin, perseptioon, oppimiseen* sekä *elämäntyyliin* vaikuttavien asiakkaiden ominaisuuksien kerääminen on tutkimuksen käyttötapauksen kannalta haasteellista, koska ne kaikki edellyttävät erilaisten kartoitusten ja asiakaskyselyiden käyttöä ennen varsinaista agentin tekemää kontaktointia. Markkinointitutkijat käyttävät näiden elämäntavan taustalla toimivien mallien selvittämiseen elämäntapa-analyysiksi (englanniksi psychographics) kutsuttavaa tutkimusmenetelmää. Esimerkki tällaisesta persoonallisuutta ja elämäntyyliä kartoittavista kyselyistä on vaikkapa kaupallisessa käytössä oleva Yhdysvaltalaisen Strategic Business Insight's:in VALS-kehikko. VALS jakaa ihmiset 6 demografiseen ja 35 asenteisiin liittyvään kysymykseen perustuvaan kyselyyn nojautuen, kahdeksaan

elämäntavoiltaan ja persoonallisuuspiirteiltään toisistaan eroavaan luokkaan (Kotler ym. 2016: 280-281; Strategic Business Insights 2019). Toinen hieman vastaavan kaltainen kansainvälisesti suosittu ja suomessakin käytössä oleva kaupallinen työkalu on niin kutsuttu DISC-testi (Discprofiili 2019), jonka vastausten perusteella ihmiset jaetaan persoonallisuuspiirteiltään neljään persoonallisuustyyppiin, jotka yhdistetään neljään eri väriin. DISC-malli perustuu discprofiili.fi -internetsivuston mukaan Carl Gustav Jungin työhön, josta William Moulton Marson Jr. (1928) jatko-kehitti DISC-analyysin. (Discprofiili 2019) Yleisesti kaupallisessa käytössä oleva sekä lukuisten yritysten esimerkiksi myyntikoulutuksissa ja HR strategian suunnittelutyökaluna käyttämä DISC-analyysi on kohdannut runsasta kritiikkiä tieteelliseltä yhteisöltä. Yksi DISC analyysin viimeisimmistä kritisoijista, sovelletun matematiikan professori David Sumpter, tuo yksityiskohtaisessa artikkelissaan (Medium 2020) selkeästi ilmi, että DISC-mallia ei ole koskaan täsmällisesti testattu ja että se nojaa kokonaisuudessaan teoriaan, jolla ei ole tieteellistä pohjaa. (Sumpter 2020)



**Kuva 4.** DISC-testin ihmisprofiili (Discprofiili 2019)

Koska valitun neuroverkkomenetelmän opetus perustuu historian testidataan, joka ei tässä käyttötapauksessa sisällä asiakkaista erilaisten elämäntapa-analyysitestein kerättyä tietoa, on näiden ominaisuuksien käyttö ainakin asiakkaiden osalta tässä tutkimuksessa joka tapauksessa poissuljettua. Agenttien osalta erilaisten vapaaehtoisuuteen perustuvien testien suorittaminen, hyvää tietosuoja noudattaen, oli kohdeorganisaation puhelinpalvelun toiminnasta vastaavan henkilön mukaan mahdollista. Osalle puhelinpalvelun työntekijöistä oli myös kartoitettu edellä mainittu DISC-profiili, jota kohdeorganisaation mukaan olisi mielenkiintoista käyttää ainakin testimielessä järjestelmän ominaisuutena. DISC-profiilin persoonallisuustyyppien jakautuminen neljään karkeaan kategoriaan, sekä niiden kuvaus näyttäisi korreloivan jossain määrin myös edellä esitellyn Buzzotta, Lefton ja Sherbergin ostokäyttäytymisen ulottuvuuksien mallin kanssa: Punainen-Q1, Keltainen-Q4, Sininen-Q2 ja Vihreä-Q3. DISC -profiilin kohtaamasta kritiikistä huolimatta sen testikäyttö yhtenä järjestelmän ominaisuutena voisi tuoda uusia näkökulmia aiheesta käytyyn keskusteluun, järjestelmän testivaiheesta saatuja tuloksia tulkittaessa.



**Kuva 5.** Buzzotta, Lefton ja Sherbergin ostokäyttäytymisen ulottuvuuksien mallin ja DISC-profiilin persoonallisuustyyppien läheinen korrelaatio (Jobber 2009: 88; Discprofiili 2019)

Tiettyjen, asiakkaan jo tekemien kulutusvalintojen perusteella on myös oletettavasti mahdollista kartoittaa ainakin jossain määrin asiakkaan *persoonallisuuteen* ja *elämäntapaan* liittyviä ominaisuuksia. Tiettyä automerkkiä suosivat henkilöt

profiloituvat esimerkiksi lähtökohtaisesti data journalisti Paul Hiebertin mukaan persoonallisuudeltaan, tulotasoltaan ja elämäntyyliään eri luokkiin. (Hiebert 2016) *YouGov plc Corporate* on kansainvälinen tutkimustietoa ja analyysiä tuottava yhtiö, joka tarjoaa asiakasdata-johdannaisia palveluita poliittisten, kulttuurillisten ja kaupallisten organisaatioiden markkinoinnin tueksi, mukaan lukien joukon maailman tunnetuimpia brändejä. (YouGov 2019) Paul Hilbertin mukaan YouGovin, yli 200 000 yhdysvaltalaisen asenne-, persoonallisuus- ja käyttäytymispiirteitä sisältävää tietokantaa hyödyntäneessä tutkimuksessa selvisi, että eri automerkkien omistajiin liittyvät käyttäytymismallit, asenteet ja persoonallisuuspiirteet poikkesivat toisistaan yllättävän paljon. BMW: n omistajat pitivät esimerkiksi itseään selkeästi muita enemmän *asioista perillä olevampina*, Mercedes Benzin omistajat enemmän *johtajatyyppeinä*, Volkswagenin omistajien pitäessä itseään muita *mielikuvituksellisempina*.

	Asioista perillä oleva	Mielikuvituksellinen	Tunneälyinen	Sosiaalisesti taitava	Hyvä muisti	Johtaja	Suurisydäminen	Mekaanisesti taitava	Luotettava	Seikkailunhaluinen	Analyttinen	Ystävällinen
BMW	70 %	29 %	27 %	25 %	19 %	27 %	26 %	17 %	13 %	11 %	16 %	9 %
Cadillac	39 %	36 %	45 %	46 %	22 %	26 %	27 %	18 %	22 %	14 %	8 %	12 %
Chrysler	56 %	38 %	27 %	27 %	23 %	24 %	24 %	15 %	25 %	13 %	11 %	15 %
Dodge	46 %	36 %	33 %	24 %	25 %	26 %	29 %	23 %	23 %	16 %	9 %	14 %
Ford	47 %	36 %	30 %	30 %	28 %	26 %	24 %	25 %	19 %	12 %	13 %	16 %
General Motors	46 %	34 %	22 %	26 %	24 %	18 %	17 %	28 %	16 %	9 %	10 %	12 %
Lexus	43 %	34 %	31 %	29 %	23 %	43 %	22 %	15 %	14 %	21 %	17 %	12 %
Lincoln	44 %	20 %	47 %	16 %	30 %	42 %	26 %	16 %	13 %	8 %	11 %	6 %
Mercedes-Benz	46 %	35 %	21 %	21 %	23 %	45 %	9 %	21 %	10 %	36 %	11 %	7 %
Volkswagen	48 %	49 %	42 %	34 %	18 %	26 %	17 %	15 %	12 %	19 %	10 %	6 %

**Kuva 6.** Omistajien persoonallisuuspiirteiden painot autobrandeittain suomennettuna (Hiebert 2016)

Koska automerkki näyttäisi YouGov:in edellä kuvatussa tutkimuksessa korreloivan ainakin jossain määrin tiettyjen auton omistajan itse kokemien persoonallisuuspiirteidensä, elämäntapaan liittyvien piirteiden sekä tulotason kanssa, voisi se toimia yhtenä mielenkiintoisena asiakkaita sekä agentteja jaottelevana luokkana

testissä. Automerkin lisäksi merkityksellisiä samaan kategoriaan liittyviä ominaisuuksia voisivat oletettavasti olla myös auton tarkemmat tiedot kuten malli ja käyttöönottovuosi. Tarkemmin autosta kertova malli voisi oletettavasti antaa lisää viitteitä esimerkiksi omistajansa elämäntavoista ja vaiheesta (perheauto, urheiluauto, pieni auto, tila-auto, maastoauto), vuosimallin antaessa viitteitä esimerkiksi tulotasosta.

Autobrändit, kuten esimerkiksi Volkswagenin kanssa yhdistetty, nykyisin yhdessä sen kanssa Integrated Automotive Groupin muodostava Porsche suorittavat markkinoinnissaan asiakkaidensa profilointia ja segmentointia, hinnoittelustrategian sekä asiakasryhmille kohdennetun markkinoinnin suunnittelussa. (Wells 2018; Zoeller 2019) Zoellerin mukaan esimerkiksi Porsche identifioi kohdesegmentit käyttämällä kahta muuttujaa toisen sisältäessä *kuvaavia elementtejä* kuten demografisia, psykografisia ja geografisia erityispiirteitä ja toisen *käyttöä liittyviä elementtejä* kuten yksilöllisiä vasteita brändeihin, käyttöön ja hyötyihin. Porschen psykografinen segmentointi jakaa kuluttajia käyttäytymiseen pohjaaviin ryhmiin kuluttajien psykologisten sekä elämäntapaan, persoonallisuuteen ja arvoihin liittyvien ominaispiirteiden perusteella. Erilaisia psykografisia profiileita, joita kutakin varten Porsche räätälöi yksilöityä, eri mallejaan suosittavaa kohdeviestintää olivat muun muassa: (Zoeller 2019)

- ”Top gun” -profiili, kunnianhimoinen ja omatoiminen yksilö, jolle on tärkeää valta ja kontrolli ja joka odottaa tulleensa huomatuksi.
- ”Elitisti” -profiili, varakasta lähtökohdista lähtöisin oleva yksilö, joka asennoituu autoon kuluvälineenä, ei persoonallisuutta ilmaiseksi välineenä.
- ”Ylpeä kanta-asiakas” -profiili, yksilö, joka näkee Porschen ennen muuta palkintona kovasta työstä ja jonka päätavoite ei ole tulla huomatuksi.
- ”Elämännautiskelija” -profiili, jet-setter tai jännitystä etsivä yksilö, joka näkee keinona jännityksen luomiseen.
- ”Fantasioija” -profiili, joka näkee Porschen pakokeinona ja ei ole kiinnostunut tekemään vaikutusta muihin.

(Zoeller 2019)

Autovalmistajien harjoittaman markkinoinnin ja niiden profiileiltaan erilaisille asiakasryhmille kohdentaman viestinnän voisi olettaa osittain selittävän edellä mainitussa YouGov:in tutkimuksessa esiin tulleita havaintoja eri automerkkien omistajien persoonallisuuspiirteiden ja elämäntapaan liittyvien piirteiden eroista. Eri autobrändien kohdistaessa viestintää erilaisille asiakasprofiileille, voidaan olettaa, että eri automerkkien ja mallien omistajat myös pitävät sisällään todennäköisesti merkittäviä määriä profiililtaan, juuri sellaisia kuluttajia, joita varten viestintä on suunniteltu ja suunnattu. Tutkimuksen kannalta mielenkiintoiseksi kysymykseksi nousikin se, voisiko esimerkiksi automerkki, malli ja vuosimalli olla *välillisesti* sellaisia asiakkaan psykografisia erityispiirteitä kuvaavia ominaisuuksia, joita pystyttäisiin edes jossain määrin hyödyntämään valitun neuroverkkomallin kouluttamisessa.

Koska kaikille Suomessa liikennekäytössä oleville ajoneuvoille, muutamia poikkeuksia lukuun ottamatta, täytyy ottaa liikennevakuutus, ja koska liikennevakuutuksen voi antaa vain vakuutusyhtiö, jolla on oikeus harjoittaa vakuutusyhtiölain (521/2008) tai ulkomaisista vakuutusyhtiöistä annetun lain (398/1995) mukaan vakuutusluokista annetun lain (526/2008) 6 §:ssä tarkoitetun vahinkovakuutusluokan 10 mukaista vakuutustoimintaa, on Suomalaisten vakuutusyhtiöiden tietokannoissa valtava määrä tarkkaa dataa asiakkaidensa omistamista ajoneuvoista. Asiakkaidensa ajoneuvojen tarkat tiedot ovat tästä syystä vakuutusyhtiöille helposti saatavilla olevaa dataa, minkä takia ne soveltuisivat vakuutusyhtiöiden kannalta mainiosti ACPS-järjestelmässä käytettäväksi asiakkaiden attribuuteiksi. (Finlex 2019)

Agenttien osalta *persoonallisuuteen, kommunikointitapaan ja elämäntapaan* liittyviä ominaisuuksia olisi todennäköisesti helpompi kartoittaa erilaisin kyselyin tai kartoituksin huomattavasti rajatumman ryhmän koon takia. Agentit olisi luultavasti myös helpompi saada osallistumaan testiin, esimerkiksi yhdistämällä sen tekeminen myynnin valmentamiseen. Edellä läpi käydyn Buzzottan, Leftonin ja Sherbergin ostopsykologian ymmärtämiseen tarkoitetun kaksiulotteisen lähestymistavan mukaan, ostopäätöksen todennäköisemmän syntymisen kannalta myyjän käyttäytymisen tulisi sopeutua asiakkaan persoonallisuustyyppiin. Tutkimuksen kannalta mielenkiintoiseksi seikaksi nousikin kysymys siitä, että *mikäli ajoneuvotiedot jossain määrin selittäisivät suuria*

*datamääriä louhittaessa omistajiensa persoonallisuutta ja mikäli agentit saataisiin myös jaoteltua joko edellä mainituin kyselyin tai automerkin -mallin ja vuosimallin perusteella, kykenisikö historiadataalla koulutettu neuroverkkomenetelmä löytämään näiden ominaisuuksien perusteella toistensa kanssa resonoivia psykografisiin piirteisiin nojaavia vastinpareja.*

*Ostotilanteen sosiaalisia vaikutteita selittävien, sosiaalisen luokkaan ja kulttuuriin liittyvien ominaisuuksien kerääminen on tutkimuksen käyttötapauksen kannalta mahdollista, koska ne molemmat ovat johdettavissa erilaisista demografisista muuttujista, joista vakuutusyhtiöillä todennäköisesti on asiakkaiden kanssa solmittujen vakuutusten myötä dataa asiakastietokannoissaan. Perheen eli perheenjäsenten päätäntärooleja ja niiden erillistä vaikutusta ostopäätökseen sekä viiteryhmiä eli muiden asenteisiin, käyttäytymiseen ja ostopäätökseen vaikuttavien ihmisten osalta, dataa on vaikea selvittää ilman asiakaskyselyitä. Perheen rakennetta, tuloluokkaa, asuintapaa kuvaavilla geo- ja demografisilla ominaisuuksilla on varmasti oma merkityksensä, mutta niistä ei suoraa ole johdettavissa mm. päätäntärooleja tai muuta perheen sisäistä päätöksentekoon liittyvää dynamiikkaa.*

Puhtaasti demografisista ja geografisista erityispiirteistä merkityksellisiä voisivat oletettavasti olla ainakin sellaiset ominaisuudet, jotka agentilla ja asiakkaalla ovat toistensa kaltaisia. Esimerkiksi *keski-ikäisen perheellisen isossa kaupungissa asuvan naispuolisen agentin* on oletettavasti helpompi samaistua toisen samoista lähtökohdista olevan asiakkaan tilanteeseen. Toisaalla on täysin mahdollista, että täysin erilaisin ominaisuuksin varustetun agentin hitrate, on kyseisenlaisten asiakkaiden kohdalla silti edellistä korkeampi. Joka tapauksessa tietyt demografiset muuttujat kuten *ikä, sukupuoli, perheeseen liittyvä elämänvaihe, asuintyyppi, ammatti, koulutus*, tai geografiset muuttujat kuten *postinumero* ja *asuinkaupunki* ovat oletettavasti osaltaan vaikuttamassa ostopäätökseen liittyviin taustoihin, tarpeisiin ja odotuksiin myyntitapahtuman suhteen.

Koska ostopäätökseen vaikuttavien ominaisuuksien arvioiminen irrallaan toimintaympäristöstä on varsin haastavaa, yksi vaihtoehto on pyrkiä johtamaan niitä manuaalisesti, tai edellä mainittua *neuroverkkoluokittelijaa* tai *päätöspuuta* hyödyntäen,



käsillä olevasta agentteja, asiakkaita ja transaktioita sisältävästä historiadatasta. Tällöin kohdeorganisaation kunkin agentin suorittamista myyntiprojekteista voitaisiin kerätä lukuisia esimerkkejä sisältävä joukko dataa ja tutkia kutakin agenttia erikseen. Kunkin esimerkin tulisi sisältää suurempi joukko asiakkaiden merkitykselliseksi arvioituja ominaisuuksia sekä etikettinä esimerkiksi kaupan suuruus jaoteltuna muutama sopivaan luokkaan, kuten *ei-kauppaa*, *pieni*, *keskisuuri* tai *suuri*. Kunkin agentin kohdalla voitaisiin pyrkiä määrittelemään niin sanotun ihanneasiakkaan ominaisuuksia järjestämällä esimerkit parhaista onnistumisista huonoimpaan ja keskittymällä tämän jälkeen manuaalisesti havainnoimaan vaikkapa parasta kymmenystä, tavoitteena löytää niistä yhteneviä ominaisuuksia. *Neuroverkkoluokittelijaa* käytettäessä, verkko voitaisiin kouluttaa ja testata historiadataalla kullekin agentille erikseen, jonka jälkeen sitä voitaisiin käyttää uuden datan, kuten esimerkiksi prospekttilistojen luokittelussa kyseiselle agentille. Tällöin agenttien ominaisuuksia ei tarvitse välttämättä arvioida erikseen vaan neuroverkko luokittelisi asiakkaat puhtaasti niiden ominaisuuksien ja menneiden onnistumisten perusteella.

Koska segmentoinnin hyödyntämistä tutkineen Yankilovichin mukaan segmentoinnissa ei missään nimessä tule keskittyä liikaa pelkästään asiakkaan identiteettiin vaan pikemminkin *asiakaskäyttäytymisen painottamiseen*, ja koska käyttäytymiseen perustuvien iskuryhmien käytöstäkin oli kohdeorganisaatiossa saatu myös hyviä kokemuksia, kannattaa ACPS järjestelmään liitettäviä ominaisuuksia suunniteltaessa myös keskittyä pitkälti nimenomaan käyttäytymiseen pohjautuviin ominaisuuksiin. Agenttien kohdalla tällaisia ominaisuuksia voisivat olla esimerkiksi *tuotealuekohtaiset hitratet* ja asiakkaiden kohdalla kohdeorganisaatiossa käytössä oleva tuotealuekohtainen, käyttäytymiseen pohjautuvaan tietoon perustuva *potentiaalipisteytys*. Asiakkaiden potentiaalipisteytykset voivat sisältää monenlaista asiakkaiden käyttäytymiseen liittyvää tietoa kuten tietoja aiemmista ostoista, verkko- tai asiakaspalvelun käytöstä, tiedossa olevista harrastuksista, omistamasta vakuutettavasta omaisuudesta kuten ajoneuvoista, kiinteistöistä ja erilaisesta irtaimistosta. Antamalla erilaisia painokertoimia eri asiakkaan käyttäytymiseen liittyville tiedoille, on asiakkaalle piirrettävissä pisteytys, joka viittaa eri tuotealueisiin liittyvään ostopotentiaaliin. (Call Center vastaava 2020; Yankelovich 2006: 10)

## 5.6 Automaattiseen tietojen käsittelyyn perustuvan markkinoinnin rajoitteet

EU:n yleinen tietosuoja-asetus (2016/679) eli niin kutsuttu GDPR (General Data Protection Regulation) määrittää säännöt luonnollisten henkilöiden suojelusta henkilötietojen käsittelyssä ja näiden tietojen vapaasta liikkuvuudesta sekä direktiivin 95/46/EY kumoamisesta.

### 5.6.1 Henkilötietojen käsittely

Tietosuoja-asetuksen (2016/679) määrittelee kuusi perustetta, joista yhden täyttymistä henkilötietojen käsittely edellyttää ja joka täytyy olla selvillä ennen käsittelyn aloittamista:

- *Rekisteröidyn suostumus*
- *Sopimus*
- *Rekisterinpitäjän lakisääteinen velvoite*
- *Elintärkeiden etujen suojaaminen*
- *Yleistä etua koskeva tehtävä tai julkinen valta*
- *Rekisterinpitäjän tai kolmannen osapuolen oikeutettu etu*

(Tietosuojavaltuutetun toimisto 2019)

ACPS-järjestelmän asiakkaiden profiloinnissa käytettävät tiedot tulee kerätä nojaten johonkin edellä mainituista perusteista. Vakuutusyhtiöiden asiakastietokantoihin kumuloituvasta tiedosta suuri osa liittyy asiakkaan ja vakuutusyhtiön väliseen sopimukseen, kuten vakuutus sopimusten myöntämistä ja ylläpitoa vaativiin tietoihin. Markkinointitoimenpiteitä varten voidaan kerätä myös tietoa rekisteröityjen suostumuksella, jonka tulee olla *yksilöity, tietoinen, aidosti vapaaehtoinen ja yksiselitteinen tahdonilmaisuu*, kuten esimerkiksi ruudun rastittaminen verkkosivuilla.

Suostumus täytyy olla peruutettavissa yhtä helposti. Suostumusta pyydetessä rekisterinpitäjän on myös yksilöitävä käyttötarkoitus, johon tietoja kerätään. Suostumus saatetaan joissain tapauksissa tarvita *nimenomaisesti*. Nimenomainen suostumus viittaa tapaan, jolla suostumus ilmaistaan ja se voidaan antaa esimerkiksi sähköisellä- tai kirjallisen lausuman allekirjoituksella. Nimenomainen suostumus on mahdollinen oikeusperuste *automaattisia yksittäispäätöksiä tai profilointia tehdessä*. (Tietosuojavaltuutetun toimisto 2019)

### 5.6.2 Asiakkaiden profilointi

Tietosuoja-asetuksen (2016/679) artiklan 4 kohdassa 4 määritellään ”*profiloinnin*” tarkoittavan:

*” mitä tahansa henkilötietojen automaattista käsittelyä, jossa henkilötietoja käyttämällä arvioidaan luonnollisen henkilön tiettyjä henkilökohtaisia ominaisuuksia, erityisesti analysoidaan tai ennakoitetaan piirteitä, jotka liittyvät kyseisen luonnollisen henkilön työsuoritukseen, taloudelliseen tilanteeseen, terveyteen, henkilökohtaisiin mieltymyksiin, kiinnostuksen kohteisiin, luotettavuuteen, käyttäytymiseen, sijaintiin tai liikkeisiin, ”*  
(EUR-Lex 2016: 4)

Profilointi koostuu tietosuoja-asetuksen (2016/679) näkökulmasta kolmesta eri komponentista:

- automattisesta tai osittain automaattisesta käsittelystä
- se suoritetaan henkilötiedoilla
- siinä arvioidaan luonnollisen henkilön henkilökohtaisia ominaisuuksia.

Euroopan neuvoston suositukseen CM/Rec (2010)132, sisältyvää profiloinnin määritelmää voidaan pitää myös sen käyttökelpoisena selityksenä. Sen mukaan profilointiin voi kuulua seuraavat kolme eri vaihetta:

- tiedon kerääminen
- korrelaatiosuhteiden tunnistamiseen tähtäävä automaattinen analysointi
- henkilön nykyiseen tai tulevan käyttäytymiseen liittyvien attribuuttien tunnistamiseen tähtäävä korrelaation soveltaminen

29 artiklan mukaisen tietosuojatyöryhmän (2017: 8) mukaan, profiloinnin voidaan katsoa yleisesti olevan tiedonkeruuta henkilöstä, tai ryhmästä henkilöitä sekä henkilöön liittyvien attribuuttien tai käyttäytymisen arvioimista tämän sijoittamiseksi tiettyyn luokkaan tai ryhmään, joiden kautta pystytään ennustamaan tai analysoimaan vaikkapa henkilön:

- kykyä tehtävän suorittamiseen
- mielenkiinnon kohteita
- käyttäytymisen todennäköisyyttä

Koska ACPS -järjestelmä suorittaa vakuutusyhtiön keräämiin asiakkaiden henkilötietoihin perustuvaa automaattista tiedonkäsittelyä, tarkoituksenaan löytää myynnin hitraten perusteella korreloivia henkilökohtaisia ominaisuuksia agenttien ja asiakkaiden väliltä, *voidaan toiminnan katsoa täyttävän Tietosuoja-asetuksen (2016/679) mukaisen profiloinnin määritelmän.*

### 5.6.3 Automaattinen päätöksenteko

Automatisoidut päätökset voivat olla osittain päällekkäisiä profiloinnin kanssa tai sen tuloksia. Puhtaasti automatisoidulla päätöksenteolla tarkoitetaan teknistä kyvykkyyttä päätöksien tekemiseen, vailla ihmisen osallisuutta. (29 artiklan mukainen tietosuojatyöryhmä 2017: 8)

Päätöksenteon katsotaan olevan automaattista, kun

- Päätöksenteko perustuu pelkästään automaattiseen henkilötietojen käsittelyyn

- tehtävillä päätöksillä on oikeusvaikutuksia tai ne vaikuttavat muulla tavoin merkittävästi rekisteröityyn.

(Tietosuojavaltuutetun toimisto 2019).

Profilointia ja automaattisia päätöksiä voidaan käyttää henkilötietojen käsittelyyn liittyvissä toiminnoissa joko yhdessä tai erikseen. Profilointia voidaan näin ollen suorittaa ilman automaattista päätöksentekoa, automaattista päätöksen teko ilman profilointia tai ne voivat liittyä samaan toimintoon. Profilointia voi myös sisältyä päätöksiin, jotka eivät sisällä pelkästään automaattista päätöksentekoa, vaan sisältävät esimerkiksi päätöksentekoprosessiin merkityksellisellä tavalla osallistuvan luonnollisen henkilön. (Tietosuojavaltuutetun toimisto 2019; 29 artiklan mukainen tietosuojatyöryhmä 2017: 8).

Mikäli ACPS- järjestelmän asiakasprofiilissa käytettyjä tietoja käytettäisiin vakuutusturvan myöntämiseen tai eväämiseen koneellisesti, olisi kyseessä mahdollisesti automaattinen päätöksenteko. Mikäli koneellisesti suoritettua asiakasprofilointia käytetään ainoastaan markkinoinnillisessa toiminnassa, kuten tässä tapauksessa prospektiasiakkaiden ohjaamisessa potentiaalisimmalle agentille, eivät koneellisesti tehdyt päätökset aiheuta niihin kohdistuville henkilöille oikeusvaikutuksia. Näin ollen voidaan katsoa, *että edellä mainittu toiminta ei täytä Tietosuoja-asetuksen (2016/679) mukaista automaattisen päätöksenteon määritelmää.*

#### 5.6.4 Automaattiseen tietojenkäsittelyyn perustuva markkinointi

ACPS-järjestelmän perustuessa asiakastietokannassa olevien henkilötietojen automaattiseen käsittelyyn, on sitä käyttävän organisaation, eli rekisterinpitäjän, arvioitava soveltuuko edellä mainittu automaattista päätöksentekoa koskeva sääntely sen omaan toimintaan. (Tietosuojavaltuutetun toimisto 2019)

Mikäli järjestelmää käytetään ainoastaan markkinoinnin työkaluna etämyynnin prospektoinnissa, sekä asiakkaiden ja agenttien yhdistämisessä profiloinnin perusteella,

eikä esimerkiksi vakuutusten myöntämiseen liittyvissä päätöksissä, ei profiloinnin sinällään voida katsoa aiheuttavan sitä koskeville henkilöille oikeusvaikutuksia vastaavia merkittäviä päätöksiä. Markkinointia ei tällöin määritellä automaattiseksi päätöksenteoksi, eikä näin ollen automaattista päätöksen tekoa koskeva sääntely ulotu siihen. (Tietosuojavaltuutetun toimisto 2019)

Kohdennettuun profilointiin perustuvalla markkinoinnilla voi kuitenkin olla yksilöihin tai henkilöryhmiin kohdistuvia merkittäviä vaikutuksia, joita tulee arvioida erikseen. Eriksen arvioitavia seikkoja ovat muun muassa:

- Profilointimenettelyn tunkeilevuus
- Markkinointitoimenpiteiden kohteena olevien odotukset ja toiveet
- Kanava, jonka kautta markkinointia suoritetaan
- Markkinoinnin kohteena olevien haavoittuvuus
- Yksilöille suunnatun markkinoinnin vaikutus erilaisiin henkilöryhmiin, kuten vähemmistöihin

Tietosuoja-asetuksessa (2016/679) kiinnitetään myös erityistä huomioita lapsiin kohdistettuun markkinointiin, joiden henkilötietoja on pyrittävä suojaamaan kyseen ollessa:

- Henkilötietojen käyttämisestä markkinointitarkoituksiin
- Henkilö- tai käyttäjäprofiilien luomisesta
- Henkilötietojen keräämisestä, lapsen käyttäessä hänelle suunnattuja palveluita.

*Ohessa mainittuja erikseen huomioitavia seikkoja on arvioitava aina tapauskohtaisesti ACPS-järjestelmää varten luotavien asiakasprofiilien suunnittelun yhteydessä.*

Muita profilointiin liittyviä, huomioitavia seikkoja:

- Henkilötietojen kyseenomaiselle käsittelylle tulee pyytää aina rekisteröidyn *nimenomainen lupa.*

- Rekisteröidylle tulee taata oikeus *pääsyn saamisesta häntä koskeviin tietoihin.*
- Rekisteröidylle tulee taata oikeus profiilin lähtötietojen *oikaisemiseen ja poistamiseen.*
- Rekisteröidyllä on tietyissä tilanteissa oikeus *vastustaa* häntä koskevien henkilötietojen käsittelyä. Mahdollisuudesta käyttää vastustamisoikeutta, täytyy ilmoittaa rekisteröidylle.
- Tietosuojaa koskeva vaikutusten arviointi tulisi suorittaa.

(Tietosuojavaltuutetun toimisto 2019)

## 6. TOIMINNAN SUUNNITTELUTUTKIMUS

*Toiminnan suunnittelututkimus* (Action Design Research) tai toisin ilmaistuna *suunnittelutoimintatutkimus* on menetelmällisesti erittäin samakaltaista perinteisempien *suunnittelutieteellisen tutkimuksen* ja *toimintatutkimuksen* kanssa. Kaikissa edellä mainituissa menetelmissä tutkijan pyrkimyksenä on produsoida aiempaan tieteelliseen tutkimukseen perustuvia, eksakteja ratkaisuja tai interventioita, omassa autenttiossa ympäristössään sijaitseviin relevantteihin tarpeisiin tai ongelmiin. (Tiainen ym. 2015: 2; 19-20; 24; Järvinen 2018: 104)

Edellä mainitut menetelmät kuitenkin eroavat toisistaan jossain määrin ja soveltuvat näin ollen parhaiten hieman erilaisiin tutkimusongelmiin ja -ympäristöihin. Suurimpia eroja metodien välillä on muun muassa se, että kun *suunnittelutieteellisessä tutkimuksessa* tutkija tekee tutkimusta tarkoituksellisesti erillään kohdeorganisaatiosta, on *toimintatutkimuksessa* ja *toiminnansuunnittelututkimuksessa* keskeistä taas tutkijan ja kohdeorganisaation välinen yhteistyö. (Tiainen ym. 2015; 3; 19-20; 24) Toisin kuin suunnittelutieteellisessä tutkimuksessa, suunnittelutoimintatutkimuksessa ei myöskään erotella rakennus- ja arviointivaiheita omiksi aliprosesseikseen, vaan niiden katsotaan kuuluvan tiiviisti samaan prosessiin. (Järvinen 2018: 129-130) Niin suunnittelutieteelliseen-, kuin suunnittelutoimintatutkimukseenkin perustuvia ratkaisuja kutsutaan *artefakteiksi*. Toimintatutkimus eroaa edellä mainituista sikäli, että se ei fokusoidu niinkään artefaktien suunnitteluun vaan tähtää organisaation käytäntöjen muutokseen, *interventioon*. (Tiainen ym. 2015: 19; 24) Artefaktit tarkoittavat useimmiten joko olemassa olevien ratkaisujen parannuksia tai kokonaan uusia innovaatioita. Eksakti artefakti täytyy aina pohjautua aiempaan tietoon ja teorioihin. (Hevner ym. 2004: 82- 84; Peffers ym. 2008: 49)

Toiminnan suunnittelututkimuksen voidaankin katsoa olevan eräänlainen yhdistelmä suunnittelutieteellistä tutkimusta ja toimintatutkimusta. (Tiainen ym. 2015:19) Sen voidaan kuvata olevan tiedon tuottamista käytäntöjen suunnitteluun ja ohjaamiseen tavalla, jossa tutkimusympäristön todellisuus ilmenee osana tutkimusprosessia (Järvinen 2018: 130)



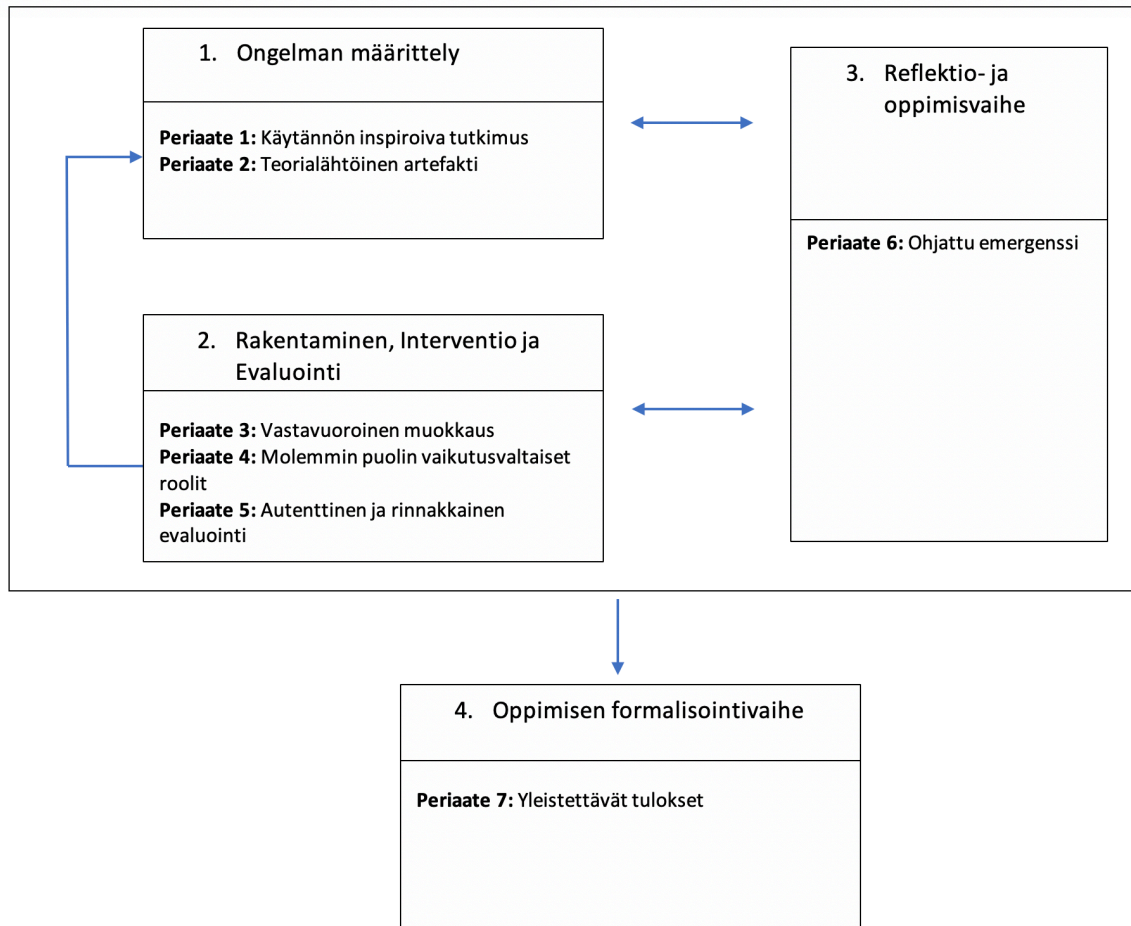
Koska tässä tutkimuksessa keskeisimpinä tavoitteina on todelliseen kohdeympäristöön suunniteltavan IT-artefaktin kehittäminen ja toisaalla taas tiivis tutkijan sekä kohdeorganisaation välinen yhteistyö sen jokaisessa kehitysvaiheessa, päädyttiin siinä käyttämään Seinin, Hendfridssonin, Puraon, Rossin ja Lindgrenin (2011) kehittämää ADR (Action Design Research) -metodia. Menetelmä on kehitetty suunnittelutieteellisen tutkimuksen paradigmaan liittyvien puutteiden, kuten organisatorisen kontekstin relevanssin vähäisen vaikutuksen kehitys- ja evaluointisykliin, vuoksi. ADR-metodi on yleisesti hyväksytty menetelmä tietojärjestelmätieteen tutkimuskentällä, ja sen edellä mainitut kehittäjät ovat julkaisseet siitä kattavan kuvauksen mm. alalla laajalti arvostetussa *MIS Quarterly* -lehdessä. ADR-metodin todettiin vastaavan hyvin käsillä olevaan tutkimusasetelmaan ja se valikoitui lopulta parhaan soveltuvuutensa takia tutkimusta kokonaisuudessaan ohjaavaksi menetelmäksi. (Sein ym. 2011: 40-45; Tiainen ym. 2015: 19-20)

ADR-metodi on kehitetty tuottamaan ohjailevaa suunnittelutietoa organisaatioympäristössä tapahtuvan IT-artefaktien rakentamisen ja arvioinnin yhteydessä. Se keskittyy kahteen erilliseen haasteeseen: spesifissä kohdeorganisaatiossa kohdattujen ongelmatilanteiden esiintuontiin interventioiden ja arvioinnin kautta, sekä toisaalla varsinaisen tilanteessa ilmenevät ongelmaluokat osoittavan IT-artefaktin rakentamiseen ja arviointiin. Metodi keskittyy näin ollen refleктоimaan yhtä aikaa niin teoreettista esitietoa ja tutkijoiden aikeita kuin artefaktin käyttäjien vaikutusta ja jatkuvaa sen todellisessa kontekstissa tapahtuvaa käyttöä. (Sein ym. 2011: 40) ADR-metodin keskittyessä kokonaisuuksiin, käsittelee se ainakin kolmea kriittistä perusongelmaa:

- (1.) Arviointi ei voi seurata rakentamista jaksoissa kuten suunnittelutieteellisestä tutkimuksesta tutussa state-gate -mallissa.
- (2.) Kontrolloitu evaluointi on vaikeaa suunnitella ja johtaa.
- (3.) Innovaatio täytyy olla määritelty luokalle järjestelmiä, joita kokonainen artefakti ilmentää.

(Sein ym. 2011: 40)

ADR-metodi onkin kokonaisuus, joka sisältää valmiit vaiheet sekä niihin sisältyvät ankkuriperiaatteet, jotka käsittelevät ja auttavat ratkomaan juuri näitä ongelmia. (Sein ym. 2011: 40) ADR-metodin eri vaiheet ja niiden sisältämät periaatteet ovat esiteltyinä alla olevassa kuvassa.



**Kuva 7.** ADR-metodin vaiheet ja periaatteet suomennettuna ja sovellettuna (Sein ym. 2011: 41)

### 6.1 Ongelman määrittely

ADR-metodin ensimmäinen vaihe lähtee liikkeelle käytännön toiminnassa havaitusta tai tutkijoiden kohdeympäristössä ennakoimasta ongelmasta, joka luo varsinaisen impulssin tutkimusponnistusten käynnistämiseksi. Ongelman formulointivaiheen pääasiallisena tavoitteena on tunnistaa ja käsitteellistää olemassa oleviin teorioihin ja teknologioihin perustuvat ongelmaan liittyvät tutkimusmahdollisuudet. (Sein ym. 2011: 40)

Tutkimuksen muodostamisessa käytettävä syöte voi olla peräisin kohdeorganisaatiossa päivittäin toimivilta henkilöiltä, loppukäyttäjiltä, tutkijoilta, olemassa oleviin teknologioihin liittyvästä tiedosta, katselmuksesta aiempia tutkimuksia tai yhdistelmästä näitä. ADR-metodin mukainen ongelman määrittelyvaihe pitää sisällään syötteeseen perustuvan *tutkimuksen alustavan laajuuden määrittelyn, siihen liittyvien toimijoiden roolien jakamisen ja osallistumisen laajuudesta päättämisen sekä alustavien tutkimuskysymysten muodostamisen*. Ongelman määrittelyvaihe tehdään lisäksi useimmiten rinnakkain ongelman alustavan empiirisen tutkimisen kanssa.

ADR-metodin mukaisen ongelman määrittelyvaiheen kriittisiä elementtejä ovat siihen osallistuvan organisaation sitoutumisen varmistaminen myös myöhempiä vaiheita varten sekä ongelman määrittely kokonaisen ongelmia sisältävän luokan ilmentymänä. Vaikka määrittelmä voi olla alustava, antaa se pohjan myöhemmälle työlle käsittelemällä laajempaa ongelmien luokkaa ja osoittamalla aidosti kohdatun ongelman ratkaisuun liittyvän tension. Ongelman ollessa tunnistettu, skaalattu ja artikuloitu toimii se kimmokkeena tutkimuksen jatkoponnisteluille ja luo samalla hyvän pohjan uuden tieteellisen tiedon luonnille. Kuten toimintatutkimuksessa, on toiminnan suunnittelututkimuksessakin suosituksena solmia tutkijan ja toimeksiantajan välille selkeä sopimus, joka toimii perustana yhteisymmärrykselle tutkimustavasta, -fokuksesta ja -laajuudesta, sekä määrittelee tutkijoita ja organisaatiossa työskenteleviä henkilöitä sisältävän tutkimustiimin roolit ja vastuut.

Ongelman määrittelyvaihe pitää sisällään kuusi tehtävää: (1) Tutkimusmahdollisuuden tunnistamisen ja käsitteellistämisen. (2) Alustavien tutkimuskysymysten muodostamisen. (3) Ongelman esittämisen kokonaisen ongelmia sisältävän luokan ilmentymänä. (4) Ongelmaan vaikuttava teoreettinen perustan ja aiemman teknologisen edistyksen

tunnistamisen. (5) Kohdeorganisaation pitkäaikaisen sitoutumisen varmistamisen. (6) Roolien ja vastuiden järjestelemisen. (Sein ym. 2011: 41)

Ongelman määrittelyvaihe noudattaa myös kahta periaatetta:

#### Periaate 1: Käytännön inspiroima tutkimus

ADR-metodin ongelman määrittelyvaiheen ensimmäinen periaate korostaa näkökulmaa, jossa todellisessa ympäristössään, esimerkiksi organisaation toimintakentällä, esiintyvät ongelmat nähdään mahdollisuutena uuden tiedon luontiin. Tutkimustoiminnan tulisi näin ollen olla ongelmalähtöistä. Toiminnan suunnittelututkimus etsii tarkoituksellisesti mahdollisuuksia uuden tiedon luontiin teknologisten ja organisatoristen alueiden risteyskohdista. ADR-tutkimusryhmän ei tule pyrkiä ratkaisemaan ongelmaa kuten esimerkiksi ohjelmistoinsinööri tai puuttua ainoastaan sen organisatoriseen kontekstiin, vaan sen tulisi tuottaa tietoa, joka on sovellettavissa kokonaiseen luokkaan ongelmia, jota käsillä oleva ongelma esimerkinomaisesti edustaa. (Sein ym. 2011: 40)

#### Periaate 2: Teorialähtöinen artefakti

ADR-metodin ongelman määrittelyvaiheen toinen periaate painottaa ADR-metodin kautta luotujen ja evaluoitujen artefaktien teorialähtöisyyttä. Teorian määrittelyssä Sein ym. (2011) käyttivät Gregorin (2006) ”Voiman yleistää” kriteeristöä, joka käsittelee järjestelmiä väitteitä, jotka sallivat yleistyksen ja abstrahoinnin pitämisen teoriana. Teorioiden ennustusvoiman taso sekä tausta voivat vaihdella luonnontieteellisistä laeista kapea-alaisempiin, kuten esimerkiksi teknologian hyväksynnän malli, TAM (Technological Acceptance Model). ADR-tutkijan tulee aktiivisesti sisällyttää teoreettisia elementtejä kokonaiseen artefaktiin ilmentäen teoriaa sosiaalisesti tunnistettavassa muodossa, tuloksena alustava teoriapohjainen suunnitelma artefaktista. Tämän jälkeen artefakti altistetaan organisaation käytännön arjelle, joka tarjoaa pohjan myöhemmille rakentamisen, intervention ja evaluoinnin sykleille. (Sein ym. 2011: 40-41)

## 6.2 Rakentaminen, interventio ja evaluointi (RIE)

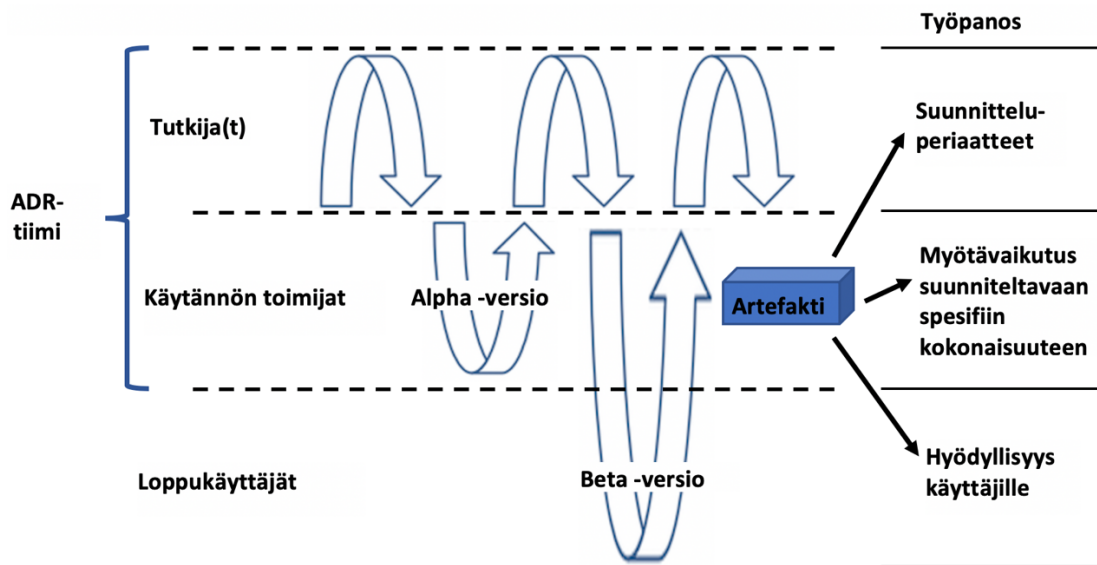
ADR-metodin toisessa vaiheessa käytetään ongelman lavastusta ja ensimmäisessä vaiheessa omaksuttuja teoreettisia oletuksia. Teoreettisia oletuksia, tai toisin ilmaistuna pmissettä, käytetään alustavan IT artefaktin mallin luontiin, jota seuraavaksi muokataan sekä organisaatiossa tapahtuvan käytön että myöhempien suunnittelusyklien yhteydessä. Tämä *RIE -sykliksi* kutsuttu vaihe toteutetaan iteratiivisena prosessina kohdeympäristössä niin että se punoo yhteen IT artefaktin *rakentamisen*, siihen liittyvän *intervention* organisaatiossa sekä *evaluoinnin*, lopputuloksenaan artefaktin reaalinen malli. Eräänlaisen jatkumon muodostavien syklien aikana artefaktia ja sen taustalla olevaa ongelmaa evaluoidaan jatkuvasti sekä sen suunnitteluperiaatteita puetaan ymmärrettävään sanalliseen muotoon, valittuun luokkaan järjestelmiä. RIE-vaiheen tarkoituksena on tuottaa uusia huomioita ja innovaatioita sekä myös selventää innovaatioiden tapahtumapaikka eli lokus, joka voi olla artefaktin suunnittelussa tai organisatorisessa interventiossa. Lokus vaikuttaa merkittäväällä tavalla ADR-tiimin jatkossa noudattaman tutkimuksen rakenteeseen, sen suuntautuessa joko *IT-dominanttiin RIE:n malliin*, tai *organisaatiodominanttiin RIE:n malliin*. Organisaatiodominantin mallin soveltuessa tapauksiin, joissa ADR-tutkimuksen tavoitteena on tuottaa suunnittelutietoa organisatorisiin interventioihin liittyviin innovaatioihin, ja käsillä olevan tutkimuksen taas keskittyessä IT-artefaktin kehittämiseen, käsitellään seuraavaksi tarkemmin ainoastaan IT-dominantin RIE:n yleistä mallia. (Sein ym. 2011: 41-43)

IT-dominantin RIE:n malli soveltuu tapauksiin, joissa tutkimus tähtää innovatiiviseen, alusta alkaen luotavaan uuteen teknologiseen malliin. Organisaatiossa työskentelevillä henkilöillä on mahdollisuus vaikuttaa läpi tämän vaiheen artefaktin malliin käyttäen hyväksi ensikäden tietoaan sen projisoidusta käytöstä. Artefaktin aikaiset mallit ja alpha-versiot toimivat kevyinä interventioina rajatussa organisatorisessa kontekstissa. Alati näiden kevyiden organisatoristen interventioiden kautta testattava, kehittyvä artefakti alistetaan siihen liittyvineen teorioineen toistuvasti osallistuvien henkilöiden oletuksille,

tiedolle ja odotuksille, tavoitteena osallistava ja organisaatiota sitouttava prosessi, joka johtaa lopulliseen, kokonaisen artefaktin malliin. (Sein ym. 2011: 41-43)

Edellä kuvatun laisen vuorovaikutuksen kautta rakennettu valmis beta-versio artefaktista vietään seuraavaksi laajempaan organisatoriseen kontekstiin evaluoitavaksi, suorittamalla kokonaisvaltainen interventio sen varsinaisessa käyttöympäristössä. Tämän vaiheen tavoitteena on loppukäyttäjäkontekstista käsin tapahtuva artefaktin jatkuva jalostaminen, sen uudelleen muokkaamisen kautta. Tämä vaihe voi päättyä tutkijoiden poistumiseen tai laukaista edelleen uuden RIE-syklin. (Sein ym. 2011: 41-43)

Alpha -version evaluointisyklit ovat muodollisia, myötävaikuttaen artefaktin jalostumiseen ja tuoden esille niin ennakoituja kuin ennakoimattomiakin seurauksia. Myöhempi beta -version evaluointi on yhteen vetävää, arvioiden sen arvoon ja hyötyihin liittyviä tuloksia. Artefaktin emergentistä luonteenlaadusta johtuen, kontrolloitu evaluointi voi olla vaikeaa. Evaluointi mahdollisuudet tulisikin seurata luonnollista kontrollia aina kun mahdollista. Autenttisuus on ADR-tutkimuksessa aina kontrolloitua tutkimusasetelmaa tärkeämpi ainesosa. (Sein ym. 2011: 43-44)



**Kuva 8.** IT-dominantin RIE:n yleinen malli suomennettuna ja sovellettuna (Sein ym. 2011: 42)

RIE-vaihe pitää sisällään neljä tehtävää: (1) Lopullisen tiedonluonti kohteen selvittämisen. (2) RIE muodon valinnan tai kustomoinnin. (3) RIE sykli(en) toteuttamisen. (4) Mahdollisten lisäsyklien tarpeen arvioinnin ja toistamisen.

RIE-vaihe rakentuu lisäksi vahvasti kolmen, eri tutkimukseen vaikuttavien henkilöiden ja toimialueiden erottamattomuutta korostavan pääperiaatteen; *vastavuoroisen muokkauksen, molemmin puolin vaikutusvaltaisten roolien sekä autenttisen ja rinnakkaisen arvioinnin*, varaan. (Sein ym. 2011: 43)

#### Periaate 3: Vastavuoroinen muokkaus

*Vastavuoroinen muokkaus* korostaa IT-artefaktin ja organisatorisen kontekstin yhteistä, toisistaan erottamatonta vaikutusta tutkimuksessa. Tutkimusryhmä voi osallistua toistuviin päätössykleihin yksityiskohtaisemmin jokaisella toimialueella, hieman samankaltaisesti kuin DeGrace ja Stahl (1990) kuvaavat ”visaisten ongelmien” ratkaisemista.

Iteratiivisessa prosessissa tutkimusryhmä voi esimerkiksi käyttää valittuja suunnitteluun liittyviä käsitteitä muokatakseen sen tulkintaa organisatorisesta ympäristöstä, käyttää sen jatkuvasti kasvavaa ymmärrystä kohdeympäristöstä vaikuttaakseen valikoimaan suunnittelukäsitteitä tai lomittaa molemmat toistensa kanssa. Valitusta RIE-mallista riippuen lähtöpiste iteraatioihin voi vaihdella heijastaen tutkimusasetelmaa ja tutkijan näkemystä. (Sein ym. 2011: 43)

#### Periaate 4: Molemmin puolin vaikutusvaltaiset roolit

Molemmin puolin vaikutusvaltaiset roolit korostavat vastavuoroisen oppimisen tärkeyttä projektiin osallistujien välillä. ADR tutkijoiden antaessa panoksensa teoretiedon ja teknologisten edistysaskeleiden muodossa, organisaation käytännön toimijat antavat

tutkimuksen käyttöön arvokasta tietoa organisaation työtavoista sekä käytännön hypoteeseja. Eri perspektiivit ja myötävaikuttaminen voivat kilpailla toistensa kanssa tai olla toisiaan täydentävää. Lukuisat eri osallistujien omaksumat roolit eivät välttämättä ole kuitenkaan toisiaan poissulkevia. Yksilöiden työskennellessä erilaisissa tai jopa yhtä aikaa useanlaisissa rooleissa, selkeä vastuualueiden jako on tärkeää, jotta kaikkien osallistujien osaaminen heijastuu tutkimukseen oikealla tavalla. (Sein ym. 2011: 43)

#### Periaate 5: Autenttinen ja rinnakkainen evaluointi

Autenttinen ja rinnakkainen evaluointi korostaa ADR-tutkimuksen tunnusmaisimpia piirteitä. Evaluointi ei näin ollen ole rakennusvaiheen jälkeinen erillinen tutkimusprosessin vaihe, vaan päätökset kokonaisen artefaktin suunnittelusta, muotoilusta ja uudelleenmuotoilusta sekä organisatorisiin työtapoihin tehtävät interventiot punoutuvat yhdeksi jatkumoksi, jatkuvan evaluoinnin yhteydessä.

#### 6.3 Reflektio- ja oppimisvaihe

Reflektio- ja oppimisvaihe siirtyy käsitteellisesti erityiseen tapaukseen liittyvän ratkaisun rakentamisesta, opitun soveltamiseen laajempaan luokkaan ongelmia. Tämä vaihe on jatkuva ja suoritetaan rinnakkain kahden ensimmäisen vaiheen kanssa. Reflektio- ja oppimisvaihe tunnistaa, että tutkimusprosessi sisältää myös muuta kuin pelkkää ongelmanratkaisua. Tietoinen ongelman kehityksen, valittujen teorioiden ja hahmottuvan kokonaisuuden reflektointi on tutkimuksen kannalta kriittistä niin että kontribuutio olemassa olevaan tietoon tunnistetaan. On myös tärkeää mukauttaa tutkimusprosessi perustumaan aikaisiin evaluointituloksiin, kokonaiseen artefaktiin liittyvän kasvavan ymmärryksen reflektoinniksi. Reflektio- ja oppimisvaihe pitää sisällään kolme tehtävää: (1) Reflektoi suunnittelu ja uudelleensuunnittelua koko projektin ajan. (2) Evaluoi kiinnipysymistä periaatteissa. (3) Analysoi interventiotuloksia määriteltyjen tavoitteiden mukaisesti. Tämä vaihe rakentuu vahvasti yhden periaatteen; *ohjatun emergenssin*, varaan. (Sein ym. 2011: 44)



## Periaate 6: Ohjattu emergenssi

Termien *ohjattu* (viittaa ulkoiseen, tarkoitukselliseen interventioon) ja *emergenssi* (viittaa orgaaniseen evoluutioon) ollessa määritelmällisesti lähes toistensa vastakohtia, tavoittaa tämä periaate yhden ADR-tutkimuksen tärkeimmistä luonteenpiirteistä, eli näiden kahden toisiinsa nähden jopa ristiriitaisen näkökulman vuorovaikutuksen. Ohjattu emergenssi korostaa, että kokonaisen artefaktin ei tulisi heijastaa ainoastaan periaatteen 2 mukaista alustavaa, tutkijoiden luomaa mallia vaan myöskin sen jatkuvaa muovautumista organisaation käytössä. Muovautumista aiheuttaa niin organisaation sisältä tulevat näkökulmat ja osallistujat, kuin rinnakkaisen ja autenttisen evaluoinnin tulokset. Nämä hienosäädöt voivat pienten korjausten lisäksi pitää sisällään huomattaviakin mallin suunnittelun, metasuunnittelun ja metavaatimusten muutoksia. Odotetut ja odottamattomat seuraukset johdattavat edellä mainittuihin hienosäätöihin RIE:een liittyvien iterointien aikana, tarjoten ADR tutkimusryhmälle mahdollisuuden tuottaa ja kehittää suunnitteluperiaatteita koko prosessin ajan. ADR-tiimin pitäisi periaatteen mukaisesti olla alttiina kaikille signaaleille, jotka indikoivat tällaisesta meneillään olevasta hienosäädön tarpeesta. (Sein ym. 2011: 44)

### 6.4 Oppimisen formalisointivaihe

ADR-metodin neljännen vaiheen tavoitteena on oppimisen formalisointi. ADR-projektin sisällä tapahtunut oppiminen tulisi kehittää edelleen yleisiksi luokan ratkaisukonsepteiksi kenttäongelmille. Tätä konseptuaalista askelmaa helpottaa vaiheessa 1 tehtävä yksittäisen ongelmatapauksen muuntaminen luokaksi ongelmia. Tutkijat hahmottelevat IT-artefaktin liittyvät oivallukset ja kuvaavat organisatorisia tuloksia oppimisen formalisoinniksi. Näitä tuloksia voidaan luonnehtia suunnitteluperiaatteiksi ja edelleen refleктоimalla hienosäädöt teoriaksi, joka vaikutti alustavaan malliin.

Oppimisen formalisointivaihe sisältää viisi tehtävää: (1) Oppimisen abstrahoinnin konsepteiksi luokalle kenttäongelmia. (2) Tuloksien ja tehtävien jakamisen käytännön toimijoiden kanssa. (3) Tulosten viestimisen sanallisina suunnitteluperiaatteina. (4) Oppimisen pukemisen sanoiksi valittujen teorioiden valossa. (5) Tuloksien formalisoinnin levitystä varten. Oppimisen formalisointivaihe pohjautuu yhteen periaatteeseen, *yleistettäviin tuloksiin*. (Sein ym. 2011: 44)

#### Periaate 7: Yleistettävät tulokset

Tuloksien yleistäminen on erityisesti ADR tutkimuksessa haastavaa, niiden erittäin suuren kohdeorganisaatioon liittyvän kohdentuvuuden takia. Tuloksena oleva kokonaisuus on määritelmältäänkin tukku ominaisuuksia eri toimialueilla. Kokonaisuus edustaa ratkaisua, joka osoittaa ongelman ja jotka molemmat voidaan yleistää. Tämä askel erityisestä ja uniikista, yleiseen ja abstraktiin on kriittinen ADR tutkimuksen rakenneosana. Sein ym. (2011: 44) suosittelevat kolmea tasoa tähän käsitteelliseen askelmaan. (1) Ongelmatapauksen yleistäminen, (2) ratkaisutapauksen yleistäminen, ja (3) Suunnitteluperiaatteiden johtaminen suunnittelu tutkimuksen tuloksista.

Ensimmäinen taso koostuu alkuperäisen ongelman taivuttamisesta luokan tapaukseksi (Periaate 1). Toinen taso sisältää erityisen ratkaisutapauksen uudelleen käsitteellistämisen luokaksi ratkaisuja, koska ADR tutkimus tuottaa erittäin organisaatiospesifin tuloksen. Kolmas taso vaatii spesifistä ratkaisutapauksesta opitun uudelleen konseptointia suunnitteluperiaatteiksi luokalle ratkaisuja. Nämä reflektio- ja oppimisvaiheessa tunnistetut ja jalostetut suunnitteluperiaatteet muotoillaan ja artikuloidaan kokonaan tämän vaiheen aikana. Suunnitteluperiaatteisiin sisällytetään kaikki valitun toimialueen ratkaisujen rakennusprosessista kerrytetty tieto sekä tietoa toisten luokkaan kuuluvien tapausten luonnista. Suunnitteluperiaatteet on muotoiltu ADR-projektin RIE-sykliden kautta, joiden johdatus seuraa induktiivista askelta niin että se yhdistää yleiset tulokset suunnitteluperiaatteiden muotoon, ratkaisujen luokaksi sekä ongelmien luokaksi. (Sein ym. 2011: 44-45)

## 7. PROFIILIEEN SUUNNITTELUPROSESSI

Suunnitteluprosessissa käytetään runkona edellä läpikäytyä ADR-metodia. Suunnitteluprosessin eri vaiheissa noudatetaan ADR-metodiin kuuluvia seitsemää periaatetta.

### 7.1 Ongelman määrittely

ADR-metodin ensimmäinen vaihe lähtee liikkeelle käytännön toiminnassa havaitusta tai tutkijoiden kohdeympäristössä ennakoimasta ongelmasta, joka luo varsinaisen impulssin tutkimusponnistusten käynnistämiseksi. Seuraavassa on käyty läpi tutkimuksen eteneminen ensimmäisessä vaiheessa määriteltyjen tehtävien läpi.

#### 7.1.1 Tutkimusmahdollisuuden tunnistaminen ja käsitteellistäminen

Tutkimusongelma ja sen tunnistaminen tapahtui keskusteluissa yrityksen alfan liiketoiminnan kehityksen johtamisesta vastaavan henkilön kanssa. Tutkimusongelma liittyy laajempaan kohdeorganisaation projektiin, jonka tarkoituksena on selvittää nykyaikaisen tekoälyn, koneoppimisen ja niin kutsuttujen neuroverkkojen hyödyntämispotentiaalia vahinkovakuutusyhtiön yksityisasiakkaille suuntaamassa Call Center -asiakaspalvelussa. Projektin yhtenä osiona on selvittää koneoppimisen ja neuroverkkojen hyödyntämistä käyttötapauksessa, jossa vakuutusyhtiön kontaktoimia asiakkaita pyritään edellä mainittuja teknologioita hyödyntäen ohjaamaan automaattisesti, niin asiakkaan, kuin vakuutusyhtiön näkökannalta potentiaalisimmille vakuutusyhtiön edustajille. Koska kohdeorganisaation tavoitteena profiloituneen asiakkaan ja myyjän yhdistämisessä on puhtaasti paremman myyntituloksen saavuttaminen, tarkoitetaan tässä yhteydessä potentiaalisimmalla vakuutusyhtiön edustajalla sitä agenttia, joka todennäköisimmin saavuttaa parhaan myyntituloksen kyseisen asiakkaan kohdalla.

Kohdeympäristössä havaitut suurimmat käytännön ongelmat eivät tässä tapauksessa liittyneet niinkään projektin teknologiseen toteutukseen, vaan pikemminkin sen liiketoiminnallisiin aspekteihin. Tarkemmin ottaen keskusteluissa ongelmaksi muodostui valitulle teknologialle, eli koneoppiville neuroverkoille tarjottavan syöte. Syöte, joka kyseisessä käyttötapauksessa sisältää erilaisia agenttien ja asiakkaiden ominaisuuksia, tulisi suunnitella niin että se sisältäisi asiakkaiden ostopäätöksen tekemiseen liittyvän tiedon valossa sellaista dataa, jota hyödyntämällä koneoppivat neuroverkot todennäköisimmin pystyisivät saavuttamaan asetetun tavoitteen eli ohjaamaan oppimisen kautta oikean asiakkaan sopivimmalle agentille. Varsinaisena impulssina tutkimuksen käynnistämiseksi toimivat kohdeorganisaatiossa esiin nousseet agenttien ja asiakkaiden profilointiin liittyvät kysymykset kuten; *Mitä myynnin lisäämisen kannalta merkittäviä ominaisuuksia asiakkailta ja agenteilta löytyy? Mitä dataa on mahdollista kysyä ja kerätä? Millaisen datan käyttö on EU:n yleisen tietosuoja-asetuksen (2016/679) puitteissa laillista?*

#### 7.1.2 Alustavien tutkimuskysymysten muodostaminen.

Tutkimustehtävien ja ongelmien laajuuden johdosta, niiden asettelussa on käytetty Hirsjärven, Remeksen ja Sajavaaran (2009: 126) Tutki ja kirjoita -teoksessa esitettyä lähestymistapaa, jossa muotoillaan aluksi pääongelma ja sitä analysoimalla jaetaan se useampiin osaongelmiin. Tutkimuksen pääongelma sekä osaongelmat muodostuivat lopulliseen muotoonsa, yhtä aikaa ongelman alustavan empiirisen sekä teoreettisen tutkimisen aikana.

Tutkimuksen pääongelma 1. muotoiltiin seuraavasti: *Miten vahinkovakuutusyhtiön puhelinpalvelukeskus pystyisi neuroverkkoja ja koneoppimista hyödyntämällä ohjaamaan asiakkaitaan, niin asiakkaan kuin vakuutusyhtiönkin näkökulmasta potentiaalisimmille agenteille?*

Osaongelmat jaettiin seuraavasti: 1.1. *Miten asiakkaat ja vakuutusyhtiöin edustajat profiloitetaan ja kategorisoidaan?* 1.2 *Mitä tietoja asiakkaista ja edustajista on saatavilla*

*ja mitä niistä voidaan käyttää? 1.3. Millainen tieto pitäisi teoriaan pohjautuen olla merkityksellistä tavoitteen toteutumisen kannalta? 1.4 Kuinka paljon parempiin myyntituloksiin (hitrate%) päästään löydettyjä ominaisuuksia käyttävällä, tekoälyohjatulla agentti–asiakas parituksella?*

### 7.1.3 Tutkimusongelma kokonaisen ongelmia sisältävän luokan ilmentymänä.

Toiminnan suunnittelututkimuksen tulisi tuottaa tietoa, joka on sovellettavissa kokonaiseen luokkaan ongelmia, joita käsillä oleva kohdeorganisaation ongelma ainoastaan esimerkinomaisesti edustaa. Tästä syystä tutkimus ei keskity yksinomaan kohdeorganisaation tapahtuvaan ongelman ratkaisuun vaan sen tarkoitus on tuottaa tietoa, joka on sovellettavissa kokonaiseen ongelmia sisältävään luokkaan. Tästä johtuen tutkimusongelma on rakennettu niin että se pyrkii ilmentämään yleisellä tasolla niitä ongelmia, joita tekoälyohjattuja järjestelmiä varten tehtyjen asiakas- ja agenttiprofiilien suunnittelu vakuutusyhtiöiden Call Center ympäristössä aiheuttaa. Tutkimuksen laajempi konteksti liittyy näin ollen yleisesti vakuutusyhtiöiden Call Center -keskuksiin, agenttien ja asiakkaiden profilointiin sekä koneoppivien neuroverkkojen hyödyntämiseen myynnin lisäämisessä. Tutkimuksessa tuotettu tieto tulee olla näin ollen hyödynnettävissä kohdeorganisaation spesifin ympäristön lisäksi, yleisesti vakuutusyhtiöiden Call Center -keskuksissa. (Sein ym. 2011: 40-41)

### 7.1.4 Ongelmaan vaikuttava teoriaperusta ja aiempi teknologinen edistys.

Neuroverkon opettamisessa käytettävä historiadataan perustuva syöte, joka kyseisessä käyttötapauksessa sisältää erilaisia agenttien ja asiakkaiden ominaisuuksia, tulisi suunnitella niin että se sisältäisi asiakkaiden ostopäätöksen tekemiseen liittyvien teorioiden perusteella sellaista dataa, jota hyödyntämällä koneoppivat neuroverkot todennäköisimmin pystyisivät saavuttamaan asetetun tavoitteen eli ohjaamaan oikean asiakkaan sopivimmalle agentille. Ongelman pääasiallisena teoreettisena perustana käytettiin Jobberin ja Lancasterin (2009) kuvausta kuluttajan päätöksentekoprosessiin

vaikuttavista tekijöistä, McDonalin ja Dunbarin (1995) sekä Kotlerin ja Kellerin (2016) kuvausta kuluttajamarkkinoiden segmentoinnista, Daniel Yankelovichin ja David Meerin (2006) kuvausta segmentoinnissa yleisimmin tapahtuvista virheistä, sekä mm. Alpaydinin (2014), Berryn ym.(2014) sekä Nisbetin ym. (2009) kuvausta koneoppimisesta sekä sen aiemmista sovelluksista.

#### 7.1.5 Kohdeorganisaation pitkäaikainen sitoutuminen

Kohdeorganisaation sitoutuminen varmistettiin solmimalla tutkijan ja toimeksiantajan välille sopimus, jossa sovittiin ADR-metodin käytöstä sekä fokuoitumisesta käyttötapaukseen, jossa vakuutusyhtiön kontaktoimia asiakkaita pyritään koneoppivia neuroverkkoja hyödyntäen ohjaamaan automaattisesti, niin asiakkaan, kuin vakuutusyhtiön näkökannalta potentiaalisimmille vakuutusyhtiön edustajille, tutkimuksen keskittyessä erityisesti myyjien ja agenttien profilointiin. Tutkimuksen laajuudeksi sovittiin alustavasti yksi RIE sykli, joka pitää sisällään tutkijan kehittämän Alpha -version artefaktista, sen evaluoinnin käytännön toimijoiden kanssa, sekä tutkijan muokkaaman Beta -version, joka testataan käytännössä loppukäyttäjien toimesta. Jatkosyklien tarvetta harkitaan erikseen ensimmäisen syklin jälkeen.

#### 7.1.6 Roolit ja vastuut.

Tutkimustiimi pitää sisällään:

- Projektin teknisestä toteutuksesta vastaavan henkilön, jonka kanssa sovitaan projektin teknisistä raameista ja jonka kanssa evaluoidaan artefaktin Alpha- ja Beta -versiot.
- Call Centerin yleisestä toiminnasta vastaavan henkilön, jolta kerätään tietoa projektin organisatorisista raameista ja jonka kanssa evaluoidaan artefaktin Alpha- ja Beta -versiot.

- CRM spesialisti, jonka kanssa sovitaan agenttien ja asiakkaiden käytettävissä oleviin ominaisuuksiin liittyvistä raameista ja jonka kanssa evaluoidaan artefaktin Alpha- ja Beta -versiot.
- Joukon agenteja, joiden toimesta lopullinen artefaktin Beta -versio testataan käytännössä.

Artefaktia testataan tekoälyohjatuille sekä satunnaiselle ryhmälle suunnatulla testillä, joiden tuloksia verrataan keskenään. Loppukäyttäjien eli agenttien vastuulle jää täten lopulta myyntityön suorittaminen samalla tavalla kuin tähänkin asti. Mikäli artefakti toimii tavoitteenmukaisesti, tulisi sen kasvattaa tekoälyohjatun ryhmän myynnin ”hitratea”. Testin tuloksia arvioidaan tarkemmin oppimisen formalisointivaiheessa.

## 7.2 Rakentaminen, interventio ja evaluointi

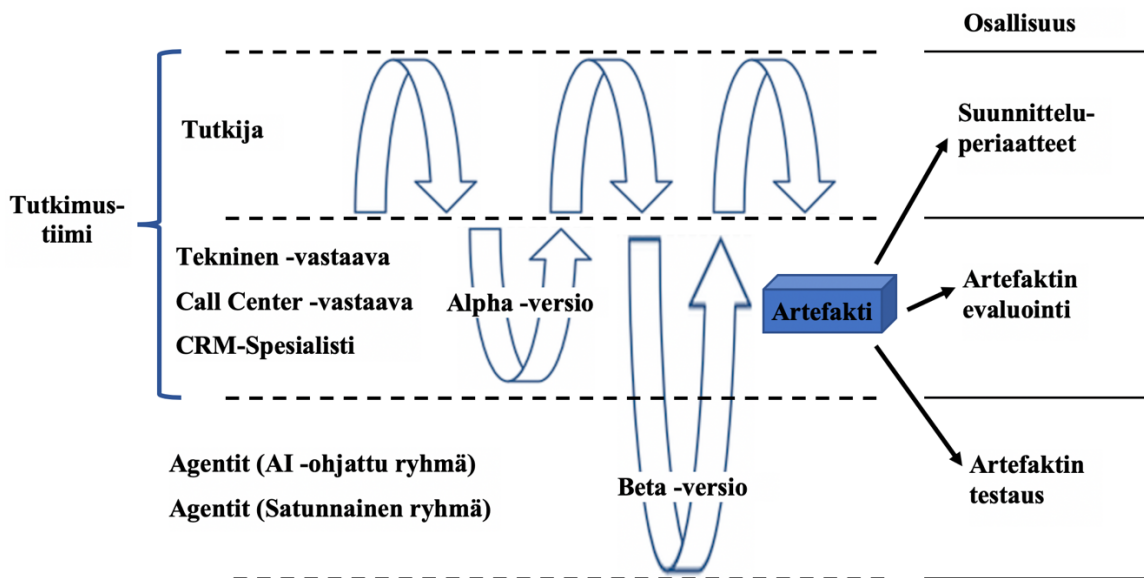
ADR-metodin toisessa vaiheessa käytetään ongelman lavastusta ja ensimmäisessä vaiheessa omaksuttuja teoreettisia oletuksia. Teoreettisia oletuksia, tai toisin ilmaistuna pmissettä, käytetään alustavan IT artefaktin mallin luontiin, jota seuraavaksi muokataan sekä organisaatiossa tapahtuvan käytön että myöhempien suunnittelusyklien yhteydessä. (Sein ym. 2011: 41-43) Seuraavassa on käyty läpi tutkimuksen eteneminen sen toisessa vaiheessa määriteltyjen tehtävien läpi.

### 7.2.1 Tiedonluonti kohteen lopullinen selvittäminen.

Tässä tutkimuksessa tuotettavien innovaatioiden tapahtumapaikaksi eli lokukseksi määrittyi organisaation kanssa käytyjen keskustelujen perusteella artefaktin suunnittelu. (Sein ym. 2011: 41-43) Tietoa pyritään tarkasti ottaen luomaan siitä, minkälainen tehokas ACPS -järjestelmän agenttien ja asiakkaiden profilointi tulisi teoretiedon ja käytännön toiminnan valossa olla.

### 7.2.2 RIE muodon valinta ja kustomointi.

Lokuksen vaikutus tutkimustiimin noudattaman tutkimuksen rakenteeseen on merkittävä, sen suuntautuessa joko *IT-dominanttiin RIE:n malliin* tai *organisaatiodominanttiin RIE:n malliin*. Organisaatio-dominantti malli soveltuu parhaiten tapauksiin, joissa tutkimuksen tavoitteena on tuottaa suunnittelutietoa organisatorisiin interventioihin liittyviin innovaatioihin. IT-Dominantti malli soveltuu taas parhaiten tapauksiin, joissa tutkimus tähtää innovatiiviseen, alusta alkaen luotavaan uuteen teknologiseen malliin. (Sein ym. 2011: 41-43) Käsillä olevan tutkimuksen keskittyessä IT-artefaktin kehittämiseen, valittiin sen muodoksi IT-dominantin RIE:n yleinen malli. Alla kuva tutkimuksessa sovelletusta, kustomoidusta IT-dominantin RIE:n mallista



**Kuva 9.** IT-dominantin RIE:n yleinen malli suomennettuna, kustomoituna ja sovellettuna tutkimukseen (Sein ym. 2011: 42)



### 7.2.3 RIE sykli(e)n toteutus.


RIE sykli(t) toteutetaan vaiheittain edellä kuvatun kustomoidun ja sovelletun IT-dominantin RIE-mallin mukaisesti. Tässä osioissa käydään läpi tutkimuksessa tehdyt RIE-sykli(t) vaihe vaiheelta.


#### 7.2.3.1 Alpha -version suunnittelu

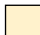
Artefaktin alpha -versioon kerättiin teoriaosuuden sekä haastattelujen perusteella mahdollisesti merkityksellisinä pidettäviä agentin ja asiakkaan ominaisuuksia. Merkityksellisinä pidettyjä ominaisuuksia käsiteltiin tutkimuksen osassa 5.5 ja artefaktin Alpha -versiossa niistä tärkeimpinä pidetyt kerättiin taulukkomuotoon evaluointia varten. Alpha -version tarkoitus on tuoda tutkijan tutkimustyön kautta tuottama näkökulma kohdeorganisaation tietoon. Kohdeorganisaation tutkimukselle asettama toive oli nimenomaan uusien näkökantojen avaaminen mahdollisesti merkityksellisten ominaisuuksien määrittämiseen, mistä syystä tutkijalla ei ollut ennakkotietoa organisaation pohdinnassa olleista tai kenties jo käyttämissä ominaisuuksista. Tavoitteena oli näin ollen tuottaa artefakti, joka mahdollisesti avaa organisaatiolle uusia ajatusväyliä siihen valittavien ominaisuuksien suhteen, ja joita yksitellen on tarkoitus validoida yhdessä tutkimustiimin kanssa RIE-syklin seuraavassa vaiheessa. Artefaktin ei ole tarkoitus tuoda esiin kaikkia mahdollisia käytettävissä olevia agenttien ja asiakkaiden ominaisuuksia, vaan poimia niistä tutkimustyön aikana esiin nousseet, läpikäydyn teoratiedon perusteella merkityksellisimmäksi arvioidut muuttujat. Asiakkaiden ja agenttien käyttäytymiseen liittyvien ominaisuuksien osalta artefaktiin valikoitui esimerkiksi tuotekategorioita ja yksittäisiä tuotteita joista kohdeorganisaatiolla oli haastattelujen perusteella positiivisia kokemuksia myyntiä suorittavien agenttien valikoinnin suhteen.


**Taulukko 4.** Taulukko agenttia kuvaavista merkitykselliseksi arvioituista ominaisuuksista.


Ominaisuus	Kuvaus ja perustelu
Sukupuoli	Joukko tyypillisiä perinteisessä markkinoinnissa käytettyjä demografisia asiakkaisiin liitettjä ominaisuuksia. Profiloivat agentin yleistä elämäntilannetta ja siihen liittyvää kokemusta. Selittävät ehkä jossain määrin agentin kykyä samaistua asiakkaan tilanteeseen. Liittyvät asiakkaan ostopäätökseen vaikuttaviin sosiaalisiin vaikutteisiin kuten sosiaaliseen luokkaan, viiteryhmään ja perheeseen. (s. 49-50, 38-45 ja 63-64)
Ikä	
Perheeseen liittyvä elämänvaihe	
Perheen koko	
Koulutus	
Asuintyyppi	
Asema taloudessa	
Postinumero	Profiloivat agentin synnyin- ja asuinpaikkaan liittyvää kokemusta. Selittävät ehkä jossain määrin agentin kykyä samaistua asiakkaan kulttuurilliseen viitekehukseen ja toimintaympäristöön. Liittyvät asiakkaan ostopäätökseen vaikuttaviin sosiaalisiin vaikutteisiin kuten kulttuuriin ja viiteryhmään. (s. 49-50, 38-45 ja 63-64)
Asuinpaikunki tai -kunta	
Synnyin alue	
Automerkki	Selittävät ehkä jossain määrin välillisesti agentin psykografista profiilia ja tätä kautta kykyä vastata asiakkaan ostopäätökseen vaikuttaviin henkilökohtaisiin vaikuttimiin kuten persoonallisuustyyppiin, elämäntyyliin ja motiiveihin. (s. 59-64 ja 38-48)
Malli	
Vuosimalli	
Moottorivilavuus	
Istumapaikkojen määrä	
Myyjän yleinen hitrate%	Selittävät agentin kykyä vastata asiakkaan ostotilanne- ja ongelmanratkaisutyyppiin. (s. 38-40 ja 56-57)
Työkokemus yhtiössä	
Autovakuutusten hitrate%	Yankelovichin ym. (2006: 10) mukaan segmentoinnissa yleisimmin tapahtuvat virheet liittyvät usein liialliseen kuluttajien identiteettiin keskittyminen, tuotteen tai tuotekategorian nykyisille ja potentiaalisille uusille asiakkaille merkityksellisimpien ominaisuuksien sijaan, sekä liian vähäiseen varsinaisen asiakaskäyttäytymisen painottamiseen. Tästä syystä viimeiset agentin ominaisuudet keskittyvät yksinomaan asiakkaiden käyttäytymiseen agenttien suhteen, jota voidaan mitata agenttien suoriutumisen eri tuotekategorioissa. Tuotealueittainen hitrate% selittää agenttien kykyä tehdä myyntiä eri tuotekategorioissa. (s. 49-52)
Moottoripyörävakuutusten hitrate%	
Venevakuutusten hitrate%	
Kotivakuutusten hitrate%	
Mökkivakuutusten hitrate%	
Henkilövakuutusten hitrate%	

 = Demografiset ominaisuudet

 = Geografiset ominaisuudet


 = Psykografiset ominaisuudet

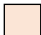
 = Geodemografiset ominaisuudet


 = Käyttäytymiseen liittyvät ominaisuudet


**Taulukko 5.** Taulukko asiakasta kuvaavista merkitykselliseksi arvioituista ominaisuuksista.


Ominaisuus	Kuvaus ja perustelu
Sukupuoli	Joukko tyypillisiä perinteisessä markkinoinnissa käytettyjä demografisia asiakkaisiin liitettyjä ominaisuuksia. Profiloivat asiakkaan yleistä elämäntilannetta. Liittyvät asiakkaan ostopäätökseen vaikuttaviin sosiaalisiin vaikutteisiin kuten sosiaaliseen luokkaan, viiteryhmään ja perheeseen. (s. 49-50, 38-45 ja 63-64)
Ikä	
Perheeseen liittyvä elämänvaihe	
Perheen koko	
Asuintyyppi	
Ammatti	
Koulutus	
Ammattiliitto	
Asema taloudessa	
Postinumero	Profiloivat asiakkaan kulttuurillista viitekehystä sekä toimintaympäristöä. Liittyvät asiakkaan ostopäätökseen vaikuttaviin sosiaalisiin vaikutteisiin kuten kulttuuriin ja viiteryhmään. (s. 49-50, 38-45 ja 63-64)
Asuinkaupunki tai -kunta	
Synnyin alue	
Automerkki	Selittävät ehkä jossain määrin välillisesti asiakkaan psykografista profiilia, persoonallisuustyyppiä, elämäntyyliä ja motiiveja. Liittyvät kokonaisuutena asiakkaan ostopäätökseen vaikuttaviin henkilökohtaisiin vaikuttimiin. (s. 59-64 ja 38-48)
Malli	
Vuosimalli	
Moottoritilavuus	
Istumapaikkojen määrä	
Käyttäjätas	Selittävät asiakkaan ostopäätökseen ja ongelmanratkaisutyyppiä. (s. 38-40 ja 56-57)
Käyttöaste	
Lojallisuustaso	
Valmiustaso	
Asenne tuotetta kohtaan	
Potentiaalipisteytys (PP)	Koska Yankelovichin ym. (2006: 10) mukaan segmentoinnissa yleisimmin tapahtuvat virheet liittyvät usein liialliseen kuluttajien identiteettiin keskittyminen, tuotteen tai tuotekategorian nykyisille ja potentiaalisille uusille asiakkaille merkityksellisimpien ominaisuuksien sijaan, sekä liian vähäiseen varsinaisen asiakaskäyttäytymisen painottamiseen. Tästä syystä viimeiset asiakkaan ominaisuudet keskittyvät yksinomaan asiakkaiden käyttäytymisen ennustamiseen potentiaalipisteytyksellä tuotekategorioittain. Potentiaalipisteytys mittaa yksittäisen asiakkaan ostopotentiaalia eri tuotekategorioissa. (s. 49-52)
Autovakuutuksen PP	
Moottoripyörävakuutuksen PP	
Venevakuutuksen PP	
Kotivakuutuksen PP	
Mökkivakuutuksen PP	
Henkilövakuutusten PP	

 = Demografiset ominaisuudet

 = Geografiset ominaisuudet

 = Psykografiset ominaisuudet

 = Geodemografiset ominaisuudet

 = Käyttäytymiseen liittyvät ominaisuudet

### 7.2.3.2 Alpha version evaluointi

Artefaktin alpha -versio evaluoitiin yhteistyössä kohdeorganisaation tutkimustiimin kanssa. Taulukko lähetettiin kohdeorganisaatioon kommentteja varten. Kommentit pyydettiin kirjattavaksi taulukon kommentit osioon. Saadut kommentit, tarkennuspyynnöt sekä muutos- ja lisäysehdotukset käytiin lisäksi läpi kohdeorganisaation teknisen vastaavan kanssa erikseen sovitussa etäpalaverissa. Kommentit ja muutosehdotukset esiteltynä alta löytyvissä taulukoissa:

**Taulukko 6.** Taulukko artefaktin agenttia kuvaavien ominaisuuksien alpha -version evaluoinnista:

Ominaisuus	Kohdeorganisaatiolta saadut kommentit ja muutosehdotukset
Sukupuoli	Nämä ominaisuudet ovat mielestämme merkittäviä ja kyselyn perusteella valtaosa meidän agenteistamme olisivat valmiita tiedot antamaan, kunhan noudatetaan hyvää tietoturvan tasoa.
Ikä	
Perheeseen liittyvä elämäntilanne	
Perheen koko	
Koulutus	
Asuintyyppi	
Asema taloudessa	
Postinumero	Keskustelussa tulneiden kokemusten perusteella asuin- ja synnyin paikalla on suuri merkitys kauppojen syntymisellä, joten nämä ominaisuudet ovat merkittäviä.
Asuinpaikka tai -kunta	
Synnyin alue	
Automerkki	Autoiluun ja kulkemiseen liittyvät ominaisuudet ovat merkittäviä ja riippuvat myös asuinpaikasta esim. keskusta / haja-asutusalue. Haluaisimme tähän vielä lisättävän, mikäli agentti käyttää esim. sähköautoa, yleisiä kulkuneuvoja tai liikkuu pyörällä/kävelen. Lisäksi voisimme käyttää persoonallisuus analyysiä kuten DISCiä.
Malli	
Vuosimalli	
Moottorikäyttö	
Istumapaikkojen määrä	
Myyjän yleinen hitrate%	Nämä tiedot ovat saatavissa ja kertovat yleisestä onnistumisesta.
Työkokemus yhtiössä	
Autovakuutusten hitrate%	Tuotekohtaiset hitratet ovat merkittävä tehtäessä tuotekohtaisia kampanjoita. Lisäisimme vielä lemmikki tuotteen. Keskustelussa esitettiin myös agentin harrastuksia, mutta niiden mallintaminen ja määrittäminen voisi johtaa liian isoon AI malliin. Lisäksi tuotekohtaiset hitratet varmasti korreloivat harrastuksiin. Lisättävä tuotealue voisi olla lemmikkivakuutus.
Moottoripyörävakuutusten hitrate%	
Venevakuutusten hitrate%	
Kotivakuutusten hitrate%	
Mökkivakuutusten hitrate%	
Henkilövakuutusten hitrate%	

= Demografiset ominaisuudet

= Geografiset ominaisuudet


= Psykografiset ominaisuudet


= Geodemografiset ominaisuudet


= Käyttäytymiseen liittyvät ominaisuudet


**Taulukko 7.** Taulukko artefaktin asiakasta kuvaavien ominaisuuksien alpha -version evaluoinnista.


Ominaisuus	Kohdeorganisaatiolta saadut kommentit ja muutosehdotukset
Sukupuoli	Näemme nämä ominaisuudet merkittävänä. Tosin ammattiliitto tulkitaan tällä hetkellä arkaluontoiseksi tiedoksi, joten se ehkä joudutaan käytännön syistä rajaamaan pois mallista. Mutta toisaalta yhteistyömme eri ammattiliittojen kanssa mahdollistaa tämän tiedon käytön kampanjoissa. Mahdollinen käyttö selvittää ennen testiä suoritettavassa Data Protection Impact Analysis - analyysissä.
Ikä	
Perheeseen liittyvä elämäntilanne	
Perheen koko	
Asuintyyppi	
Ammatti	
Koulutus	
(Ammattiliitto)	
Asema taloudessa	
Postinumero	Keskustelussa tulleiden kokemusten perusteella asuin- ja synnyin paikalla on suuri merkitys kauppojen syntymiselle, joten nämä ominaisuudet ovat merkittäviä.
Asuinpaikka tai -kunta	
Synnyin alue	
Automerkki	Autoiluun ja kulkemiseen liittyvät ominaisuudet ovat merkittäviä ja riippuvat myös asuinpaikasta esim. keskusta / haja-asutusalue, joka voisi olla myös merkittävä lisäominaisuus. Haluaisimme tähän vielä lisättävän, mikäli asiakas käyttää esim. sähköautoa, yleisiä kulkuneuvoja tai liikkuu pyörällä/kävelen.
Malli	
Vuosimalli	
Moottorivilavuus	
Istumapaikkojen määrä	
Käyttäjätasot	Näemme nämä ominaisuudet merkittävänä. Käyttäjä statukseen kaiken sisältyy myös nykyisten asiakkaiden lisäksi entiset asiakkaat ja täysin uudet. Voisimme myös lisätä, mikäli asiakas on jonkin yhteistyökumppanimme asiakas. Lisäksi voisimme kerätä tiedon, miten asiakas käyttää meidän sähköisiä palveluitamme kuten If mobiilia, If apua, omia sivuja sekä chatbotteja. Valmius tason selvittämisessä voidaan käyttää Web käyttäytymisen analytiikkaa.
Käyttöaste	
Lojaalisuus	
Valmiustaso	
Asenne tuotetta kohtaan	
Potentiaalipisteitys (PP)	Potentiaalipisteytykseen voisimme käyttää olemassa olevan suosittelumoottorin potentiaalia. Lisäksi eri tuotekategorioista syntyneitä leadeja web-käyttäytymisestä, chatbot keskusteluista tai kontaktimakkailta.
Autovakuutuksen PP	
Moottoripyörävakuutuksen PP	
Venevakuutuksen PP	
Kotivakuutuksen PP	
Mökkivakuutuksen PP	
Henkilövakuutusten PP	

 = Demografiset ominaisuudet

 = Geografiset ominaisuudet

 = Psykografiset ominaisuudet

 = Geodemografiset ominaisuudet


 = Käyttäytymiseen liittyvät ominaisuudet


## 7.2.3.3 Beta -version suunnittelu


Artefaktin Beta-versioon tehtiin kohdeorganisaation tutkimustiimin kanssa yhdessä sovitut muutokset. Muutokset sekä niihin liittyvät kuvaukset ja perustelu esiteltynä alta löytyvissä taulukoissa:


**Taulukko 8.** Taulukko artefaktin agenttia kuvaavien ominaisuuksien Beta-versiosta.

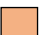
Ominaisuus	Kuvaus ja perustelu
Sukupuoli	Joukko tyypillisiä perinteisessä markkinoinnissa käytettyjä demografisia asiakkaisiin liitettyjä ominaisuuksia. Profiloivat agentin yleistä elämäntilannetta ja siihen liittyvää kokemusta. Selittävät ehkä jossain määrin agentin kykyä samaistua asiakkaan tilanteeseen. Liittyvät asiakkaan ostopäätökseen vaikuttaviin sosiaalisiin vaikutteisiin kuten sosiaaliseen luokkaan, viiteryhmään ja perheeseen. (s. 49-50, 38-45 ja 63-64)
Ikä	
Perheeseen liittyvä elämäntilanne	
Perheen koko	
Koulutus	
Asuintyyppi	
Asema taloudessa	
Postinumero	Profiloivat agentin synnyin- ja asuinpaikkaan liittyvää kokemusta. Selittävät ehkä jossain määrin agentin kykyä samaistua asiakkaan kulttuurilliseen viitekehykseen ja toimintaympäristöön. Liittyvät asiakkaan ostopäätökseen vaikuttaviin sosiaalisiin vaikutteisiin kuten kulttuuriin ja viiteryhmään. (s. 49-50, 38-45 ja 63-64)
Asuinpaikka tai -kunta	
<i>Asuinalueen tyyppi</i>	
Synnyin alue	
<i>Persoonaalisuusanalyysi</i>	Selittää ehkä jossain määrin agentin psykografista profiilia ja tätä kautta kykyä vastata asiakkaan ostopäätökseen vaikuttaviin henkilökohtaisiin vaikuttimiin kuten persoonallisuustyyppiin, elämäntyyliin ja motiiveihin. (s. 59-64 ja 38-48) Käytettäessä esimerkiksi DISC- tai mitä tahansa muuta analyysia, tulee sen tuloksiin suhtautua varauksella. Persoonallisuuden kategorisointi erilaisin lyhyin kyselytestein on äärimmäisen hankalaa ja epäluotettavaa. (s. 58-59)
<i>Autottomuus (k/e)</i>	Selittävät yksittäin sekä kokonaisuutena asiakkaan käyttäytymistä. (s. 49-51)
<i>Autoton pääliikkumistapa</i>	
<i>Julkisten liikkumisvälineiden käyttö</i>	
Automerkki	
Malli	
Vuosimalli	
Moottorivilavuus	
<i>Käyttövoima</i>	
Istumapaikkojen määrä	
Myyjän yleinen hitrate%	Selittävät agentin kykyä vastata asiakkaan ostotilanne- ja ongelmanratkaisutyyppiin. (s. 38-40 ja 56-57)
Työkokemus yhtiössä	
Autovakuutusten hitrate%	Yankelovichin ym. (2006: 10) mukaan segmentoinnissa yleisimmin tapahtuvat virheet liittyvät usein liialliseen kuluttajien identiteettiin keskittyminen, tuotteen tai tuotekategorian nykyisille ja potentiaalisille uusille asiakkaille merkityksellisten ominaisuuksien sijaan, sekä liian vähäiseen varsinaisen asiakaskäyttäytymisen painottamiseen. Tästä syystä viimeiset agentin ominaisuudet keskittyvät yksinomaan asiakkaiden käyttäytymiseen agenttien suhteen, jota voidaan mitata agenttien suoriutumisen eri tuotekategorioissa. Tuotealueittainen hitrate% selittää agenttien kykyä tehdä myyntiä eri tuotekategorioissa. (s. 49-52)
Moottoripyörävakuutusten hitrate%	
Venevakuutusten hitrate%	
Kotivakuutusten hitrate%	
Mökkivakuutusten hitrate%	
Henkilövakuutusten hitrate%	
<i>Lemmikkivakuutusten hitrate%</i>	

 = Demografiset ominaisuudet

 = Geografiset ominaisuudet


 = Psykografiset ominaisuudet


 = Geodemografiset ominaisuudet


 = Käyttäytymiseen liittyvät ominaisuudet


**Taulukko 9.** Taulukko artefaktin asiakasta kuvaavien ominaisuuksien Beta-versiosta:


Ominaisuus	Kuvaus ja perustelu:
Sukupuoli	Joukko tyypillisiä perinteisessä markkinoinnissa käytettyjä demografisia asiakkaisiin liitettyjä ominaisuuksia. Profiloivat asiakkaan yleistä elämäntilannetta. Liittyvät asiakkaan ostopäätökseen vaikuttaviin sosiaalisiin vaikutteisiin kuten sosiaaliseen luokkaan, viiteryhmään ja perheeseen. (s. 49-50, 38-45 ja 63-64)
Ikä	
Perheeseen liittyvä elämänvaihe	
Perheen koko	
Asuintyyppi	
Ammatti	
Koulutus	
(Ammattiliitto)	
Asema taloudessa	
Postinumero	
Asuinalueen tyyppi	
Synnyin alue	
<i>Autottomuus (k/e)</i>	
<i>Autoton pääliikkumistapa</i>	Selittävät yksittäin sekä kokonaisuutena asiakkaan käyttäytymistä. (s. 49-51)
<i>Julkisten liikennevälineiden käyttö</i>	
Automerkki	
Malli	
Vuosimalli	
Moottoritilavuus	
<i>Käyttövoima</i>	
Istumapaikkojen määrä	
Käyttäjätasus	
<i>Yhteistyökumppaneiden asiakkuus</i>	
Käyttöaste	
Lojaalisuustaso	
Valmiustaso	
Asenne tuotetta kohtaan	
<i>Sähköisten palveluiden käyttötaso</i>	
Potentiaalipisteytys (PP)	Koska Yankelovichin ym. (2006: 10) mukaan segmentoinnissa yleisimmin tapahtuvat virheet liittyvät usein liialliseen kuluttajien identiteettiin keskittyminen, tuotteen tai tuotekategorian nykyisille ja potentiaalisille uusille asiakkaille merkityksellisimpien ominaisuuksien sijaan, sekä liian vähäiseen varsinaisen asiakaskäyttäjätymisen painottamiseen. Tästä syystä viimeiset asiakkaan ominaisuudet keskittyvät yksinomaan asiakkaiden käyttäytymisen ennustamiseen potentiaalipisteytyksellä tuotekategorioittain. Potentiaalipisteytys mittaa yksittäisen asiakkaan ostopotentiaalia eri tuotekategorioissa. (s. 49-52)
Autovakuutuksen PP	
Moottoripyörävakuutuksen PP	
Venevakuutuksen PP	
Kotivakuutuksen PP	
Mökkivakuutuksen PP	
Henkilövakuutusten PP	
<i>Lemmikkivakuutusten PP</i>	

 = Demografiset ominaisuudet

 = Geografiset ominaisuudet

 = Psykografiset ominaisuudet

 = Geodemografiset ominaisuudet

 = Käyttäytymiseen liittyvät ominaisuudet

#### 7.2.3.4 Beta-version testaus sekä evaluointi

Artefaktin Beta-version vaihteluvälien suunnittelu, testaus sekä RIE-syklin vienti siitä eteenpäin sen evaluointivaiheeseen päätettiin jättää jatkotutkimukseen, johtuen testiä varten alun perin suunniteltujen aikataulujen muuttumisesta kohdeorganisaatiossa. Kohdeorganisaation aikatauluja myöhästytti projektien uudelleen priorisointi sekä niin kutsuttu *Data Protection Impact* -analyysi, jota testin ajamisen todettiin edellyttävän. Beta -version jälkeisten osioiden jättäminen jatkotutkimusaiheeksi koettiin hyvänä asiana niin tutkijan kuin kohdeorganisaation osalta koska sen sisällyttäminen tehtyyn tutkimukseen olisi osaltaan todennäköisesti laajentanut tutkimusta liikaa. Tutkimuksen loppuosio nähtiin myös uutena mahdollisena kokonaisen tutkimuksen aiheena.

#### 7.2.4 Mahdollisten lisäsykliä tarpeen arviointi ja niiden toistaminen.

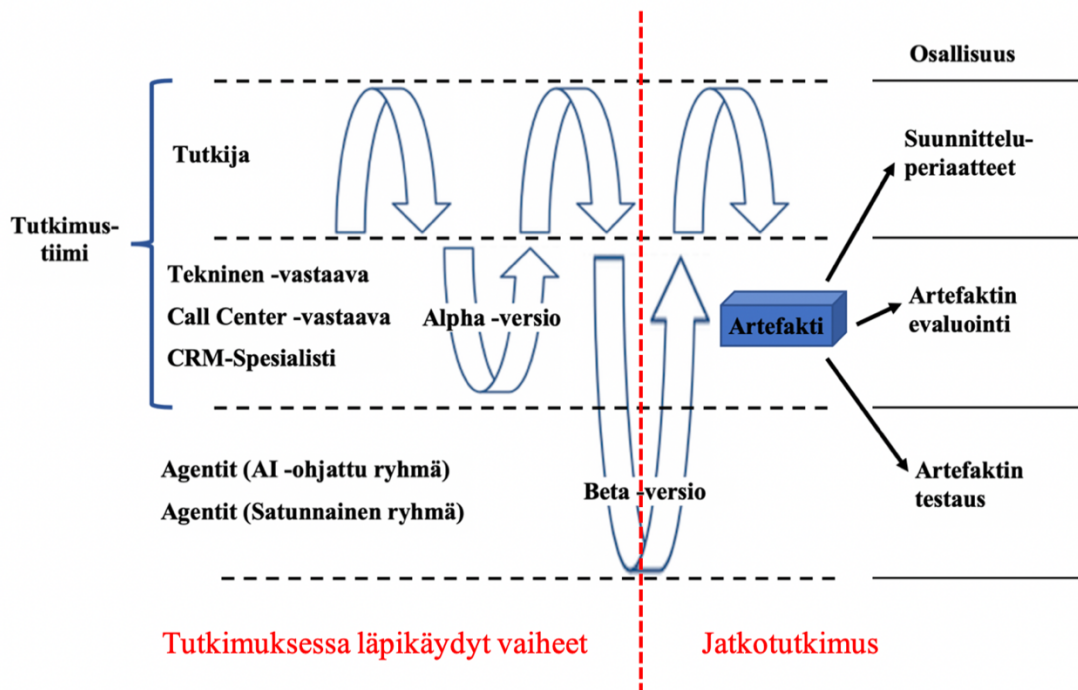
Tehtävässä mahdollisesti käytettävissä olevien ominaisuuksien suuresta määrästä johtuen tutkimusta voitaisiin jatkaa lukuisilla lisäsykleillä, joilla edelleen pyrittäisiin etsimään käyttöön uusia ominaisuuksia. Jotta tutkimus ei kuitenkaan laajenisi liiaksi päädyttiin siinä toteuttamaan ainoastaan yksi sykli artefaktin Beta-version valmistumiseen asti. Aiheen tutkimista jatkettaessa suositeltavaa olisi kuitenkin tutkimussuunnitelman mukaisesti tehdä artefaktin Beta-versiolla testi loppukäyttäjien parissa ja evaluoida se vielä ainakin kertaalleen ennen lopullisen artefaktin valmistumista. Myös tulosten toistettavuuden sekä menetelmällä mahdollisesti uutettavissa olevien lisälöydösten kannalta olisi suositeltavaa toteuttaa tarve ja resurssit huomioiden mahdollisimman useita kokonaisia lisäsyklejä.

#### 7.2.5 Valmis artefakti

Tutkimus päätettiin rajata siihen kustomoidun IT-dominantin RIE mallin suunnitteluun, sekä ensimmäisen RIE-syklin toteutukseen artefaktin Beta-vaiheeseen asti. Artefaktin Beta -versio, sekä suunniteltu RIE-malli luovutettiin kohdeorganisaation käyttöön, jonka



loppuun viennistä suunniteltiin tehtävän sen laajuudesta johtuen kokonaan erillinen tutkimus. Lopullinen artefakti suunniteltiin valmistuvaksi jatkotutkimusosiossa, kohdeorganisaation loppukäyttäjien suorittaman testin, sekä tutkimustiimin kanssa suoritettun artefaktin Beta-version evaluoinnin jälkeen. Tämän tutkimuksen valmiina tuotoksena voitaneen pitää alla kuvattua kustomoitua RIE-mallia, artefaktin edellä esiteltyä Beta-versiota sekä kaikkea sen suunnitteluun liittyvää niin teorian kuin käytännön näkökulmasta suoritettua pohdintaa, jonka osaltaan koettiin kohdeorganisaatiossa tuovan lisäarvoa, niin kohdeorganisaation suorittamaan jatkotutkimukseen, kuin myös muille samojen kenttäongelmien kanssa painiville, saman toimialan organisaatioille.



**Kuva 10.** Tutkimuksen rajaus kuvattuna siihen kustomoidun RIE: malliin.

### 7.3 Reflektio- ja oppimisvaihe

ADR-metodin kolmannessa vaiheessa siirytään opitun soveltamiseen laajempaan luokkaan ongelmia. (Sein ym. 2011: 44) Seuraavassa on käyty läpi tutkimuksen eteneminen sen kolmannessa vaiheessa määriteltyjen tehtävien läpi.

#### 7.3.1 Suunnittelun ja uudelleensuunnittelun reflektointi koko projektin ajan

Tutkimuksessa suunnitellun artefaktin ei tulisi heijastaa ainoastaan alustavaa, tutkijoiden luomaa mallia vaan myöskin sen jatkuvaa muovautumista organisaation käytössä. Tästä syystä tutkimuksessa ensimmäisenä tutkijan toimesta suunnitellun artefaktin Alpha -version evaluointi yhdessä kohdeorganisaation teknisen vastaavan, Call Center vastaavan sekä CRM-spesialistin kanssa sekä myöhemmin Beta -versiolla käytännön toimijoiden kanssa suoritettavaksi tarkoitettu testi, aiheuttivat artefaktin jatkuvaa kohdeorganisaation kanssa yhteistyössä tapahtunutta muovautumista ja uudelleen suunnittelua. Myös artefaktin Alpha -version suunnittelussa otettiin huomioon haastatteluin kerätty spesifi organisaatioon liittyvä tieto, joka osaltaan muokkasi sen muutoin teoriatietoon pohjautuvaa suunnitteluprosessia. Projektin jokainen suoritettu vaihe sisälsi näin ollen jatkuvaa, artefaktin muovaamiseen tähtäävää kanssakäymistä kohdeorganisaation eri osien kanssa. Myös myöhemmäksi tarkoitettua artefaktin beta -versiolla loppukäyttäjien parissa suoritettava testi sekä sen lopullinen evaluointi on suunniteltu niin että ne mitä todennäköisimmin aiheuttavat artefaktin uudelleensuunnittelua ennen lopullisen version valmistumista.

#### 7.3.2 Periaatteista kiinni pitämisen evaluointi

Tutkimuksessa pyrittiin pitäytymään vahvasti toiminnan suunnittelututkimuksen eri vaiheiden sisältämissä periaatteissa. Tutkimus oli *käytännön inspiroima* eli sen aihe ja siihen liittyvät tutkimuskysymykset syntyivät suoraan kohdeorganisaation kohtaamista,

tutkimuksen alussa haastatteluin selvitetystä käytännön tarpeista. Tutkimuksessa rakennettiin aluksi puhtaasti tutkijan keräämään kirjalliseen tietoon perustuva *teorialähtöinen artefakti*, eli artefaktin alpha-versio.

Artefaktin *vastavuoroista muokkausta* tapahtui sen kaikissa alpha-version evaluointi vaiheen jälkeisissä vaiheissa. Niin alpha-version evaluoinnissa kuin sen jälkeen beta-version *suunnittelussa, testissä* sekä *evaluoinnissa*, kohdeorganisaation tutkimustiimin jäsenet osallistuivat vahvasti sen muokkaamiseen. Tutkimuksessa alusta asti tärkeää oli myös *molemmiin puolin vaikutusvaltaisten roolien* toteutuminen, joista huolehdittiin ennen kaikkea tarkalla tutkimustiimin tehtävien ja roolien jaolla. Tärkeää oli, että niin tekoälysovellusten teknisestä toteutuksesta vastaavan, CRM käytöstä vastaavan kuin puhelinpalvelukeskuksessa työskentelevien henkilöiden johtamisesta vastaavan henkilön roolit olivat sellaisia, joiden kautta pystyttiin vahvasti vaikuttamaan lopullisen artefaktin muovautumiseen. Myös loppukäyttäjien rooli viimeisenä suoritettavassa testissä oli vaikuttava, koska sen kautta oli saatavissa paras mahdollinen palaute artefaktin beta-version toimivuudesta käytännön ympäristössä. Kaikille kohdeorganisaatiosta mukana olleille toimijoille pyrittiin antamaan mahdollisuus antamaan palautetta ja korjausehdotuksia kaikissa artefaktin muokkausvaiheissa. Artefaktin *autenttista ja rinnakkaista evaluointia* tapahtui näin ollen edellä kuvatulla tavalla artefaktin alpha-version evaluointivaiheesta projektin loppuun asti.

Artefaktin suunnitteluperiaatteet pyrittiin pitämään joustavina niin että *ohjattu emergenssi* -periaatteen mukaista teoriaan pohjautuvaa, mutta samalla jatkuvaa organisaation käytössä tapahtuvaa muovautumista tapahtuisi koko suunnitteluprosessin ajan. Esimerkkeinä tästä käyvät artefaktin alpha -version suunnittelua varten kohdeorganisaatiosta kerätty käytännön tieto, sekä beta -versioon kohdeorganisaation toimijoiden suorittamien evaluointien ja näkökulmien perusteella tehdyt teorian kanssa linjassa olleet muutokset. Myös myöhemmin loppukäyttäjien suorittamaksi suunniteltu testi sekä artefaktin Beta-version evaluointi suunniteltiin tehtäväksi noudattaen ohjatun emergenssin periaatetta.

Tutkimus pyrittiin alusta asti suunnittelemaan niin että se tuottaisi organisaatiospesifidestään huolimatta *yleistettäviä tuloksia*. Ongelmatapaus yleistettiin tutkimuskysymyksissä sellaiseksi, että se voisi koskea minkä tahansa vahinkovakuutusyhtiön puhelinpalvelukeskusta, suunniteltaessa neuroverkkoja ja koneoppimista hyödyntävää, asiakkaat ja agentit, myynnin hitraten näkökulmasta mahdollisimman tehokkaasti yhdistävää järjestelmää. Ratkaisutapaus, eli tässä tutkimuksessa noin 30 attribuuttia sisältävät taulukot agenttien ja asiakkaiden merkityksellisiksi arvioiduista ominaisuuksista, suunniteltiin myös niin että niiden sisältämät tiedot olisivat yleisesti vahinkovakuutusyhtiöiden saatavilla. Lopullinen *suunnitteluperiaatteiden tutkimustuloksista johtaminen*, jätettiin jatkotutkimusosioon, jossa loppukäyttäjien artefaktin Beta-versiolla suorittamasta testistä saaduilla tuloksilla on äärimmäisen keskeinen merkitys minkäänlaisten pidemmälle vietyjen johtopäätösten vetämisen kannalta.

### 7.3.3 Interventiotuloksien analysointi määriteltyjen tavoitteiden mukaisesti

Interventiotuloksina tutkimuksessa näyttäytyivät eritoten artefaktin alpha- ja Beta-version väliset muutokset, joissa kohdeorganisaation rooli oli merkittävä ja vaikutusvaltainen. Interventiovaiheissa pyrittiin täten noudattamaan tiiviisti *ohjattu emergenssi* -periaatetta. Interventiosta johtuneet muutokset tehtiin linjassa tutkimuksen teoriapohjan kanssa, kuitenkin käytännön toimijoiden näkökulma ja mielipiteet huomioiden. Intervention tavoitteena oli saada tutkimuksen teoriapohjan kanssa linjassa olevia, mutta samalla käytännön näkökulmasta merkityksellisiksi havaittuja päivitysideoita artefaktiin, jotka eivät kuitenkaan saisi olla liian organisaatiospesifejä ja olisivat täten yleisesti käytettävissä muissakin vastaavissa käyttötapauksissa. Interventiotulokset olivat tähän peilaten tavoitteiden mukaisia.

Interventiotuloksina saatuja uusia agentin ominaisuuksia olivat: *Asuinalueen tyyppi, persoonallisuusanalyysi, autottomuus, auton pääliikkumistapa, julkisten liikkumisvälineiden käyttö, auton käyttövoima sekä lemmikkivakuutusten hitrate*.

Interventiotuloksina saatuja uusia asiakkaan ominaisuuksia olivat: *Asuinalueen tyyppi, autottomuus, auton pääliikkumistapa, julkisten liikkumisvälineiden käyttö, auton käyttövoima, yhteistyökumppaneiden asiakkuus, sähköisten palveluiden käyttötaso sekä lemmikkivakuutusten potentiaalipisteytys*. Lisäksi interventiotuloksena havaittiin, että *ammattiliitto* -ominaisuuden käyttö ACPS-järjestelmässä vaatii Data Protection Impact Analysis -lisäselvityksen.

#### 7.4 Oppimisen formalisointivaihe

ADR-metodin neljännessä vaiheessa tavoitteena on oppimisen formalisointi. (Sein ym. 2011: 44) Seuraavassa on käyty läpi tutkimuksen eteneminen sen neljännessä vaiheessa määriteltyjen tehtävien läpi.

##### 7.4.1 Oppimisen abstrahointi konsepteiksi luokalle kenttäongelmia

Sein ym. (2011: 44) suosittelevat kolmea askelmaa tutkimustulosten yleistämisessä. Ensimmäinen vaihe eli *ongelmatapauksen yleistäminen*, suoritettiin tutkimuskysymyksiä muotoiltaessa niin että ne eivät olleet suunniteltu koskemaan suoraa kohdeorganisaatiossa suoritettavaa projektia, vaan myös laajemmin vakuutusyhtiöissä mahdollisesti käyttöön otettavia puhelinpalvelukeskuksen agentin asiakkaaseen yhdistäviä koneoppimisen sovelluksia.

Toinen vaihe eli *ratkaisutapauksen yleistäminen*, pyrittiin toteuttamaan niin että artefaktin ensimmäinen versio suunniteltiin yksinomaan yleisen teorian tiedon eikä niinkään organisaatiospesifin tiedon pohjalta, jolloin ratkaisujen oletettiin olevan paremmin sovellettavissa yleisesti hieman eri tavoin toimivissa saman luokan kohdeorganisaatioissa, eli vahinkovakuutusyhtiöissä. Myös artefaktin Beta-versioon kohdeorganisaation kanssa yhteistyössä tehdyt muutokset pyrittiin toteuttamaan samassa hengessä, eli niiden yleistä soveltuvuutta pohdittiin ennen kunkin ominaisuuden valintaa. Yleistetyt ratkaisutapaukset ovat esiteltyinä tutkielman sivuilla 92-93 esitellyissä

taulukoissa, sekä myös toisaalla vastaavien ongelmien ratkaisuun kustomoidussa IT-dominantin RIE:n mallissa (tutkimuksen sivu 84), jota voidaan hyödyntää jatkotutkimuksessa suorittamalla useampia sen mukaisia syklejä uusien ominaisuuksien löytämiseksi.

Kolmas vaihe eli *suunnitteluperiaatteiden johtaminen suunnittelu tutkimuksen tuloksista*, olisi ollut täydellisempi, mikäli tutkimuksen viimeinen vaihe, eli artefaktin Beta-version testi käytännön toimijoilla olisi voitu toteuttaa. Tällöin tietoa suunnitellun artefaktin toimivuudesta käytännön ympäristöstä olisi voitu hyödyntää paremmin johtopäätösten tekemisessä. Artefaktin Beta-versioon asti tehdystä tutkimuksesta pyrittiin kuitenkin johtamaan ne suunnitteluperiaatteet, jotka havaittiin merkityksellisiksi tutkimuksen siihen astisen etenemisen kannalta. Suunnitteluperiaatteet esitellään myöhemmin erikseen kohdassa ”Tulosten viestiminen sanallisina suunnitteluperiaatteina”.

#### 7.4.2 Tuloksien ja tehtävien jakaminen käytännön toimijoiden kanssa

Tutkimuksen etenemistä käytiin läpi noin kymmenessä palaverissa, joista kaksi suoritettiin kasvokkain kohdeorganisaation tiloissa ja loput noin tunnin kestäneinä etäpalaverina. Tutkimuksen alusta asti siinä mukana olleille toimijoille oli jaettu tarkat tehtävät ja roolit. Tietoa ja tutkimuksen keskeneräisiä versioita jaettiin koko tutkimuksen ajan kohdeorganisaatiolle jatkuvan palautteen keräämiseksi sekä jatkosuunnittelun polttoaineeksi. Tutkimus sekä sen artefaktin Beta-version valmistumiseen asti saadut tulokset jaettiin kohdeorganisaatiolle tutustuttavaksi sen valmistumisvaiheessa. Loppuvaiheessa olevasta tutkimuksesta pyydettiin palaute sekä kommentit, joiden perusteella kohdeorganisaatiossa tapahtunutta oppimista, sen kokemaa hyödyllisyyttä sekä jatkoajatuksia pyrittiin kartoittamaan.

#### 7.4.3 Tulosten viestiminen sanallisina suunnitteluperiaatteina

Artefaktin Beta-versioon asti tehdystä tutkimuksesta johdettiin kolme suunnitteluperiaatetta:

- ACPS-järjestelmän asiakkaiden ja agenttien tavoitteen kannalta merkityksellisiä ominaisuuksia sisältävää artefaktin alpha -versiota suunniteltaessa on hyvä keskittyä lähes yksinomaan teorian pohjalta merkityksellisiin seikkoihin. Tämä todettiin parhaiten avaavan kohdeorganisaatiolle uusia näkökulmia sen lähestyessä aihetta enemmän käytännön sanelemista lähtökohdista.
- Artefaktin beta -versioon on hyvä tehtävät muutokset tulisi pyrkiä tekemään niin että ne huomioivat kohdeorganisaation toimijoiden kautta saadut uudet ideat sekä käytännön sanelemat muutokset niin että ne kulkevat käsi kädessä aiemmin selvitetyn teoriapohjan kanssa.
- Valmista artefaktia tulisi edeltää hyvin suunniteltu käytännön testi, jonka tuloksien perusteella pystytään määrittämään löydettyjen ominaisuuksien relevanssi. RIE-syklejä tulisi toistaa niin kauan, kunnes tavoitteen kannalta merkityksellisiksi havaittuja ominaisuuksia löytyy tyydyttävä määrä.

#### 7.4.4 Oppimisen pukeminen sanoiksi valittujen teorioiden valossa

Tutkimuksessa tapahtunut oppiminen on puettavissa sanoiksi parhaiten sen alussa määriteltyjen tutkimusongelmien kautta. Tutkimuksen pääongelmaan ”*Miten vahinkovakuutusyhtiön puhelinpalvelukeskus pystyisi neuroverkkoja ja koneoppimista hyödyntämällä ohjaamaan asiakkaitaan, niin asiakkaan kuin vakuutusyhtiönkin näkökulmasta potentiaalisimmille agenteille?*”, liittyvä oppiminen avautuu parhaiten tarkasteltaessa siihen liittyviä osaongelmia. Osaongelmat ja niihin liittyvä oppiminen sanoiksi puettuna tiivistyi tutkimuksen päättyessä seuraavaan muotoonsa:

1. *Miten asiakkaat ja vakuutusyhtiöin edustajat profiloidaan ja kategorisoidaan?*

Käytettäessä Multilayer Perceptron -neuroverkon, Random Forest -luokittelijan tai Support Vector Machinen kaltaisia menetelmiä, tarvitaan niiden käyttöön ongelmaan

liittyvät luokittelumääritelmät ja datat. Järjestelmän käyttäessä tavallisia taulukoita, voidaan sekä vakuutusyhtiön agentit että asiakkaat profiloida keräämällä molemmista ongelman kannalta merkityksellisimpinä pidetyt ominaisuudet taulukkomuotoon, joiden perusteella koulutetun neuroverkon tulisi kyetä yhdistämään reaaliajassa kulloisessakin tilanteessa parhaiten tavoitteen kannalta toisilleen soveltuvat vastinparit. (Tekninen vastaava 2020) Profilointi tulee suorittaa tavoite huomioiden. Kyseisessä käyttötapauksessa sekä asiakkaan että agentin profiileihin sisällytettävät ominaisuudet tulisi valikoitua niin että ne näyttäytyvät merkittävinä asiakkaan ostopäätökseen liittyvien vaikuttimien kannalta. Asiakkaiden ja agenttien ominaisuuksia uutettaessa suositeltavaa on, että se tehdään ongelman ratkaisuun kehitetyn teorian pohjalta. Kyseisessä tutkimuksessa teoriapohjana käytettiin Jobberin ja Lancasterin (2009: 85-92) teoriaa, joka erittelee kuluttaja-asiakkaiden päätöksentekoprosessin lopputulokseen vaikuttavat tekijät kolmeen luokkaan sekä perinteistä kuluttajamarkkinoiden segmentointiin liittyvää teoriaa. (McDonald ym. 1995: 54-59; Kotler ym. 268-282) Tässä tutkimuksessa ominaisuuksia pyrittiin uuttamaan teoriapohjalta.

Asiakkaiden ja agenttien profiloinnissa käytettäviä merkityksellisiä ominaisuuksia etsittäessä voidaan hyödyntää myös koneoppimisen keinoja kuten tiedonlouhintaa. (Berry ym. 2004: 111; 349) Tiedonlouhinnan lähestymistapa asiakassegmentteihin on käyttäytymiseen liittyvien segmenttien tunnistaminen, joita tunnistamalla voidaan pyrkiä pääättelemään segmenteissä esiin nousevia ominaisuuksia ja niiden merkityksellisyyttä. (Berry 2004: 111)

Asiakkaiden kategorisointia voidaan tehdä myös yksittäisten agenttien näkökulmasta käyttämällä neuroverkkoluokittelijaa, joka jakaa prospektit agentin olemassa olevia asiakkaita tutkimalla. Neuroverkko luokittelee tällöin myyjän prospektit (syötteen) huonoon, hyvään tai muutama eri tasoiseen luokkaan, ihanneasiakkaan attribuuteilla tapahtuneen neuroverkon koulutuksen perusteella. Menetelmän käyttäminen sisältää neljä vaihetta: 1. *Ominaisuuksien uuttaminen*, jossa asiakkaan merkitykselliset ominaisuudet pyritään uuttamaan kysymyksiin saatujen vastausten perusteella. 2. *Datan etiketöinti* esimerkiksi sen mukaan tapahtuiko kaupan saavuttaminen nopeasti, keskimääräisesti, hitaasti vai eikö kaupaa saavutettu ollenkaan tai vaikkapa kaupan



suuruuden perusteella 3. *Neuroverkon koulutus*, joka toteutetaan ohjatun oppimisen algoritmeilla tavanomaisen neuroverkkoluokittelijan kouluttamiseksi. 4. Neuroverkon testaaminen lopulla datalla. 5. Neuroverkon käyttö uuteen dataan. (Mitra 2019)

2. *Mitä tietoja asiakkaista ja edustajista on saatavilla ja mitä niistä voidaan käyttää?*

Vahinkovakuutusyhtiöillä havaittiin toiminnan luonteesta johtuen olevan käytössään runsaasti erilaista tietoa asiakkaistaan. Asiakaskantojen sisältämä tieto liittyy useimmiten asiakassuhteen aikana kerättyyn dataan sekä erilaisten markkinointiin liittyvien työkalujen ja yhteistyötahojen kautta kerättyyn dataan. (Kotler ym. 2016: 662-669; Tekninen vastaava 2020)

Lähdettäessä pohtimaan asiakkaista ja edustajista saatavilla olevaa dataa sekä erityisesti sen luokittelua, havaittiin siinä hyväksi työkaluksi tavallinen kuluttajamarkkinoiden segmentointiin liittyvä teoria, joka pitää sisällään asiakkaiden jakamista segmentteihin *demografisten, geografisten, geodemografisten, psykografisten ja käyttäytymiseen liittyvien* tunnusmerkkien perusteella. (McDonald ym. 1995: 54-59; Kotler ym. 268-282)

Kun dataa jaettiin perinteisesti kuluttajamarkkinoinnissa käytettyihin segmentteihin, havaittiin demografista ja geografista tietoa olevan käytettävissä runsaasti sekä niiden saatavuus hyväksi. Asiakkaiden käyttäytymiseen liittyvää tietoa oli myös kerättävissä erilaisin menetelmin, esimerkiksi seuraamalla asiakkaiden vakuutusyhtiön sähköisten työkalujen käyttöä tai aiemmin suorittamia ostoja. Haastavimmiksi selvitettäviksi asioiksi nousivat psykografiset erityispiirteet, joiden selvittämien olisi monesti vaatinut erilaisten markkinatutkimukseen perustuvien haastattelujen tekemistä. Tällaisten erityispiirteiden selvittämisen haasteen havaittiin piilevän siinä, että vaikka asiakkaista kerättäisiin erilaisin haastatteluin tietoa, pystyttäisiin se toteuttamaan käytännössä vain hyvin pienelle joukolle asiakkaita. Tällöin kyselyt voisivat tarjota paljonkin tietoa, mutta kokonaisuuteen suhteutettuna vain *harvoista asiakkaista*. (Berry ym. 2004:111-116; Tekninen vastaava 2020)

Jotta henkilötietoa voidaan käyttää, on sen käsittelyn ja keräämisen täytynyt täyttää Tietosuoja-asetuksen (2016/679) määrittelemistä kuudesta perusteesta vähintään yhden. Perusteen täytyy olla myös selvillä ennen käsittelyn aloittamista. ACPS-järjestelmässä käytettävä tieto täytyy siten olla edellä kuvatuilla perusteilla kerätty. Lisäksi ACPS-järjestelmässä käytettävä tieto ei saa sisältää minkäänlaista automaattista päätöksentekoa eli esimerkiksi oikeusvaikutuksia henkilöihin, joista tietoa on kerätty. Tällainen oikeusvaikutus voisi olla vaikkapa vakuutusurvan automaattinen epäminen kerätyn tiedon perusteella. Koska kohdennettuun profilointiin perustuvalla markkinoinnilla voi kuitenkin olla yksilöihin tai henkilöryhmiin kohdistuvia merkittäviä vaikutuksia, joita tulee arvioida erikseen, suositellaan ennen ACPS-järjestelmän käyttöön ottoa erillistä EU:n yleinen tietosuoja-asetuksen (2016/679) huomioon ottavaa analyysiä. Kohdeorganisaatiossa muun muassa työkaluna ennen järjestelmän käyttöönottoa päätettiin käyttää niin kutsuttua Data Protection Impact -analyysiä. (Tietosuojavaltuutetun toimisto 2019; Tekninen vastaava 2019)

### *3. Millainen tieto pitäisi teoriaan pohjautuen olla merkityksellistä tavoitteen toteutumisen kannalta*

Markkinatutkimukseen perustuvan segmentoinnin ongelman havaittiin teorian perusteella piilevän siinä, että sitä on äärimmäisen vaikeaa soveltaa niihin kaikkiin asiakkaisiin, jotka eivät olleet mukana, tai muusta syystä vastanneet markkinatutkimukseen liittyviin erilaisiin kartoituksiin ja kyselyihin, lähestymistavan tarjotessa yleensä *valtavasti tietoa* mutta *harvoista asiakkaista*. Toisaalla pelkkiin demografisiin ominaisuuksiin nojaavien segmenttien ongelma on taas siinä, että ne eivät selitä juurikaan asiakkaiden mieltymyksiin, persoonallisiin piirteisiin tai käyttäytymiseen liittyviä tekijöitä kovinkaan hyvin. (Berry ym. 2004: 111-116)

Vaikka elämäntapa-analyysin keinoin voidaan saavuttaa jossain määrin totuudenmukaista tietoa todellisten ihmisten asenteista, tavoitteista, elämäntavasta ja omakuvasta, havaittiin sen ainakin teoratiedon perusteella antavan heikkoja tuloksia pyrittäessä ennustamaan, mitä kukakin asiakas todennäköisesti tulee kussakin vakuutusyhtiön erillisessä tuotekategoriassa ostamaan. Tästä syystä niin asiakkaiden kuin

agenttienkin profiilien tulisi sisältää paljon myös puhtaasti käyttäytymiseen liittyvää tietoa. (Yankelovich 2006: 10)

Kaikilla lopullisiin asiakkaiden ja agenttien profiileihin valikoituvilla ominaisuuksilla tulisi myös olla teoreettisesti vaikutus asiakkaan ostopäätökseen. Tutkimuksessa ominaisuuksia valikoitaessa käytettiin Jobberin ja Lancasterin (2009: 85-92) teoriaa, jonka mukaan kuluttaja-asiakkaiden päätöksentekoprosessin lopputulokseen vaikuttavat tekijät voidaan luokitella kolmen otsakkeen; (1) Ostotilanteen, (2) Henkilökohtaisten vaikutteiden, ja (3) Sosiaalisten vaikutteiden, alle. Valituilla ominaisuuksilla täytyi näin ollen olla oletettava vaikutus johonkin edellä mainituista luokista.

*4. Kuinka paljon parempiin myyntituloksiin (hitrate%) päästään löydettyjä ominaisuuksia käyttävällä, tekoälyohjatulla agentti–asiakas parituksella?*

Tutkimuksen viimeisen osaongelman ratkaisu jätettiin agenteilla suoritettavaan testiin liittyneistä aikataulullisista syistä, sekä osaltaan sen laajuuden johdosta jatkotutkimuksen aiheeksi.

#### 7.4.5 Tuloksien formalisointi levitystä varten

Agenteilla suoritettun testin jäätyä pois tutkimuksesta aikataulullisista syistä, jätettiin myös artefaktin Beta-versiolla ajetusta testistä saatavien tulosten formalisointi jatkotutkimukseen.

## 8. DISKUSSIO

Tutkimus oli osa kohdeorganisaationa toimineen vahinkovakuutusyhtiön laajempaa projektia, jonka tarkoituksena on selvittää nykyaikaisen tekoälyn, koneoppimisen ja erilaisten neuroverkkomenetelmien hyödyntämispotentiaalia sen yksityisasiakkaille suuntaamassa, puhelinpalvelukeskuksesta käsin suoritettavassa asiakaspalvelussa ja myyntityössä. Tutkimus keskittyi erityisesti käyttötapaukseen, jossa vakuutusyhtiön kontaktoimia asiakkaita pyritään edellä mainittuja teknologioita hyödyntäen ohjaamaan automaattisesti, myyntitapahtuman toteutumisen kannalta potentiaalisimmille vakuutusyhtiön edustajille. Tutkimustuloksia on tarkoitus käyttää pohjatietona kohdeorganisaation kehittämän ACPS-järjestelmän käyttämien asiakkaiden sekä agenttien profiilien suunnittelussa. Sovelluksen pääasiallinen käyttäjä on kohdeorganisaation puhelinpalvelukeskus.

### 8.1 Tulosten arviointi ja suositukset

ACPS-järjestelmässä käytettävien asiakkaiden ja agenttien profiilien suunnittelussa pääasiallinen fokus oli myyntitapahtuman toteutumisen todennäköisyyden kasvattamisessa. Profiilien suunnittelussa täytyi huomioida myös EU:n yleisen tietosuoja-asetuksen (2016/679) niiden käytölle mahdollisesti asettamat rajoitteet. Profiilien suunnittelussa pyrittiin keskittymään sellaisiin saatavilla oleviin asiakkaiden ja agenttien ominaisuuksiin, joilla niin käytännön kokemuksen kuin teorian perusteella pitäisi olla vaikutusta ostopäätöksen syntyyn.

Vahinkovakuutusyhtiöillä havaittiin toiminnan luonteesta johtuen olevan käytössään runsaasti erilaista tietoa asiakkaistaan. Asiakaskantojen sisältämä tieto liittyy useimmiten asiakassuhteen aikana kerättyyn dataan sekä erilaisten markkinointiin liittyvien työkalujen ja yhteistyötahojen kautta kerättyyn dataan. Laaja asiakastietokanta on kriittinen osa ACPS-järjestelmän kehitystyötä ja toimivuutta. Tästä syystä suositeltavaa on, että asiakassuhteisiin liittyvää tiedonkeruuta pyritään tekemään lähestulkoon kaikista tapahtuneista asiakaskontakteista, olivatpa ne sitten soittoja yrityksen

puhelinpalvelukeskukseen tai vaikkapa sähköisten palvelujen käyttöä. (Kotler ym. 2016: 662-669; Tekninen vastaava 2020)

Asiakkaiden ja agenttien profiloinnissa käytettäviä merkityksellisiä ominaisuuksia uutettaessa suositeltavaa on, että se tehdään ongelman ratkaisuun kehitetyn teorian pohjalta. Tietoa etsittäessä voidaan lähteä liikkeelle perinteisestä kuluttajamarkkinoiden segmentoinnista (McDonald ym. 1995: 54-59; Kotler ym. 268-282) jossa erilaisia saatavissa olevia ja markkinoinnissa yleisesti käytettyjä ominaisuuksia etsitään *demografisista, geografisista, geodemografisista, psykografisista ja käyttäytymiseen liittyvistä* luokista. Ominaisuuksia etsittäessä voidaan hyödyntää myös koneoppimisen keinoja kuten tiedonlouhintaa (Berry ym. 2004: 111; 349) tai neuroverkkoluokittelijaa, joka jakaa prospektit agenttien olemassa olevia asiakkaita tutkimalla. (Mitra 2019) Järjestelmään valikoituvat, ostopäätökseen vaikuttavat ominaisuudet tulisi kategorisoida Jobberin ja Lancasterin (2009: 85-92) teorian mukaisesti kolmeen luokkaan, *ostotilannetyypin, henkilökohtaisten vaikutteiden tai sosiaalisten vaikutteiden* alle.

Markkinatutkimukseen perustuvan segmentoinnin ongelman havaittiin teorian perusteella piilevän siinä, että sitä on äärimmäisen vaikeaa soveltaa niihin kaikkiin asiakkaisiin, jotka eivät olleet mukana, tai muusta syystä vastanneet markkinatutkimukseen liittyviin erilaisiin kartoituksiin ja kyselyihin, lähestymistavan tarjotessa yleensä *valtavasti tietoa* mutta *harvoista asiakkaista*. Toisaalla pelkkiin demografisiin ominaisuuksiin nojaavien segmenttien ongelma on taas siinä, että ne eivät selitä juurikaan asiakkaiden mieltymyksiin, persoonallisiin piirteisiin tai käyttäytymiseen liittyviä tekijöitä kovinkaan hyvin. (Berry ym. 2004: 111-116)

Vaikka elämäntapa-analyysin keinoin voidaan saavuttaa jossain määrin totuudenmukaista tietoa todellisten ihmisten asenteista, tavoitteista, elämäntavasta ja omakuvasta, havaittiin sen ainakin teorian tiedon perusteella antavan heikkoja tuloksia pyrittäessä ennustamaan, mitä kukakin asiakas todennäköisesti tulee kussakin vakuutusyhtiön erillisessä tuotekategoriassa ostamaan. Tästä syystä niin asiakkaiden kuin agenttienkin profiilien tulisi sisältää paljon myös puhtaasti käyttäytymiseen liittyvää tietoa. (Yankelovich 2006: 10)

Jotta henkilötietoa voidaan käyttää, on sen käsittelyn ja keräämisen täytynyt täyttää Tietosuoja-asetuksen (2016/679) määrittelemistä kuudesta perusteesta vähintään yhden. Perusteen täytyy olla myös selvillä ennen käsittelyn aloittamista. Lisäksi järjestelmässä käytettävä tieto ei saa sisältää minkäänlaista automaattista päätöksentekoa eli esimerkiksi oikeusvaikutuksia henkilöihin, joista tietoa on kerätty. Koska kohdennettuun profilointiin perustuvalla markkinoinnilla voi kuitenkin olla yksilöihin tai henkilöryhmiin kohdistuvia merkittäviä vaikutuksia, joita tulee arvioida erikseen, suositellaan ennen ACPS-järjestelmän käyttöönottoa erillistä EU:n yleinen tietosuoja-asetuksen (2016/679) huomioon ottavaa analyysiä. (Tietosuojavaltuutetun toimisto 2019)

## 8.2 Tutkimuksen arviointi ja rajoitukset

Tutkimuksen kontribuutiona oli tuottaa niin teorian tietoon kuin käytännön kokemukseen perustuvaa tieteellistä pohdintaa ja arviointia erilaisten järjestelmässä käytettävissä olevien asiakkaiden sekä agenttien ominaisuuksien vaikuttavuudesta myyntitapahtuman toteutumisen todennäköisyyteen sekä niiden käyttöä koskeviin rajoituksiin. Tutkimus pyrittiin toteuttamaan mahdollisimman tiukasti toiminnan suunnittelututkimuksellista toimintatapaa (Tiainen ym. 2015: 2; 19-20; 24; Järvinen 2018: 104) sekä siihen liittyvän ADR -metodin vaiheita ja periaatteita (Sein ym. 2011: 41) noudattaen. Vaikka tutkimus suoritettiin ADR-metodin mukaisesti tiiviissä yhteistyössä kohdeorganisaation kanssa, tehtiin se vahvasti teorian tietoon pohjaavalla otteella, jolloin sen tuottamien tulosten tulisi olla sovellettavissa universaalisti vahinkovakuutus alalla. Potentiaalisia, vastaavanlaisen sovelluksen sekä kerätyn tutkimustiedon tulevaisuuden käyttäjiä, voivat yleisesti ottaen olla kaikki vahinkovakuutusyhtiöt, jotka tekevät myyntityötä puhelinpalvelukeskuksen kautta ja hyödyntävät koneoppista- sekä erilaisia neuroverkkomenetelmiä asiakaspuheluiden ohjauksessa.

Tutkimuksen kontribuutiona oli myös konkreettinen toiminnan suunnittelututkimuksellisella menetelmällä kehitetty artefakti, johon kerättiin 37 asiakkaan sekä 30 agentin ominaisuutta niiden todellista vaikuttavuutta mittaavaa testiä

varten. Testivaihe sekä sen kautta saatujen tuloksien käsittely oli alun perin tarkoitus suorittaa osana tutkimusta, mutta jätettiin aikataulullisista syistä jatkotutkimuksen aiheeksi. Tutkimuksen kautta saadut tulokset eivät tästä syystä anna tyydyttävää vastausta etenkään viimeiseen osaongelmaan, eli kuinka paljon parempiin myyntituloksiin löydettyjä ominaisuuksia käyttävällä ACPS-järjestelmällä voidaan päästä. Tutkimuksen kontribuutiona voitaneen kuitenkin pitää pohjan rakentamista aihetta käsittelevälle jatkotutkimukselle, jota voidaan suorittaa esimerkiksi osana kohdeorganisaation projektin jatkoa.

### 8.3 Jatkotutkimusmahdollisuuksia

Tutkimuksessa kehitetyn artefaktin sisältämien, myyntitapahtuman toteutumisen todennäköisyyttä kasvattavien asiakkaiden ja agenttien ominaisuuksien lista ei ole testattu, kattava tai täydellinen. Se toimii kuitenkin hyvänä pohjana jatkotutkimukselle, jota voidaan suorittaa esimerkiksi osana kohdeorganisaation projektin jatkoa tai muussa yhteydessä. Jatkotutkimuksessa oheista artefaktia voidaan testata esimerkiksi samalla tavalla kuin tässä tutkimuksessa alun perin suunniteltiin. Vasta testin avulla saatavien tulosten perusteella voidaan vetää pidemmälle vietyjä johtopäätöksiä valikoituneiden ominaisuuksien toimivuudesta. Jatkotutkimuksessa voidaan pyrkiä myös uuttamaan uusia ominaisuuksia tutkimuksessa käytettyjä, tai muita menetelmiä käyttämällä.

Laajemmassa kontekstissa neuroverkkojen ja koneoppimisen käyttämistä vastaavassa sovelluksessa voidaan lähestyä myös lukuisista muista näkökulmista. Eräs tutkimuksen aikana esiin noussut mahdollisuus oli esimerkiksi nauhoitettujen asiakaspuheluiden litterointi, sekä neuroverkon käyttäminen reaaliaikaisessa asiakasohjauksessa itse puheen, aiheiden ja käytettyjen sanamuotojen perusteella. Vastaavanlaisten asiakaspalvelua sekä myynnin tehokkuutta parantavien sovellusten kehittäminen tulee todennäköisesti joka tapauksessa kiihtymään, neuroverkkojen sekä koneoppivien järjestelmien käytön kehittyessä sekä yleistyessä.

## LÄHTEET

29 Artiklan Mukainen Tietosuojatyöryhmä (2017). *Suuntaviivat automatisoiduista yksittäispäätöksistä ja profiloinnista asetuksen (EU) 2016/679 täytäntöön panemiseksi*. Annettu 3.10.2017. Viimeksi tarkistettu ja hyväksytty 6.2.2018. [online] [cited 5.12.2019]. Available from Internet: <URL: <https://tietosuoja.fi/documents/6927448/8316711/Automaattinen+päätöksenteko/28ae24f4-3345-4fb2-8708-c84abd8f57b0/Automaattinen+päätöksenteko.pdf>>.

Alpaydin, Ethem (2014). *Introduction to Machine Learning*. 3. painos. The MIT Press Cambridge, Massachusetts London, England. ISBN 978-0-262-02818-9.

Ahearne, Michael, Manning, Gerald L. & Reece, Barry L. (2012). *Selling Today. Partnering to create value*. 12. painos. Pearson Education Inc., Prentice Hall, One Lake Street, Upper Saddle River, New Jersey 07458, United States of America. ISBN 978-0-13-257019-0.

Berry, Michael, J. A. & Linoff, Gordon, S. (2004). *Data Mining Techniques For Marketing, Sales and Customer Relationship Management*. 2. painos. Wiley Publishing, Inc., Indianapolis, Indiana, United States of America. ISBN 0-471-47064-3.

Boyle, Brandon H. (2011). *Support Vector Machines: Data Analysis, Machine Learning and Applications*. Nova Science Publishers, Inc., New York, United States of America. ISBN 978-1-62257-078-2 (E-Book).

CACI Information Services Ltd (2019). *What is ACORN?*. [online] [cited 8.12.2019]. Available from Internet: <URL: <https://acorn.caci.co.uk>>.

Discprofiili (2019). *Discprofiili* [online] [cited 8.12.2019]. Available from Internet: <URL: <https://discprofiili.fi/>>.



EUR-Lex (2016). *Euroopan Parlamentin ja Neuvoston asetus (EU) 2016/679 luonnollisten henkilöiden suojelusta henkilötietojen käsittelyssä sekä näiden tietojen vapaasta liikkuvuudesta ja direktiivin 95/46/EY kumoamisesta (yleinen tietosuoja-asetus)*. Annettu 27.4.2016. [online] [cited 5.12.2019]. Available from Internet: <URL: <https://eur-lex.europa.eu/legal-content/FI/TXT/PDF/?uri=CELEX:02016R0679-20160504&from=FI> >.

Finanssiala Ry (2018). *Vakuutusvuosi 2018. Vakuutusyhtiöiden tulokatsaus*. [online] [cited 13.11.2019]. Available from Internet: <URL: <https://www.finanssiala.fi/materiaalit/FA-Julkaisu-Vakuutusvuosi-2018.pdf> >.

Finanssivalvonta (2019). FIN-FSA Finanssivalvonta [online][cited 16.11.2019]. Available from Internet: <URL: <http://www.finanssivalvonta.fi>>.

Finlex (2019). *Liikennevakuutuslaki*. Annettu 17.6.2016. [online] [cited 7.12.2019]. Available from Internet: <URL: <https://www.finlex.fi/fi/laki/ajantasa/2016/20160460> >.

Haikonen, Pentti O. A. (2017). *Tietoisuus, Tekoäly ja Robotit*. Art House, Bulevardi 19 C, 00120 Helsinki. Printon, Tallina 2017. ISBN 978-951-884-643-0.

Hevner, Alan. R. (2007). *A three Cycle View of Design Science Research*. Scandinavian Journal of Information Systems 19: 2, 87-92.

Hevner, Alan. R., March, S., Park, J. (2004). *Design Science in Information Systems Research*. MIS Quarterly/March 2004, Vol. 28, No. 1, 75-105.

Hiebert, Paul (2016). *The distinct personalities of car brands, as revealed by their customers*. YouGov, Global Public Opinion and Data Company. Artikkelin 28.8.2016. [online][cited 17.11.2019]. Available from Internet: <URL: >

<https://today.yougov.com/topics/lifestyle/articles-reports/2016/04/28/what-car-customers-reveal-about-brand-value> >.

Hirsjärvi, Sirkka, Remes, Pirkko & Sajavaara, Paula (2009). *Tutki ja kirjoita*. 15., uudistettu painos. Kariston kirjapaino Oy, Hämeenlinna 2009.

Hirsjärvi, Sirkka, Remes, Pirkko & Sajavaara, Paula (2008). *Tutki ja kirjoita*. 13.-14. Painos. Otavan kirjapaino Oy, Keuruu 2008.

IF (2020). If Vahinkovakuutus Oyj, Suomen sivuliike [online][cited 19.9.2020]. Available from Internet: <URL: <https://www.if.fi/henkiloasiakkaat> >.

Jobber, David & Lancaster, Geoffrey (2009). *Selling and Sales Management*. 8. painos. Pearson Education Limited, Edinburgh Gate, Harlow, Essex CM20 2JE, England. ISBN 978-0-273-72065-2.

Kivisaari, Esko & Rantala Jukka (2014). *Vakuutusoppi*. 12. uudistettu painos. Finanssi- ja vakuutuskustannus Oy. Kirjapaino Jaarli Oy, Turenki 2014.

Kotler, Philip & Keller, Kevin, Lane (2016). *Marketing Management*. 15. painos. Pearson Education Limited 2016, Edinburgh Gate, Harlow, Essex CM20 2JE, England. ISBN 978-1-292-09262-1.

Livingstone, David J. (2009). *Artificial Neural Networks. Methods and Applications*. 1. painos. Humana Press, 999 Riverview Drive, Suite 208, Totowa, NJ 07512 USA. ISBN 978-1-61737-738-9.

Nisbet, Robert, Elder, John & Miner, Gary (2009). *Handbook of Statistical Analysis and Data Mining Applications*. 1. painos. Elsevier, 30 Corporate Drive, Suite 400, Burlington, MA 01803, USA. 525 B, Street Suite 1900, San Diego, California 92101-4495, USA. 84 Tehobald's Road, London WC1X 8RR, UK. ISBN 978-0-12-374765-5.

McDonald, Malcom & Dunbar, Ian (1995). *Market Segmentation. A step-by-step approach to creating profitable market segments*. 1. painos. MACMILLIAN PRESS LTD, Houndmills, Basingstoke, Hampshire RG21 2XS and London, Great Britain. ISBN 0-333-63723-2.

Menetelmäopetuksen tietovaranto (2019). Yhteiskuntatieteellinen tietoarasto [online][cited 11.8.2019]. Available from Internet: <URL: <https://www.fsd.uta.fi/menetelmaopetus/index.html> >.

Merilehto, Antti (2018). *Tekoäly. Matkaopas johtajalle*. Alma Talent Oy, Helsinki 2018. BALTO Print 2018, Liettu. ISBN 978-952-14-3334-4.

Mitra, Rudradeb (2019). *How to Use Machine Learning for Buying Behaviour Prediction: A Case Study on Sales Prospecting*. Medium. Artikkele 18.4.2019. [online][cited 26.1.2020]. Available from Internet: <URL: <https://medium.com/omdena/how-to-use-machine-learning-for-buying-behavior-prediction-a-case-study-on-sales-prospecting-c496edd894cd> >.

Jobber, David & Lancaster, Geoffrey (2009). *Selling and Sales Management*. 8. painos. Pearson Education Limited, Edinburgh Gate, Harlow, Essex CM20 2JE, England. ISBN 978-0-273-72065-2.

Sein, Maung K., Henfridsson, Ola, Purao, Sandeep, Rossi, Matti, & Lindgren, Rikard (2011). *Action Design Research*. MIS Quarterly, 35 (1), pp. 37-56.

Strategic Business Insight (2019). *The US VALS Survey*. [online] [cited 4.12.2019]. Available from Internet: <URL: <http://www.strategicbusinessinsights.com/vals/presurvey.shtml> >.

Sumpter, David (2020). *How Swedes were fooled by one of the biggest scientific bluffs of our time*. Medium. Artikkele 14.1.2020. [online][cited 20.1.2020]. Available from Internet: <URL:

<https://medium.com/@Soccermatics/how-swedes-were-fooled-by-one-of-the-biggest-scientific-bluffs-of-our-time-de47c82601ad> >.

Tietosuojavaltuutetun toimisto (2019). *Automaattinen päätöksenteko ja profilointi*. [online] [cited 5.12.2019]. Available from Internet: <URL: <https://tietosuoja.fi/automaattinen-paatoksenteko-profilointi> >.

Tiainen Tarja, Aittoniemi, Johanna, Haukijärvi Ilkka & Yli-Karhu, Tiina (2015). *Toimintatutkimus tietojenkäsittelytieteen tutkimuksessa*. 13.-14. Tampereen Yliopisto. Informaatiotieteiden yksikkö. Informaatiotieteiden yksikön raportteja 38/2015. Huhtikuu 2015.

Wells, Taylor (2018). *Customer Profiling & Segmentation: Price like Porsche in 5 Easy Steps!*. Taylor Wells. Artikkele 19.12.2018. [online][cited 7.12.2019]. Available from Internet: <URL: <https://taylorwells.com.au/customer-profiling-segmentation/> >.

Yankelovich, Daniel & Meer, David (2006). *Rediscovering Market Segmentation*. Harvard Business Review. Artikkele Helmi 2006. [online][cited 2.2.2020]. Available from Internet: <URL: [https://s3.amazonaws.com/academia.edu.documents/48118199/Rediscovering\\_Marketing\\_Segmentation.pdf?response-content-disposition=inline%3B%20filename%3DRediscovering\\_Market\\_Segmentation.pdf&X-Amz-Algorithm=AWS4-HMAC-SHA256&X-Amz-Credential=AKIAIWOWYYGZ2Y53UL3A%2F20200202%2Fus-east-1%2Fs3%2Faws4\\_request&X-Amz-Date=20200202T072947Z&X-Amz-Expires=3600&X-Amz-SignedHeaders=host&X-Amz-Signature=80905c60d24f855423d81764a4c8f4ea5af7a8511f0e6dd1bdb8db11faad67d2](https://s3.amazonaws.com/academia.edu.documents/48118199/Rediscovering_Marketing_Segmentation.pdf?response-content-disposition=inline%3B%20filename%3DRediscovering_Market_Segmentation.pdf&X-Amz-Algorithm=AWS4-HMAC-SHA256&X-Amz-Credential=AKIAIWOWYYGZ2Y53UL3A%2F20200202%2Fus-east-1%2Fs3%2Faws4_request&X-Amz-Date=20200202T072947Z&X-Amz-Expires=3600&X-Amz-SignedHeaders=host&X-Amz-Signature=80905c60d24f855423d81764a4c8f4ea5af7a8511f0e6dd1bdb8db11faad67d2) >.

YouGov plc Corporate (2019). *About YouGov*. [online] [cited 4.12.2019]. Available from Internet: <URL: <https://today.yougov.com/about/> >.

Zoeller, Stephen (2019). *How to Segment Your Target Market: A Porsche Success Story*. Stephen Zoeller's Marketing Blog. Artikkele 26.4.2019. [online][cited 7.12.2019]. Available from Internet: <URL: <https://www.stephenzoeller.com/targetmarket-segment-porsche/>>.

## LIITTEET

### LIITE 1. Haastattelukysymykset Call Center -vastaavalle

Kohdeorganisaation tutkimustiimin Call Center -vastaavalle esitetyt haastattelukysymykset:

- Mikä on vakuutusyhtiön puhelinpalvelukeskus ja millaisia erilaisia tehtäviä sillä on?
- Paljonko puhelinpalvelukeskuksessa on työntekijöitä ja millaisia eri työtehtäviä työntekijöillä on?
- Millä termein eri työtehtävissä toimivia henkilöitä nimitetään?
- Miten puhelinpalvelukeskuksen toiminta on yleisesti organisoitu?
- Hoitavatko eri organisaatiot tyypillisesti eri asiakasryhmiä?
- Mitä termit inbound ja outbound tarkoittavat?
- Miten asiakkaille tehtäviä tai sisään tulevia puheluita ohjataan tällä hetkellä?
- Minkälaisia eri asiakkaita puhelinpalvelukeskuksella on?
- Jaotellaanko näitä mitenkään selkeästi erilaisiin ryhmiin?
- Minkälaisille kohderyhmille puhelinpalvelukeskuksen kautta tehdään myyntityötä? (Esimerkiksi uusmyynti, olemassa oleviin asiakkaisiin myynti, osittaiset asiakkaat)
- Mitä erilaisia osia kuuluu puhelinpalvelukeskuksen inboundiin? Onko esimerkiksi korvauspalvelu osa inboundia?
- Mitä erilaisia osia kuuluu puhelinpalvelukeskuksen outboundiin?
- Miten outboundin kautta tehtävä myyntityö on organisoitu?
- Miten päätetään, kenelle soimitaan ja kuka soittaa?
- Onko outboundin myyjille määritetty erikoisrooleja?
- Liittyykö outboundin tekemään myyntityöhön usein kampanjoita? Millaisia?
- Oletteko havainneet erilaisten asiakas- ja asiakaspalvelijatyyppeiden (esimerkiksi persoonallisuus, ikä, asuin- tai syntymäkaupunki, harrastukset tai muut tekijät) välillä minkäänlaista parempiin myyntituloksiin johtavaa korrelaatioita? Onko asiaan ylipäätään kiinnitetty huomioita?

- Onko asiakaspalvelijoita tai asiakkaita profiloitu tähän mennessä? Jos on, niin miten profilointia on tähän mennessä hyödynnetty?
- Onko agenteille tehty persoonallisuutta ja käyttäytymismalleja kartoittavia testejä, kuten vaikkapa DISC-profiili?
- Onko tehty tuoteryhmäkohtaista profilointia esimerkiksi onnistumisten perusteella?
- Pisteyttääkö CRM osasto soittolistoja tehdessä asiakkaiden potentiaalia? Tehdäänkö tuoteryhmäkohtaista pisteytystä?
- Millaisiin tuotekategorioihin vakuutukset yksityisasiakaspuolella karkeasti jaetaan? (Autovakuutukset, venevakuutukset, kotivakuutukset, henkilövakuutukset jne.)?

## LIITE 2. Haastattelukysymykset tekniselle vastaavalle

Kohdeorganisaation tutkimustiimin tekniselle vastaavalle esitetyt haastattelukysymykset:

- Millaisia koneoppimisen ja neuroverkkojen sovelluksia tutkimuksessa on mahdollista hyödyntää?
- Miten käyttötapauksen ympäristön järjestelmä toimii tällä hetkellä?
- Millaiset koneoppimisen sovellukset näet tällä hetkellä itse tutkimusongelman kannalta potentiaalisimpina vaihtoehtoina?
- Millaista historiadataa tutkimuksessa on mahdollista hyödyntää? Kuinka paljon sitä on käytössä? Onko mahdollista käyttää eri myyjien hitrateja tuotealueittain?
- Minkälaisessa muodossa artefakti tulisi tuottaa? Paljonko erilaisia ominaisuuksia voidaan valita?
- Tarvitseeko tutkimuksessa miettiä luokkien sisällä datalle vaihteluvälejä, vai tekeekö CRM, tai jokin muu osasto tämän?
- Miten testi on yleisesti tarkoitus toteuttaa?
- Millaisia asiakkaita testissä on tarkoitus kontaktoida? (Uusi, osittainen, olemassa oleva)
- Onko kontaktointi tarkoitus liittää johonkin kampanjaan?
- Mitä asiakkaille testissä myydään? (Vakuutuskokonaisuutta, yksittäistä vakuutusta, johonkin kampanjaan liittyvää tuotetta?)
- Miten myynnin hitrate% määritellään. (Uudet vakuutuskappaleet per asiakaskontakti, euromäärä, jokin muu?)
- Montako RIE sykliä tutkimuksessa tehdään? Vai päätetäänkö tulosten perusteella?