



Osaamista  
ja oivallusta  
tulevaisuuden  
tekemiseen

Hiski Vihermaa

## Kohti älykästä automaatiota

Tekoälyn käyttöönotto taloushallinnon  
prosessiautomaatiossa

Metropolia Ammattikorkeakoulu

Tradenomi

Liiketalouden tutkinto-ohjelma

Opinnäytetyö

Toukokuu 2021

Tekijä Otsikko	Hiski Vihermaa Kohti älykästä automaatiota. Tekoälyn käyttöönotto taloushallinnon prosessiautomaatiossa.
Sivumäärä Aika	40 sivua toukokuu 2021
Tutkinto	tradenomi
Tutkinto-ohjelma	liiketalous
Suuntautumisvaihtoehto	laskentatoimi ja rahoitus
Ohjaaja	Lehtori Raija Olkkola
<p>Tämän opinnäytetyön tarkoituksena oli selvittää tekoälyteknologian taloushallinnon automaatioon käyttöönotossa huomioitavia tekijöitä. Tavoitteena oli tuoda esille yleisiä hyviä toimintatapoja käyttöönottoon, tutustumalla tekoälyyn, taloushallintoon ja taloushallinnon prosessiautomaatioon. Työssä oli tarkoituksena selvittää käyttöönottoon valmistautumisessa, sen käytännön toteutuksessa, ja sen jälkeen huomioitavia seikkoja. Työn teoreettisena viitekehysenä oli tekoälytutkimus ja taloushallintoa ja laskentatoimea käsittelevä aineisto.</p> <p>Opinnäytetyö toteutettiin perehtymällä tekoälyä ja taloushallintoa käsitteleviin kirjallisiin lähteisiin. Lisäksi tutustuttiin konkreettiseen esimerkkiin tekoälyn käytöstä taloushallinnon automaatiiossa haastatteleamalla toimeksiantajayrityksen asiantuntijaa. Työssä käsiteltiin tekoälyä ja digitaalista taloushallintoa erillisinä kokonaisuuksina sekä yleisesti tekoälyn käyttöä taloushallinnon automaatiiossa. Lopussa selvitettiin käyttöönottoprosessin osat ja pohdittiin niitä taloushallinnon näkökulmasta.</p> <p>Työssä tultiin siihen johtopäätökseen, että tekoälyn käyttöönotto taloushallinnon automaatiiossa edellyttää digitaalista taloushallintoa ja toimivia prosesseja. Ehdottomia edellytyksiä onnistuneelle käyttöönotolle ovat myös riittävä ja laadukas data sekä datan hallinta. Käyttöönottoa tukee myös oikeanalainen projektitiimi, henkilökunnan kouluttaminen ja kokeileva työilmapiiri. Lisäksi käyttöönotto kannattaisi aina tehdä osissa, jolloin tekoälysovellusta voidaan ensin pilotoida vain osalla käyttäjistä.</p>	
Avainsanat	laskentatoimi, taloushallinto, tekoäly, prosessiautomaatio

Author Title	Hiski Vihermaa Towards intelligent automation. Implementing artificial intelligence to financial management process automation.
Number of Pages Date	40 pages May 2021
Degree	Bachelor of Business Administration
Degree Programme	Economics and Business Administration
Specialisation option	Accounting and Finance
Instructor	Raija Olkkola, Senior Lecturer
<p>The purpose of this thesis was to examine which factors should be considered when implementing artificial intelligence to financial management automation. The goal was to disclose the best practice models for preparing and executing the implementation, and also for the follow up measures. The theoretical framework of the study was the research of artificial intelligence, and sources dealing with financial management and accounting.</p> <p>The study was carried out by exploring literature discussing artificial intelligence and financial management. Additionally, one concrete case of artificial intelligence used in financial management automation was discovered by interviewing a specialist working for the client company that commissioned the study. In the study, artificial intelligence and financial management are covered as separate entities, and also the first being generally utilized in the latter. Finally, the phases of the implementation process were examined and reflected from the aspect of the financial management.</p> <p>The conclusion of the thesis was, that implementing artificial intelligence to financial management automation requires digital financial management and quality processes. Adequate amount of quality data and efficient data management are also unconditional prerequisites for a successful implementation. The implementation is also advanced by an appropriate project team, training of the personnel, and an innovative working atmosphere. Additionally, the implementation should also be executed in sections, when the application can be first piloted for a limited part of users.</p>	
Keywords	Accounting, financial management, artificial intelligence, process automation

## Sisällys

1	Johdanto	1
1.1	Opinnäytetyön perustelu	1
1.2	Opinnäytetyön tavoite	1
1.3	Opinnäytetyön esittely	2
2	Tekoäly	2
2.1	Tekoäly yleisesti	2
2.2	Tekoälyn ja perinteisen ohjelmoinnin ero	3
2.3	Koneoppiminen	4
2.3.1	Ennustemallit	4
2.3.2	Koneoppimisen algoritmit	5
2.4	Syväoppiminen	7
2.4.1	Neuroverkot	8
2.4.2	Neuronin toiminta	9
2.5	Tekoälyn kouluttaminen	9
2.5.1	Valmistelu	10
2.5.2	Ohjattu oppiminen	11
2.5.3	Ohjaamaton oppiminen	11
2.5.4	Testaus ja validointi	12
2.5.5	Vahvistusoppiminen	12
2.5.6	Neuroverkon oppiminen	13
2.6	Data	13
2.6.1	Data tekoälyn perustana	14
2.6.2	Ominaisuudet	15
2.6.3	Mallin monimutkaisuus	15
2.7	Suorituskyvyn määrittely	16
3	Taloushallinto	19
3.1	Taloushallinto yleisesti	19
3.2	Digitaalinen taloushallinto	20
3.3	Taloushallinnon automaatio	21
3.4	Taloushallinnon prosessit	22
3.4.1	Ostolaskuprosessi	23
3.4.2	Myyntilaskutusprosessi	25

3.4.3	Matkalaskuprosessi	25
3.4.4	Maksuliikenne	26
3.4.5	Käyttöomaisuuskirjanpito	26
3.4.6	Pääkirjanpito	27
3.5	Raportointi	27
3.5.1	Ulkoisen raportointi	28
3.5.2	Sisäinen raportointi	28
4	Tekoäly taloushallinnon automaatiassa	29
4.1	Tekoäly taloushallinnon apuna	29
4.2	Käyttökohteet	30
4.3	Datan käsittely	30
4.4	Tekoäly apuna raportoinnissa	31
4.5	Kohdeyrityksen ostolaskuprosessi	31
5	Tekoälyn käyttöönotto taloushallinnossa	32
5.1	Valmistautuminen käyttöönottoon	32
5.2	Käyttöönoton toteutus	34
5.3	Käyttöönoton jälkeen	35
6	Pohdinta ja johtopäätökset	35
7	Lopuksi	37
	Lähteet	39

# 1 Johdanto

## 1.1 Opinnäytetyön perustelu

Tekoäly on yksi tämän hetken suurimmista megatrendeistä ja tulee mullistamaan tulevaisuuden työelämän. Tekoälyyn perustuvat teknologiat ovat kehittyneet huimasti 2010-luvun alusta lähtien, mikä on johtanut erityisesti laskentatehon ja datan saatavuuden kasvusta. Tämä on johtanut tekoälyteknologioiden markkinan huomattavaan kasvuun. Nykyään lähes jokainen meistä on päivittäin tekemisissä tekoälyn kanssa, esimerkiksi internetiä tai älypuhelimia käyttäessään.

Tässä opinnäytetyössä käsitellään tekoälyn käyttöönottoa taloushallinnon prosessiautomaatiossa. Aiheeseen tutustutaan erityisesti ostoreskontran ympäristössä. Työssä käsitellään tekoälyä yleisesti ja esitellään sen perustoimintoja ja ominaisuuksia. Lisäksi esitellään digitaalisen taloushallinnon perustoiminnot ja se miten tekoälyä voidaan hyödyntää sen automaatiossa.

Tekoälyn yleistyessä on tärkeää ymmärtää mitä tekoäly todella on, mihin teknologioihin se perustuu ja mihin sitä voidaan käyttää. Taloushallintojärjestelmien kehittyessä ja automaation lisääntyessä, myös taloushallinnon asiantuntijoiden työ kehittyi manuaalisesta työstä enemmän järjestelmäasiantuntijan työksi. Tämä asettaa uusia vaatimuksia asiantuntijoiden osaamiselle, ja myös ymmärrys tekoälyn toiminnasta tulee tarpeelliseksi.

## 1.2 Opinnäytetyön tavoite

Opinnäytetyön tavoitteena on selvittää, miten tekoäly otetaan tehokkaasti käyttöön taloushallinnon automaatiossa. Huomioitavia kohtia ovat käyttöönoton edellytykset, siihen valmistautuminen, sen käytännön toteutus ja jälkiseuranta. Käyttöönottoa tarkastellaan käytännöllisesti taloushallinnon näkökulmasta. Esimerkiksi tekoälyn käyttöönoton vaikutuksia yrityksen strategiaan, talouteen tai markkinointiin ei käsitellä tässä opinnäytetyössä.

Työn toimeksiantajan tavoitteena on selvitys tekoälyn tehokkaasta käyttöönotosta taloushallinnon automaatiossa. Toimeksiantaja on suomalainen yksityinen yhtiö, joka tar-

joaa asiakkailleen taloushallinnon ohjelmistoja, automaatoratkaisuja, ja ulkoistuspalveluita. Ulkoistuspalveluiden kautta asiakasyritys voi ulkoistaa yhtiön hoidettavaksi taloushallintonsa osittain tai kokonaan, ja myös ulkoistustoiminnassa pyritään voimakkaasti kehittämään ja automatisoimaan asiakkaan taloushallinnon prosesseja. Yhtenä ratkaisuna automaatiossa on tekoäly, ja tässä toimintaympäristössä työssä perehdytään asiaan.

### 1.3 Opinnäytetyön esittely

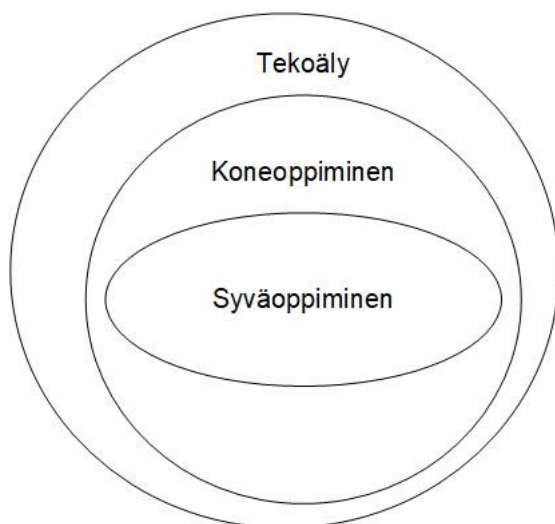
Opinnäytetyö on toteutettu suurimmaksi osaksi tutustumalla tekoälytutkimukseen ja taloushallintoa käsittelevään kirjallisuuteen. Lisäksi työssä on käytetty apuna yksittäisiä internetlähteitä ja laskentatoimen oppikirjoja. Työtä varten on myös haastateltu toimeksiantajan työntekijää, joka on ollut mukana tekoälyn käyttöönottoprojektissa.

Työ on teoriapainotteinen ja sisältää paljon käsitteitä, joita pyritään selventämään. Työn toisessa ja kolmannessa luvussa käsitellään tekoälyä ja taloushallintoa erillisinä kokonaisuuksina, ja kolmannessa luvussa ne vedetään yhteen ja käsitellään yleisesti tekoälyn hyödyntämistä taloushallinnon automaatiossa. Lopuksi esitellään tekoälyn käyttöönotossa huomioitavia seikkoja, pohditaan niitä ja tehdään johtopäätökset.

## 2 Tekoäly

### 2.1 Tekoäly yleisesti

Tekoälyllä tarkoitetaan yleisesti ohjelmistojen ja koneiden toimintaa, joka olisi ihmisen tekemänä viisasta (Merilehto 2018, 18). Terminä tekoäly on epätarkka kattoterminä, joka viittaa moneen tekniikkaan ja menetelmään, jotka voidaan lukea siihen kuuluviksi (Kananen & Puolitaival 2019, 21). Tekoälystä puhuttaessa onkin tärkeitä hahmottaa jo alussa sen keskeisimmät käsitteet. Koneoppiminen on tekoälyn tutkimusala, joka kehittää kokemuksesta oppivia ohjelmistoja. Syväoppiminen on puolestaan koneoppimisen alalaji, joka hyödyntää oppimisessa syviä neuroverkkoja. (Kelleher 2019, 15, 223.) Tekoälyn keskeisten osa-alueiden suhde toisiinsa on esitetty kuviossa 1.



Kuvio 1. Tekoälyn osa-alueet (Kelleher 2019, 15).

Yleisesti tekoäly jaetaan heikkoon ja vahvaan tekoölyyn. Heikko tai kapea tekoäly pystyy ratkaisemaan yksittäisiä sille opetettuja tehtäviä. Vahva tekoäly on puolestaan älykkyydeltään lähellä ihmisen tasoa ja osaa soveltaa tietoa. Kaikki nykyiset tekoälysovellukset perustuvat heikkoon tekoölyyn. (Kananen & Puolitaival 2019, 38.)

## 2.2 Tekoälyn ja perinteisen ohjelmoinnin ero

Algoritmi tarkoittaa prosessia tai ohjetta, jota tietokone noudattaa (Kelleher 2019, 16). Perinteisen ohjelmoinnin ja tekoälyn keskeinen ero on se, että tekoälyn hyödyntämät koneoppivat algoritmit pystyvät prosessoimaan dataa ilman, että niitä on erityisesti ohjelmoitu juuri kyseiselle datalle (Akerkar 2019, 21). Sääntöpohjaisessa, eli perinteisenä pidetyssä, ohjelmoinnissa algoritmilta koodataan säännöt, joiden mukaisesti sen halutaan käsittelevän dataa. Tämä kuitenkin rajoittaa teknologian kehitystä: esimerkiksi toimivan kuvantunnistusalgoritmin ohjelmointi sääntöpohjaisesti vaatisi todella paljon työtä. Tekoälypohjainen ohjelmointi on puolestaan kaksiosainen prosessi. Ensimmäisessä vaiheessa tekoäly koulutetaan erityisellä koulutusdatalla, josta algoritmi itse löytää tarvitsemansa säännönmukaisuudet. Toisessa vaiheessa koulutetulle tekoöllylle annetaan uutta dataa, johon se soveltaa aiemmin oppimiansa sääntöjä ja antaa niiden perusteella todennäköisen vastauksen tai ennusteen. (Kananen & Puolitaival 2019, 27–30.)

Sääntöpohjainen ohjelmointi on luonteeltaan determinististä, eli se tarkastelee ilmiötä muuttumattomina ja olettaa niiden tapahtuvan aina tietyllä tavalla. Maailma ei kuitenkaan ole deterministinen tai toimi sääntöjen mukaan, eivätkä kaikki ilmiöt ole todellisuudessa



täysin ennustettavissa ja ennakoitavissa, vaan niihin liittyy aina epävarmuutta. Tämän vuoksi deterministinen lähestymistapa toimii vain rajallisesti. Sen sijaan maailman ilmiöt noudattavat tilastollisia todennäköisyyksiä. Tekoälyn toiminta perustuu näihin tilastollisiin todennäköisyyksiin, eli se on luonteeltaan stokastinen prosessi. Stokastisessa prosessissa lähtökohtana on se, että nykytila on aina riippumaton aikaisemmista tiloista. Yksittäistä tapahtumaa ei voida varmuudella kuvata etukäteen, mutta tilastojen pohjalta voidaan määrittellä keskimääräinen tapahtuma. Tekoälymallin toiminta perustuu tilastollisiin todennäköisyyksiin, ja siksi sekin voi antaa yksittäisissä tapauksissa väärän vastauksen. (Kananen & Puolitaival 2019, 31–32, 236.)

### 2.3 Koneoppiminen

Koneoppiminen on tekoälyn keskeinen osa-alue. Perinteisessä eli sääntöpohjaisessa ohjelmoinnissa kehittäjä koodaa algoritmit, joiden avulla ohjelma käsittelee dataa ja jotka määräävät säännöt sen toiminnalle. Koneoppiminen puolestaan hyödyntää algoritmeja, jotka oppivat niille annetusta datasta. Ohjelma tunnistaa datasta itse sääntönsä, joita se käyttää tunnistuksessa ja luokittelussa. (Merilehto 2018, 27–30.)

Matemaattinen funktio on kuvaus syötearvojen joukosta yhteen tai useampaan ulostuloarvoon. Funktiot ovat deterministisiä, eli funktio tuottaa samoilla syötearvoilla aina saman ulostulon. Koneoppivan algoritmin tehtävä on tunnistaa tietoaineistosta syötteiden välisiä suhteita kuvaavia funktioita ja valita niistä paras. (Kelleher 2019, 18–19.)

#### 2.3.1 Ennustemallit

Koneoppimiseen perustuvan tekoälyn tuottamat ennustemallit voidaan jakaa kahteen pääluokkaan: luokittelu- eli klassifikaatiomalleihin ja määrä- eli regressiomalleihin. Luokittelumallit ennustavat jonkin ilmiön todennäköisyyttä. Tyypillisesti ennustetaan tapahtuuko jokin asia vai ei, mutta ennustettavia luokkia voi olla myös useita. (Kananen & Puolitaival 2019, 109–110.) Määrämallit puolestaan ennustavat numeerisia arvoja. Niiden ennusteet perustuvat laskennalliseen korrelaatioon datapisteiden välillä. (Akerkar 2019, 23.)


Ennustemallit voivat olla apuna päätöksenteossa, sillä ne ovat tarkkoja ja nopeuttavat ennusteiden laatimista suuresta data-aineistosta. Mallit ovat suhteellisen edullisia, sillä kehitysvaiheen jälkeen niiden kustannustaso on matala. Tämän vuoksi tekoälypohjaisiin

ennustemalleihin perustuvia ohjelmia onkin käytetty täydentämään tai korvaamaan asiantuntijoiden työtehtäviä. (Kananen & Puolitaival 2019, 111.)

### 2.3.2 Koneoppimisen algoritmit

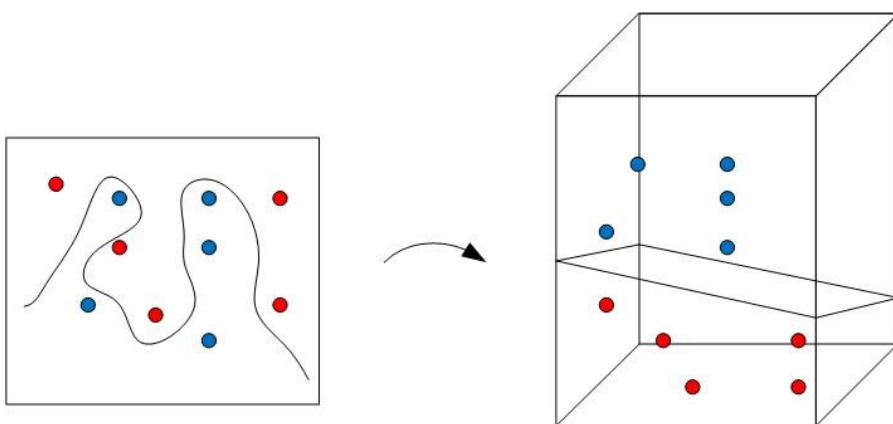
Tekoälyalgoritmeja on useita erilaisia, ja niistä täytyy valita aina tarkoituksenmukaisin ratkaistavaan ongelmaan. Tekoälysovelluksissa tarvitaan yleensä useita eri algoritmeja yhden ilmiön mallintamisessa. Algoritmit voidaan jakaa viiteen ryhmään sen perusteella, miten ne käsittelevät dataa. Regressioalgoritmit kuvaavat kahden muuttujan välistä suhdetta vastaamalla siihen, mitä muuttujalle A tapahtuu, kun muuttuja B muuttuu. Luokittelualgoritmit jakavat datan määrättyihin kategorioihin, ja ryhmittelyalgoritmit puolestaan ryhmittelevät datan ilman ennalta määrättyjä luokkia. Sijoitusalgoritmit järjestävät datan järjestykseen, ja generaatioalgoritmit pystyvät tuottamaan esimerkiksi tekstiä ja kuvia. (Kananen & Puolitaival 2019, 112–117.)

K-Nearest Neighbour eli KNN-algoritmi on yksi koneoppimisen luokittelualgoritmeista. Algoritmi yksinkertaisesti päättää annetun datapisteen luokan sillä perusteella, mihin ennalta määrättyyn luokkaan kuuluvia datapisteitä on eniten sen lähetyvillä koordinaatistossa. Kuvion 2 kuvitteellisessa tilanteessa datapiste A on määritelty siniseksi, koska sen lähellä on eniten sinisiä datapisteitä. KNN-algoritmi on yksinkertainen, monikäyttöinen ja tehokas, kun käytössä on paljon dataa. Algoritmin huono puoli on se, että se on laskennallisesti raskas. (Kananen & Puolitaival 2019, 118–119.)



Kuvio 2. K-Nearest Neighbour algoritmi (Kananen & Puolitaival 2019, 119).

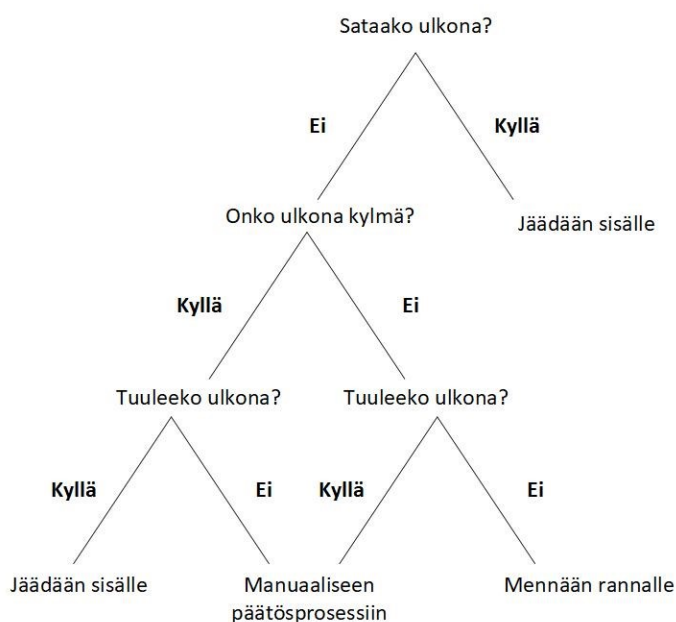
Support vector machine eli SVM, tai tukivektorikone on algoritmi, joka sopii klassifikaatio- ja regressiomalleihin. (Kananen & Puolitaival 2019, 118.) SVM-algoritmi luo koordinaatistoon hypertason, jolla havaintopisteet jaetaan eri luokkiin. Hypertaso asettuu koordinaatistossa luokkien väliin kohtaan, jossa etäisyys lähimpiin datapisteisiin on mahdollisimman suuri. (Joshi 2020, 65.) SVM-algoritmin toimintaperiaate on helppo esittää, kun havainnot voidaan jakaa lineaarisella suoralla. Todellisuudessa data ei yleensä ole niin selkeätä eli toisin sanoen puhdasta. Data on usein sekalaista, jolloin sitä kutsutaan ei-lineaarisesti separoituvaksi. Tässä tilanteessa datasettiin täytyy lisätä ulottuvuuksia eli dimensioita. Data voidaan kuvata kolmiulotteisessa asteikossa, jolloin luokat pystytään erottelamaan kaksiulotteisella hypertasolla. Tätä toimenpidettä kutsutaan termillä kernel trick eli kernelöinti, ja se on esitetty kuviossa 3. SVM-algoritmin etuja ovat sen tarkkuus ja toimivuus pienillä ja puhtailla dataseiteillä. Toisaalta isoilla dataseiteillä algoritmi vaatii paljon aikaa ja laskentatehoa, ja sen tarkkuus heikkenee datan laadun huonontuessa. (Kananen & Puolitaival 2019, 118–119.)



Kuvio 3. Kernel trick (Kananen & Puolitaival 2019, 123).

Naïve Bayes -algoritmi perustuu Bayesin teoreemaan ehdollisista todennäköisyyksistä (Massaron & Mueller 2018, 145). Algoritmin etuliite ”naïvi” johtuu siitä, että sen luokittelussa tehdään lähtöoletus, että ilmiön ominaisuudet ovat riippumattomia toisistaan. Todellisuudessa kaikki ominaisuudet ovat vain harvoin täysin toisistaan riippumattomia, ja tämä onkin Naïve Bayes -algoritmin keskeinen heikkous. Toisaalta algoritmilla saadaan usein parempia tuloksia kuin monimutkaisemmilla algoritmeilla. Lisäksi algoritmi on yksinkertainen, nopea ja helppo kouluttaa, eikä se ole herkkä epäolennaisille ominaisuuksille. (Kananen & Puolitaival 2019, 124.)

Decision tree eli päätöspuu algoritmi on koneoppimisen menetelmä, joka jäljittelee ihmisen päätöksentekoa. Algoritmi toimii sekä luokittelu- että regressiosovelluksissa. Päätöspuun toimintalogiikka on esitetty kuviossa 4. Algoritmin päättelyprosessi alkaa sen juuresta, joka on kuvassa ylimpänä. Kuvion haarat ovat yksittäisiä luokittelutestejä, ja niistä seuraavia luokkia kutsutaan päätöspuun lehdeksi. (Akerkar 2019, 24.) Päätöspuun vahvuuksia ovat sen toimintalogiikan yksinkertaisuus ja helppo tulkittavuus ja visualisointi (Kananen & Puolitaival 2019, 125). Päätöspuut ovat myös nopeita ja tarkkoja, mutta toisaalta ne skaalautuvat huonosti isoihin datasetteihin (Akerkar 2019, 25).



Kuvio 4. Päätöspuun toimintalogiikka (Kananen & Puolitaival 2019, 125).

## 2.4 Syväoppiminen


Syväoppimisella tarkoitetaan tekoälyn oppimista, joka hyödyntää syviä neuroverkkoja. Neuroverkot ovat ihmisaivojen rakennetta jäljittelevä malleja, jotka koostuvat lukuisista neuroneista. Neuroverkot yleistyivät 2010-luvun aikana, mikä selittyy erityisesti datan ja laskentatehon saatavuuden kasvulla. Niiden kehitys on mahdollistanut tekoälylle aiempaa monimutkaisempien tehtävien suorittamisen. (Kananen & Puolitaival 2019, 127–129.)

Syväoppiminen mahdollistaa koneille oppimisen, joka muistuttaa ihmisen tiedonkäsitteilykykyä. Sen avulla kone voi oppia esimerkiksi tunnistamaan puhetta ja kuvia. (Akerkar 2019, 33.)

### 2.4.1 Neuroverkot

Neuroverkkojen tehokkuus ei perustu monimutkaisiin matemaattisiin malleihin, vaan niiden lukuisien neuronien yksinkertaisten laskusuoritusten vuorovaikutukseen. Neuroverkot kuvataan yleensä useista kerroksista rakentuvina. (Kelleher 2019, 66.) Neuroverkoista käytetään myös usein lyhennettä ANN, joka tulee sanoista artificial neural network (Akerkar 2019, 30).

Yksi neuroverkko koostuu syötekerroksesta, ulostulokerroksesta ja näiden välissä sijaitsevista piilokerroksista. Syötekerros koostuu vain aistineuroneista eli muistipaikoista, joista tieto tulee verkkoon. Aistineuronit eivät käsittele tietoa, vaan vastaavat niihin tallennetun tiedon arvoa. Ulostuloskerros on neuronien viimeinen kerros, ja se tuottaa mallin ulostuloarvon. Piilokerroksen määritelmä on yksinkertaisesti se, ettei se ole syöte- tai ulostulokerros. Piilokerrosten määrä, johon lasketaan mukaan myös ulostuloskerros, on neuroverkon syvyyden mitta. Tämä osa neuroverkosta on se, joka käsittelee tietoa. Vähintään kaksi piilokerrosta sisältävät neuroverkot määritellään syviksi neuroverkoiksi, mutta yleensä syviin neuroverkkoihin kuuluu kuitenkin huomattavasti tätä useampia piilokerroksia. (Kelleher 2019, 66–68.) Yksinkertaisen neuroverkon rakenne on esitetty kuviossa 5.



Kuvio 5. Neuroverkon rakenne (Kelleher 2019, 19).

Neuroverkossa informaatio virtaa neuronista toiseen. Prosessoivien neuronien syöteinä toimivat joko aistineuronien tai toisten prosessoivien neuronien ulostulot. Neuronit muuntaa syötteenä saamansa numeeriset arvot yhdeksi ulostuloarvoksi. Jokaiselle neuronien väliselle kytkennälle on asetettu paino, joka vaikuttaa siihen, mitä arvoja neuroni painottaa laskennassa ja kuinka paljon. (Kelleher 2019, 68.) Määriteltävään painoon vaikuttaa se, kuinka vahvasti käsiteltävät asiat ovat sidoksissa toisiinsa. (Kananen & Puolitaival 2019, 129.)

Syvien neuroverkkojen pohjalta on kehitetty takaisinkytkettyvät neuroverkot, jotka pysyvät mallintamaan dataa, jossa on ajallista keskinäisriippuvuutta. Takaisinkytkettyistä neuroverkoista käytetään myös lyhennettä RNN, joka tulee sanoista recurrent neural networks. Verkon rakenne perustuu syvään neuroverkkoon, johon on lisätty takaisinkytkennät ulostulokerroksesta ja piilokerroksista edeltäviin piilokerroksiin. Tämän seurauksena neuronit vaikuttavat ulostulollaan myös omaan syötteeseensä. (Pietikäinen & Silvén 2019, 98-99.)

#### 2.4.2 Neuronin toiminta

Yksittäisen neuronin toimintaprosessi on kaksivaiheinen. Ensimmäisessä vaiheessa neuroni laskee vastaanottamiensa syötteiden painotetun summan, ja toisessa vaiheessa tämä summa syötetään aktivaatiofunktiolle, joka kuvaa sen ulostuloarvoksi. Neuronin ulostuloarvoa kutsutaan myös sen aktivaatioarvoksi. (Kelleher 2019, 68–69.) Neuronin käyttämälle aktivaatiofunktiolle on joitain eri vaihtoehtoja, mutta näistä käytetyin on sarena-aktivaatiofunktio eli rectified linear unit (Kananen & Puolitaival 2019, 131).

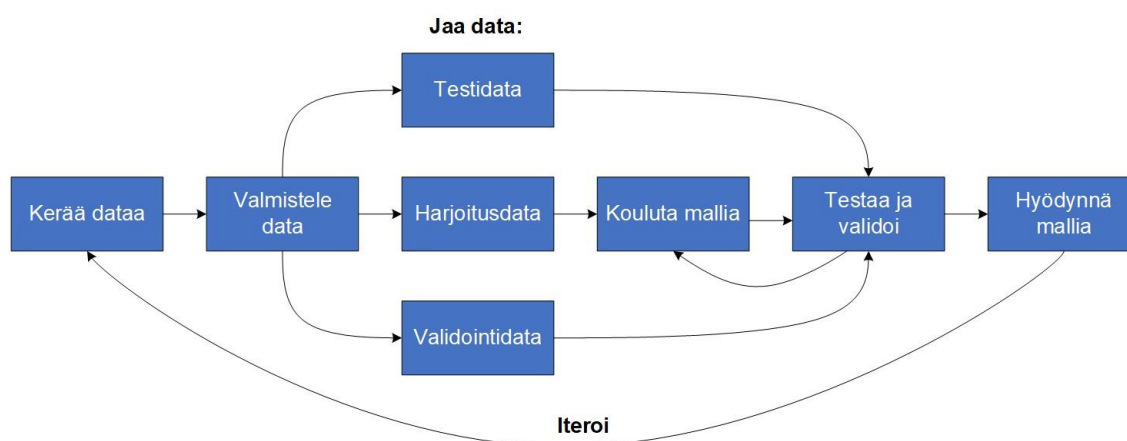
Neuronin parametreja ovat painot, joita se käyttää painotetun summan laskemiseen. Muokkaamalla painoja vaikutetaan siihen, miten neuroni painottaa vastaanottamiaan syötteitä eli millä perusteella se tekee päätöksiä (Kelleher 2019, 78–79.) Mitä suurempi jokin asetettu paino on, sitä enemmän painotettu ominaisuus vaikuttaa käsiteltävään ilmiöön (Kananen & Puolitaival 2019, 133).

#### 2.5 Tekoälyn kouluttaminen

Koneoppimisen algoritmit jaetaan sen mukaan, miten data annetaan koneelle eli kuinka se koulutetaan. Koulutuksen avulla kone luo matemaattisen mallin, jota se myöhemmin soveltaa uudelle datalle. Tämä malli kuvaa datasetin datapisteiden välisiä riippuvuuksia, ja sen avulla tekoäly pystyy luomaan yleistyksiä käsittelemästään datasta. Koulutettu tekoälymalli pyrkii löytämään samoja riippuvuuksia sille syötetystä uudesta datasta ja luomaan ennustuksia sen avulla. Tekoälyn kouluttamisen tavat jaetaan ohjattuun ja ohjaamattomaan oppimiseen sekä vahvistusoppimiseen. (Kananen & Puolitaival 2019, 45.)

Ohjatun ja ohjaamattoman koneoppimisen prosessi on kuvattu kuviossa 6. Prosessi alkaa datan keräämisellä, valmistelulla ja jakamisella testi-, harjoitus- ja validointidataan. (Akerkar 2019, 21-22.) Malli koulutetaan harjoitusdatalla, ja validointidatalla testataan

sen tuottamaa ennustusvirhettä. Tämä kertoo esimerkiksi mallin soveltuvuudesta ja koulutuksen laadusta. Testidatalla testataan mallin toimintaa, kun sen oletetaan saavutaneen optimaalisen koulutuksen. (Pietikäinen & Silvén 2019, 70.) Mikäli koulutettu malli ei toimi testidatalla, sitä on koulutettava lisää. Kun tekoälymalli on validoitu, se voidaan hyväksyä käyttöön. Käytössä ollutta mallia voidaan parantaa iteroimalla eli toistamalla koulutusprosessi uudelleen käytössä kertyneellä datalla. (Akerkar 2019, 22.)



Kuvio 6. Koneoppimisen prosessi (Akerkar 2019, 22).

### 2.5.1 Valmistelu

Tekoälyn koulutus alkaa datan keräämisellä. Yrityksestä riippuen kerättävä data voi olla tietoa esimerkiksi asiakkaista tai myynnistä, ja se voi olla muodoltaan esimerkiksi kuvia, tekstiä tai taloustietoja. Datan valmistelussa tästä kerätystä tiedosta luodaan yhtenäinen ja johdonmukainen tietokanta. Tämä vaihe voi olla pitkäkestoinen, mikäli data on laadultaan huonoa tai epäyhtenäistä. Huonosti tehty valmistelu kuitenkin näkyy myös lopputuloksessa. (Kananen & Puolitaival 2019, 46.)

Valmisteltu data muodostaa datasetin. Kerätty datasetti jaetaan kolmeen erikokoiseen osaan, joita kutsutaan koulutus-, testaus- ja validointidataseiteiksi. Perinteisessä koneoppimisessa alkuperäinen datasetti on yleensä kooltaan 1 000–100 000 näytettä, mikä on tekoälyn mittakaavassa vielä melko pieni määrä dataa. Tällöin testaus- ja validointidataseiteihin täytyy varata kumpaankin noin 20 prosenttia datasta, jotta datasetit ovat tilastollisesti edustavia. Tässä tilanteessa koulutusdataksi jää 60 prosenttia alkuperäisestä datasetistä. Syväoppivia neuroverkkoja koulutettaessa dataa on oltava miljoonia näytteitä, jolloin testaus- ja validointidataksi riittää vain yksi prosentti kokonaisdatasta kumpaankin, sillä jo tämä osuus on riittävän suuri. (Kananen & Puolitaival 2019, 46.)

### 2.5.2 Ohjattu oppiminen

Ohjatusta oppimisesta käytetään myös englanninkielistä termiä supervised learning, ja Heidi Kanasen ja Harri Puolitaipaleen mukaan se on suosituin koneoppimisen muoto liiketoiminnassa (Kananen & Puolitaival 2019, 48–50). Ohjattua oppimista käytetään malleille, jotka halutaan opettaa ennustamaan niille annetusta aineistosta (Akerkar 2019, 19).

Tässä koulutusmallissa tekoälylle annetaan koulutusdataa, johon on merkitty sen oikea vastaus. Jos kone haluttaisiin esimerkiksi kouluttaa tunnistamaan kuvasta kissa ja koira, sille annettaisiin näistä eläimistä lukuisia kuvia, joihin olisi valmiiksi liitetty tietoa siitä kumpi on kyseessä. Näitä koulutusesimerkkejä kutsutaan data–vastaus-pareiksi. Tämän jälkeen koulutetulle koneelle voitaisiin antaa täysin uusia kuvia kissoista ja koirista, ja se osaisi antaa vastauksen aiemmin käsittelemänsä koulutusdatan perusteella. Kone voidaan myös kouluttaa tunnistamaan kuvasta muitakin ominaisuuksia kuin eläimen lajin, kuten sen rodun ja värin. Tällöin koulutusdatan tietoon täytyy vain lisätä halutut lisäominaisuudet. (Kananen & Puolitaival 2019, 48–49.)

Esimerkkitapauksessa on kuitenkin otettava huomioon, että kone on koulutettu tunnistamaan kuvista vain kissat ja koirat eikä se tunnistaisi esimerkiksi laamaa kuvasta. Jos sen haluttaisiin oppivan tunnistamaan kuvasta laaman, pitäisi kone kouluttaa uudestaan laamaa esittäville kuvilla. Ongelmia muodostuu myös, mikäli koulutusdata on valmisteltu huolimattomasti. Jos esimerkkitapauksessa koulutusdataan on virheellisesti merkitty kissan kuvaan tieto, että kyseessä olisi koira, myös koulutettu malli tekee saman virheen. (Kananen & Puolitaival 2019, 48–49.)

### 2.5.3 Ohjaamaton oppiminen

Ohjaamattomasta oppimisesta käytetään myös englanninkielistä termiä unsupervised learning. Ohjaamaton oppiminen eroaa ohjatusta oppimisesta oleellisimmin siinä, ettei aineistoon ole oikeata vastausta, joka malli haluttaisiin saada oppimaan. Tässä oppimistavassa algoritmille annetaan dataa, josta sen halutaan etsivän säännönmukaisuuksia. Ohjaamattoman oppimisen tavoitteena on, että tekoäly organisoisi datan itsenäisesti ja löytää siitä poikkeukset. (Kananen & Puolitaival 2019, 51.)



Ohjaamatonta oppimista käytetään usein aineiston klusteroinnissa eli ryhmittelyssä. Tällöin algoritmi ryhmittelee aineiston ominaisuuksiensa perusteella siten, että kuhunkin ryhmään kuuluvat datapisteet muistuttavat enemmän toisiaan kuin muiden ryhmien datapisteitä. (Kelleher 2019, 33). Algoritmin hyperparametreja säätämällä voidaan vaikuttaa siihen, mihin ominaisuuksiin se kiinnittää huomiota, mitä ominaisuuksia se painottaa ja mitkä se jättää kokonaan huomioimatta. Näin voidaan esimerkiksi rajata aineistosta pois ääritapauksia tai halutessa saada juuri ääritapaukset näkyviin. Ohjaamaton oppiminen toimii myös silloin, kun tekoälyn avulla halutaan löytää datasta poikkeamia. (Kananen & Puolitaival 2019, 52–54.)

#### 2.5.4 Testaus ja validointi

Kun tekoälymallia on koulutettu koulutusdatasetillä, arvioidaan testausdatasetillä mallin toimintaa, ja miten tarkkoja ennusteita se tuottaa. Ennen käyttöönottoa mallin toimivuus täytyy vielä varmistaa validointidatasetillä. Validointivaiheessa mallille annetaan dataa, jonka todelliset vasteet ovat jo kouluttajan tiedossa. Näin tekoälyn antamia ennusteita voidaan vertailla toteutuneisiin tuloksiin, ja nähdään toimiiko malli. (Kananen & Puolitaival 2019, 47.)

Mallin testaamisen ja validoinnin tarkoituksena on arvioida sitä, miten algoritmi toimii kohdatessaan uutta dataa. Uuden datan avulla saadaan havaintoja siitä, miten hyvin malli pystyy yleistämään oppimaansa. (Alerkar, 2019. 22.)

#### 2.5.5 Vahvistusoppiminen

Tekoälyn kouluttamisessa voidaan käyttää myös vahvistusoppimista, englanniksi reinforcement learning, joka perustuu koneen jatkuvaan oppimiseen. Vahvistusoppimisessa lähtötilanne on sama kuin ohjaamattomassa oppimisessä eli mallille esitetään merkittömää dataa. (Massaron & Mueller 2018, 134). Malli saa toiminnastaan koko ajan palautetta: pisteitä toivotuista päätöksistä ja miinuspisteitä ei-toivotuista. Algoritmi on suunniteltu siten, että se haluaa aina kerätä mahdollisimman paljon pisteitä. Näin malli oppii tekemään siltä toivottuja päätöksiä ja välttämään ei-toivottuja päätöksiä. (Kananen & Puolitaival 2019, 158.)

Vahvistusoppimisen etuna on se, ettei siihen tarvita paljoa dataa koneen oppiessa toimintansa myötä. Vahvistusoppimisella onkin saatu viime vuosina hyviä tuloksia. Sen

käytännön hyödyntäminen on kuitenkin vaikeaa, sillä yleensä algoritmit tarvitsevat muuttumattomat olosuhteet oppiakseen kunnolla vahvistusoppimisen kautta. Lisäksi vahvistusoppimisen käytännön toteutusta vaikeuttaa pitkä oppimiskierto eli se, että todellisudessa voi kestää kauan aikaa ennen kuin algoritmi saa oppimiseen tarvitsemansa palautteen toiminnastaan. (Kananen & Puolitaival 2019, 159.)

### 2.5.6 Neuroverkon oppiminen

Syväoppivia neuroverkkoja voidaan kouluttaa kuten muitakin koneoppivia algoritmeja ohjatun, ohjaamattoman tai vahvistusoppimisen keinoin. John D. Kelleherin mukaan yleisin koulutusmuoto on kuitenkin ohjattu oppiminen. (Kelleher 2019, 35–36.)

Neuroverkon kouluttaminen alkaa asettamalla neuroneille parametrit eli painot. Alussa nämä painot täytyy käytännössä arvata, joten tässä vaiheessa malli toimii todennäköisesti todella huonosti. Ohjattua oppimista käytettäessä mallille syötetään arvot, joiden oikea ulostuloarvo tunnetaan ennalta. Mallin tuottama virhe voidaan laskea vertaamalla sen antamaa ulostuloarvoa oikeaan ulostuloarvoon. (Kelleher 2019, 51-53.) Mallin virhettä kutsutaan sen kustannusfunktioksi, ja neuroverkon kouluttamisen tavoitteena on kustannusfunktion minimoiminen (Kananen & Puolitaival 2019, 136-137). Jos mallin ulostulo on liian suuri, sitä yksinkertaistetusti pienennetään vähentämällä positiivisen arvon antaneiden neuronien painoa ja nostamalla negatiivisen arvon antaneiden neuronien painoa. Päinvastoin jos mallin ulostulo on liian pieni, sitä nostetaan lisäämällä positiivisen arvon antaneiden neuronien painoa ja laskemalla negatiivisen arvon antaneiden neuronien painoa. (Kelleher 2019, 53–54.)

Neuroverkon oikeiden painojen löytäminen on usein vaikeaa. Oikeita painoja etsitään yleensä iteroimalla eli kokeilemalla mallia useita kertoja ja sovittamalla joka kerran jälkeen sen painoja oikeaan suuntaan. (Kelleher 2019, 166.) Apuna käytetään gradienttialgoritmia, joka löytää funktion, jolla mallin kustannusfunktio on pienin. Lisäksi käytetään vastavirta-algoritmia, jonka avulla lasketaan miten yksittäisten neuronien parametrien muutokset vaikuttavat kustannusfunktioon. (Nielsen 2015).

## 2.6 Data

Heidi Kananen ja Harri Puolitaival määrittelevät datan olevan yksinkertaisesti havaintoja maailmasta. Data on tiedon perusyksikkö, joka voi olla mitä tahansa havaintoja mistä

tahansa ja missä tahansa muodossa, kuten numeroita, tekstiä, kuvia tai videoita. Kananen ja Puolitaipaleen mukaan data itsessään ei kerro käsiteltävästä aiheesta mitään, vaan sen tulkintaan ja hyödyntämiseen tarvitaan asiantuntemusta. (Kananen & Puolitaival 2019, 34, 71.)

Data jaetaan yleisesti rakenteelliseen ja ei-rakenteelliseen dataan. Rakenteellista dataa ovat esimerkiksi taloudellinen informaatio ja puhelinnumerot, jotka ovat järjestyksessä ja joiden muuttujat on ennalta määritetty. Ei-rakenteellista dataa ovat esimerkiksi teksti, kuvat ja videot, joiden rakennetta ei ole määritetty. (Taulli 2019, 21–22.)

### 2.6.1 Data tekoälyn perustana

Data on keskeisessä osassa toimivassa tekoälyssä, sillä sitä tarvitaan sekä koneen kouluttamiseen että varsinaiseen toimintaan. Tekoäly pystyy käyttämään mitä tahansa mitattavissa olevaa dataa, mutta sen on oltava koherenttia ja yhteismitallista. Data täytyy myös muuttaa koneen luettavaan muotoon, eli analoginen data täytyy muuttaa digitaaliseksi. Datan täytyy olla myös itsessään laadukasta: jos se sisältää ennakoasenteita tai syrjiviä vinoumia, myös koulutettava kone oppii sellaiseksi (Kananen & Puolitaival 2019, 79, 111.) Yleensä dataa täytyy valmistella ennen sen käyttämistä tekoälyn toiminnassa. Tähän kuuluu esimerkiksi kaksoiskappaleiden ja tarpeettoman datan karsiminen sekä datan laadukkuuden arviointi. Dataa käsiteltäessä on myös aina huomioitava tietoturvariskit. (Taulli 2019, 32–35.)

Tekoälyn koulutuksessa tarvitaan jokin vertailukohde, johon saatuja tuloksia verrataan. Vertailukohteesta puhutaan yleisesti referenssinä tai termillä golden dataset. Golden dataset on mahdollisimman totuudenmukaista ja vakiintunutta dataa käsiteltävästä aiheesta. Muuttumattomia referenssejä ovat esimerkiksi gravitaatio ja valonnopeus. Luonnonlakeja lukuun ottamatta golden datasetit voivat kuitenkin muuttua tieteen ja teknologian kehittyessä tai esimerkiksi painotusten ja lakien muuttuessa. Vertailukohtana toimivat referenssit vaihtelevat toimialoittain. Joskus tekoälyn koulutukseen on kehitettävä itse uusi golden dataset, esimerkiksi kun käsiteltävä kohde on yksilöllinen tai uusi. (Kananen & Puolitaival 2019, 90–93.)

## 2.6.2 Ominaisuudet

Tekoälysovellusta kehitettäessä on keskeistä tunnistaa käsiteltävään kohteeseen vaikuttavat ominaisuudet, joista usein käytetään englanninkielistä termiä feature. Ominaisuudet ovat muuttujia, joita tarkkailemalla saadaan informaatiota käsiteltävän ilmiön käyttäytymisestä. (Kananen & Puolitaival 2019, 95–97.)

Heidi Kanasen ja Harri Puolitaipaleen mukaan olennaisten ominaisuuksien tunnistaminen onnistuu parhaiten, kun teknisestä kehityksestä vastaava henkilö ja kohdetoimialan asiantuntija tekevät asiassa yhteistyötä. Myös toimialan asiantuntijan pitäisi ymmärtää tekoälyn toimintaperiaatteet. Tätä ominaisuuksien tunnistamiseen ja nimeämiseen tähtäävää prosessia kutsutaan termillä feature engineering. (Kananen & Puolitaival 2019, 95–97.)

## 2.6.3 Mallin monimutkaisuus

Tekoälymalli voi olla liian yksinkertainen tai monimutkainen käyttötarkoitukseen, mikä aiheuttaa epätarkkoja tuloksia. Liian yksinkertaisen mallin toiminnasta käytetään termiä alisovittaminen. Tällöin mallin tuloksissa on suuri harha eli bias (Kananen & Puolitaival 2019, 100.) Mallin harha tarkoittaa sen tulosten virhettä reaali maailmaan verrattuna (Smith 2018). Alisovittavassa algoritmossa on liian vähän ominaisuuksia, minkä vuoksi se antaa vain karkeita tuloksia eikä pysty kuvaamaan ilmiön yksityiskohtia. Tämä aiheuttaa mallin tuloksiin vinouman. Alisovittaminen voidaan korjata lisäämällä mallin ominaisuuksia. (Kananen & Puolitaival 2019, 100–101.)

Liian monimutkaisessa mallissa puolestaan sanotaan olevan liian iso varianssi (Kananen & Puolitaival 2019, 100). Mallin varianssi kertoo siitä, kuinka herkästi mallin tuottama harha reagoi muutoksiin syötedatassa (Smith 2018). Tällaisen algoritmin toimintaa kutsutaan ylisovittamiseksi. Ylisovittava malli toimii hyvin koulutusdatalla, mutta huonosti uudella datalla. Malli ikään kuin oppii ulkoa kaikki koulutusdatan datapisteet yksittäisinä tapauksina eikä pysty tekemään niistä yleistyksiä käsitelläkseen uutta dataa. Ylisovittamisen aiheuttaa se, että algoritmille on määritelty liikaa ominaisuuksia. Se voidaan korjata antamalla mallille lisää koulutusdataa tai yksinkertaistamalla mallia vähentämällä sen ominaisuuksia. (Kananen & Puolitaival 2019, 100–101.) Pohjimmiltaan yli- ja alisovittamisen aiheuttaa tekoälymallin induktiivinen vinouma, joka aiheutuu mallin virheellisistä päätelmistä koulutusvaiheessa (Kelleher 2019, 25).

Tekoälymallin monimutkaisuuden vaihtelusta käytetään yleisesti nimitystä bias–varianssi trade off. Optimaalinen malli ei yli- eikä alisovita, vaan pystyy erottelemaan ryhmät kohtuullisen tarkasti useimmilla dataseteillä. Malli toimii hyvin, kun se antaa oikeita tuloksia myös datalla, jota sille ei ole annettu koulutusvaiheessa. Bias–varianssi trade off on huomioitava jo ominaisuuksien valinnassa, sillä epätarkkuus aiheutuu juuri ominaisuuksien määrästä. Nyrkkisääntönä on kuitenkin pitää malli aina mahdollisimman yksinkertaisena, kunhan valitut ominaisuudet riittävät selittämään käsiteltävän ilmiön. Yksinkertainen malli on helpompi tulkita, ja se yleistää paremmin kuin monimutkainen malli. (Kananen & Puolitaival 2019, 100–102.)

Yksi ominaisuus luo tekoälymalliin aina uuden ulottuvuuden eli dimension, mikä kasvattaa riskiä siihen, että mukana on päällekkäisiä, epäolennaisia ja harhaanjohtavia ominaisuuksia. Tilannetta jossa mallissa on liikaa ominaisuuksia kutsutaan ulottuvuuksien kiroukseksi. Silloin malli käsittelee jokaisen datapisteen yksityistapauksena eikä pysty yleistämään. (Kananen & Puolitaival 2019, 100–102.)

## 2.7 Suorituskyvyn määrittely

Tekoälyn suorituskyvyn määrittely on tärkeä osa mallin koulutusvaiheen testaamista. Mallin suorituskyky kuvaa sen tarkkuutta, ja tähän vaikuttavat sen kouluttamiseen käytetty data ja mallin toimintaan käytetyn datan laatu. Numeerisia vastauksia antavan regressiomallin suorituskyvyn määrittelemisen on melko yksinkertaista, ja mallin virhe ja tarkkuus voidaan laskea käyttämällä tiettyjä matemaattisia kaavoja. Luokittelua tekevän tekoälymallin suorituskyvyn määrittely on kuitenkin monimutkaisempaa. (Joshi 2020, 169–171.) Luokittelumallin toimintaa kuvataan käsitteillä true positive, true negative, false positive ja false negative. True positive ja true negative tarkoittavat tilanteita, joissa malli on tehnyt oikean päätöksen joko tunnistaessaan tai hylätessään kohteen. False positive ja false negative puolestaan tarkoittavat tilanteita, joissa malli on tehnyt väärän päätöksen. (Kananen & Puolitaival 2019, 172–174). Käsitteet on havainnollistettu kuviossa 7.

	Tunnistettava	Hylättävä
Tunnistettu	<b>True positive</b>	<b>False positive</b>
Hylätty	<b>False negative</b>	<b>True negative</b>

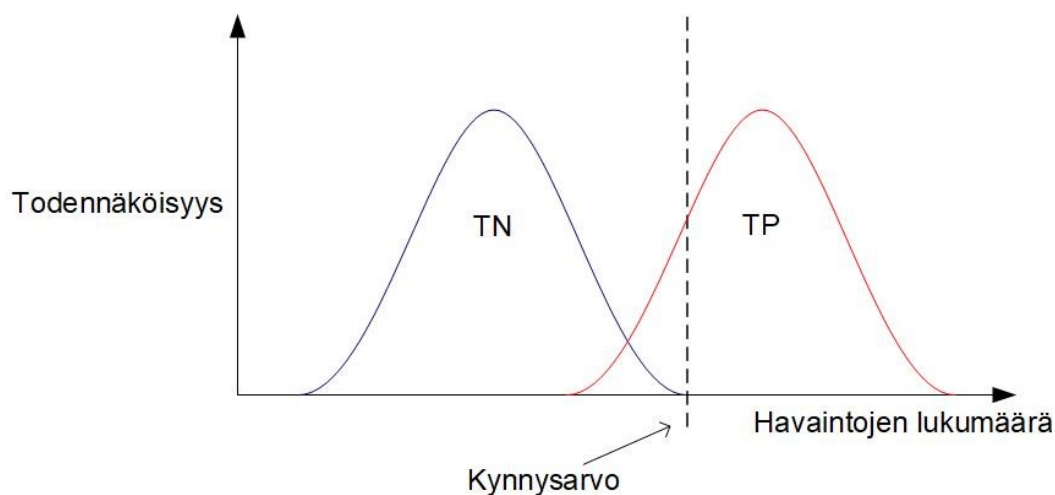
Kuvio 7. Luokittelumallin toimintaa kuvaavat käsitteet (Kananen & Puolitaival 2019, 175).

Luokittelumallin tarkkuutta kuvataan kahdella englannin-kielisellä termillä: precision ja recall. Molemmat termit tarkoittavat suomeksi tarkkuutta, mutta englanniksi niiden merkitykset eroavat toisistaan. Mallin precision kertoo siitä, kuinka suuri osa mallin tunnistamista positiivisista oli todella oikein. Recall puolestaan kertoo siitä, miten suuri osa todellisista positiivisista tunnistettiin. Hyvin toimivassa luokittelijamallissa precision ja recall ovat molemmat kunnossa. (Kananen & Puolitaival 2019, 176).

Suorituskyvyn mitoittamisen tarkoituksena on minimoida mallin tuottamat false negative ja false positive -tulokset. Ennen kaikkea halutaan välttää false negative -tulokset, jotka käytännössä tarkoittavat tilannetta, jossa malli ei tunnista kohdetta eli ei toimi. False positive -tulokset ovat niin sanottuja vääriä hälytyksiä, joiden seuraukset eivät ole yleensä vakavia, mutta jotka aiheuttavat enemmän työtä. False negative ja false positive -tulosten määrät ovat sidoksissa toisiinsa, eli false negative -arvon pienentäminen aiheuttaa false positive -arvon kasvun ja päinvastoin. Päätös arvojen toivottavasta suhteesta on aina tehtävä tapauskohtaisesti. (Kananen & Puolitaival 2019, 178.)

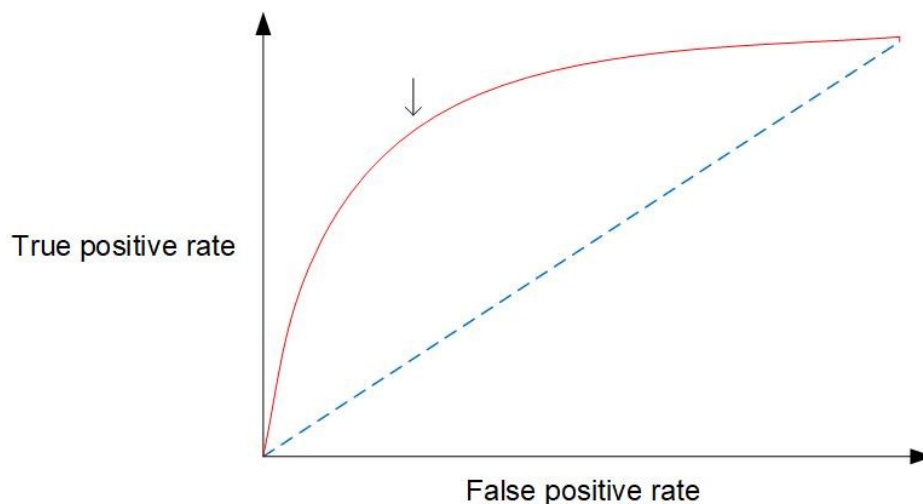
Kuviossa 8 on esitetty kuvitteellisen mallin negatiivisten ja positiivisten tulosten jakaumat koordinaatistossa. Luokittelijan kynnsarvoa muuttamalla voidaan vaikuttaa siihen, miten paljon false negative ja false positive -tuloksia saadaan. Kuvion kynnsarvolla vältettäisiin kokonaan false positive -tulokset, koska negatiivisten tulosten jakauma on kokonaan kynnsarvon alapuolella. Toisaalta, kuten kuviosta havaitaan, suuri osa positiivisten jakaumasta jää myös kynnsarvon alapuolelle, mikä aiheuttaisi paljon false negative -tuloksia. Ihannetilanteessa sininen true negative -jakauma olisi kokonaan kynnsarvon

alapuolella ja punainen true positive -jakauma kynnsarvon yläpuolella. (Pietikäinen & Silvén 2019, 101.) True negative -jakauman sijaintiin x-akselilla vaikuttaa mallin precision ja recall vaikuttaa true positive -jakauman sijaintiin. Siis mallin tarkkuutta muuttamalla voidaan muuttaa jakaumien sijaintia koordinaatistossa suhteessa toisiinsa, jolloin kynnsarvo voidaan asettaa sopivalle tasolle. (Kananen & Puolitaival 2019, 179.)



Kuvio 8. Kuvitteellisen luokittelumallin tulokset koordinaatistossa esitettynä (Kananen & Puolitaival 2019, 179).

True positive ja true negative -tulosten suhde toisiinsa voidaan esittää koordinaatistossa kuten kuviossa 9. Kuviossa kaksiluokkaisen luokittelijan kynnsarvon muutoksen vaikutuksia kuvataan ROC-kuvaajalla. Kuviossa punainen ROC-kuvaaja kertoo true positive -tulosten osuudesta, ja katkoviiva näyttää false positive -tulosten osuuden kasvun tavoitellessa korkeampaa true positive -määrää. Nuoli kuviossa osoittaa kohtaan, jossa osuuksien suhde olisi suurin piirtein optimaalinen eli johon kynnsarvo kannattaisi asettaa. ROC-kuvaaja muodostetaan true positive -tulosten osuuden, TPR, ja false positive -tulosten osuuden, FPR, funktiona. Toisin sanoen ROC-kuvaaja kertoo siis, miten monta väärää positiivista tulosta asetetulla kynnsarvolla saadaan todellista positiivista kohden. Kuvaajan alapuolelle jäävää alaa kutsutaan termillä area under curve eli AUC. Mitä suuremman osuuden koordinaatistosta AUC kattaa, sitä tarkemmin malli toimii. (Kananen & Puolitaival 2019, 178–181; Pietikäinen & Silvén 2019, 101.)



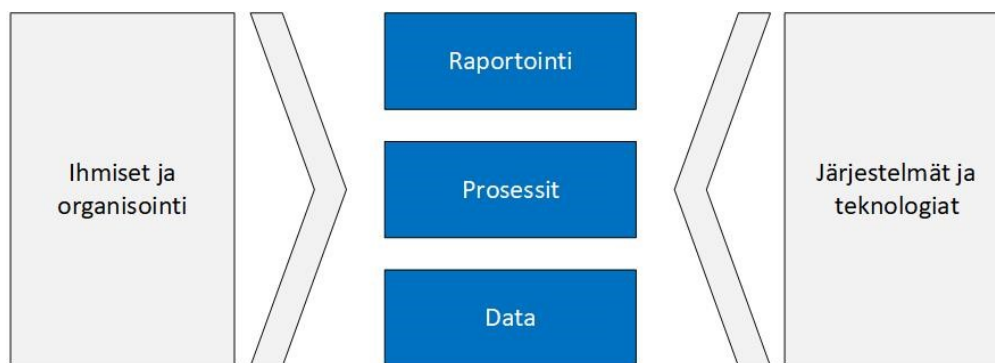
Kuvio 9. Kuvitteellisen luokittelijamallin tulosten ROC-kuvaaja (Kananen & Puolitaival 2019, 181).

### 3 Taloushallinto

#### 3.1 Taloushallinto yleisesti

Taloushallinto on usein laskentatoimen kirjallisuudessa käytetty termi, mutta vain harvoin sitä määritellään tarkasti (Lahti & Salminen 2014, 15). Sanna Kaarlejärven ja Tero Salmisen määritelmän mukaan taloushallinto on toiminto, jolla organisaation toiminta muunnetaan taloudelliseen muotoon ja raportoidaan sen tuloksista. Heidän määritelmänsä mukaan taloushallinto koostuu datasta, sitä käsittelevistä prosesseista, ihmisistä ja tietojärjestelmistä, ja sen tuloksena syntyy dokumentteja, rahavirtoja ja raportointia. (Kaarlejärvi & Salminen 2018, 93.) Tämä rakenne on esitetty kuviossa 10. Eeva Niskavaaran mukaan taloushallinto on yrityksen johtamisen tukitoiminto, jonka tehtävänä on tuottaa johtamista auttavia ja taloutta kuvaavia raportteja ja tunnuslukuja, osallistua yrityksen talouden johtamiseen ja valvontaan sekä konsultoida esimiehiä taloushallinnon näkökulmasta (Niskavaara 2017, 34). Laskentatoimen voidaan puolestaan määritellä olevan taloushallintoon kuuluva prosessi ja järjestelmä, jossa kerätään, mitataan ja tuotetaan taloudellista informaatiota yrityksen toiminnan ja päätöksenteon tueksi (Järvenpää ym. 2017, 19).





Kuvio 10. Taloushallinnon osa-alueet ja resurssit (Kaarlejärvi & Salminen 2018, 20).

Taloushallinnon raportoinnin sidosryhmien perusteella se voidaan jakaa ulkoiseen ja sisäiseen laskentatoimeen. Ulkoinen, tai rahoittajien, laskentatoimi tuottaa informaatiota yrityksen ulkopuolisille sidosryhmille, kuten viranomaisille ja omistajille. Sisäinen, tai johdon, laskentatoimi tuottaa puolestaan informaatiota yrityksen johdon päätöksenteon tueksi. (Järvenpää ym. 2017, 19-21.) Taloushallinto itsessään on laskentatoimea laajempi kokonaisuus, ja nykyaikaisessa taloushallinnossa ulkoinen ja sisäinen laskentatoimi ovat integroituneet toisiinsa. Strategisella tasolla taloushallinto voidaan nähdä liiketoimintoprosessina tai yrityksen tukiprosessina. Yksinkertaisinta sitä on kuitenkin käsitellä sen osa-alueiden ja prosessien kautta. (Lahti & Salminen 2014, 16.)

### 3.2 Digitaalinen taloushallinto

Ennen syvempää perehtymistä taloushallinnon prosesseihin on kuitenkin erotettava toisistaan digitaalinen taloushallinto ja niin sanotusti perinteinen taloushallinto. Digitaalisuus tarkoittaa sähköisessä muodossa olevan tiedon käsittelyä, siirtämistä, varastointia ja esittämistä. Digitaalinen tieto kulkee tietoverkoissa langattomasti tai langallisesti, ja sitä käsitellään tai siirretään ohjelmistoilla, jotka on myös ohjelmoitu sähköiseen muotoon. (Lahti & Salminen 2014, 19.) Digitaalisessa taloushallinnossa kaikki tietovirrat ja käsittelyvaiheet on automatisoitu ja käsitellään digitaalisessa muodossa. Kaikki kirjanpidon ja sen osaprosessien tapahtumat käsitellään sähköisesti, ja ne ovat mahdollisimman automatisoituja. Lisäksi taloushallinnon tositteet ovat konekielisiä, arkistoidaan sähköisesti ja niitä voidaan myös tarkastella sähköisesti. (Kaarlejärvi & Salminen 2018, 14–15.)

Perinteisellä taloushallinnolla viitataan tässä taloushallintoon, joka ei toimi digitaalisesti. Ei-digitaalisessa taloushallinnossa tositteita saatetaan käsitellä ja arkistoida edelleen pa-

perisina, mutta pelkkä paperittomuuskaan ei tee taloushallinnosta automaattisesti digitaalista. Kaarlejärvi ja Salminen kuvaavat sähköisen taloushallinnon digitaalisen taloushallinnon esiasteena. Sähköisessä taloushallinnossa esimerkiksi toimittajan lähettämät paperilaskut skannataan sähköiseen esitysmuotoon. Tämä ei kuitenkaan tee ostolas-kusta digitaalista, vaan sähköisen ja digitaalisen taloushallinnon keskeisenä erona on organisaatioiden ja järjestelmien välisten tietovirtojen digitalisointi. (Kaarlejärvi & Salminen 2018, 15–16.)

Digitaalisen taloushallinnon hyötyjä ovat sen nopeus ja tehokkuus verrattuna perinteiseen taloushallintoon. Siirtyminen digitaaliseen taloushallintoon on tuonut yrityksille huomattavia kustannussäästöjä, kun henkilötyötä on voitu vähentää ja tositteiden arkistoinnista on aiheutunut vähemmän kuluja. Digitaalisuus myös parantaa taloushallinnon työn laatua, lisää läpinäkyvyyttä ja vähentää virheitä. Taloushallinnon työ on aiempaa joustavampaa, kun sähköisiä tositteita voidaan tarkastella päätelaitteelta ajasta ja sijainnista riippumatta. (Lahti & Salminen 2014, 32.) Tässä työssä keskitytään ainoastaan digitaaliseen taloushallintoon, sillä tekoälyä ei voida hyödyntää ilman digitaalista dataa (Kananen & Puolitaival 2019, 79).

### 3.3 Taloushallinnon automaatio

Taloushallinnon prosesseja kehittämällä voidaan lisätä työn tehokkuutta, nopeuttaa tapahtumien läpimenoaikoja ja parantaa työtuloksen laatua. Prosesseja tehostetaan suunnittelemalla, yhtenäistämällä ja virtaviivaistamalla niitä, ja tarpeettomat tai päällekkäiset prosessit karsitaan kokonaan pois. Lisäksi manuaalista työtä voidaan vähentää automatisoimalla joitain työvaiheita. (Kaarlejärvi & Salminen 2018, 168–169.) Antero Elosen ja Tiina Torniaisen mukaan tehokkaat talousprosessit takaavat sen, että rutiinitehtävät suoritetaan laadukkaasti, ja niihin käytetään mahdollisimman vähän aikaa. Lisäksi prosessien tehostamisella voidaan vapauttaa asiantuntijoiden aikaa enemmän arvoa tuottaviin tehtäviin. (Elonen & Torniainen.)

Kaarlejärven ja Salmisen mukaan taloushallinnon prosessien tehostamisessa aloitetaan yleensä osto- ja myyntilaskuprosesseista, sillä näissä on eniten tapahtumia, ja ne ovat siksi kokonaistehokkuuden kannalta merkittävimpiä. Tämä saattaa johtaa myös siihen, että jotkin vähemmän merkittävät prosessit jäävät huomioimatta, mikä puolestaan ei ole toivottavaa. (Kaarlejärvi & Salminen 2018, 113.)

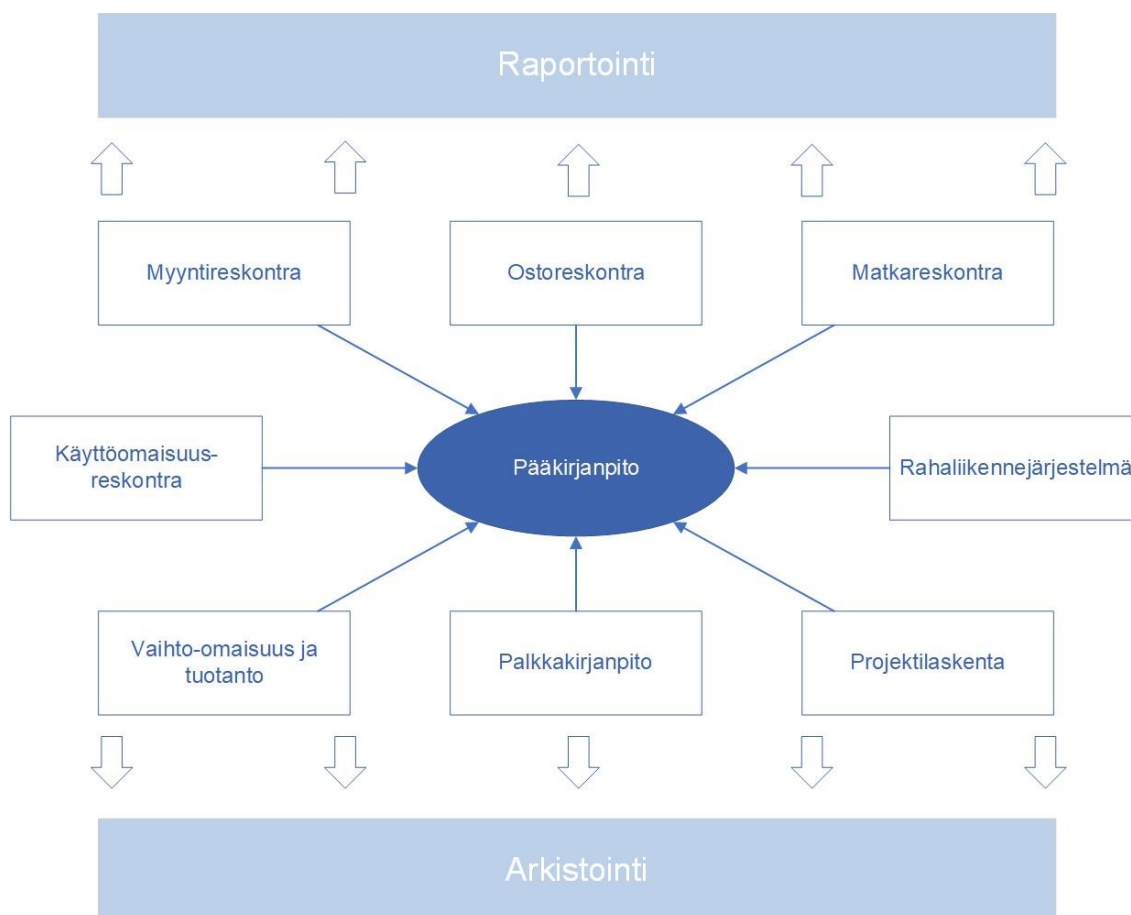
Ennen prosessien automatisointia on huolehdittava, että taloushallinnon prosessit ovat muuten laadukkaat ja tehokkaat. Automaatiota on turha tehdä prosesseihin, jotka voisi karsia pois. Automatisoinnissa voidaan hyödyntää käytössä olevien järjestelmien valmiita ominaisuuksia, ohjelmistorobotiikkaa tai tekoälyä. Käytettävän työkalun valinta tehdään tapauskohtaisesti, ja siinä on huomioitava automatisoitavan prosessin luonne, työhön kuluva aika, kustannukset ja käytettävissä olevat kehitysresurssit. (Kaarlejärvi & Salminen 2018, 182.)

Automaatiolla tavoitellaan manuaalisen työn vähenemistä, mikä vapauttaa työntekijöille lisää aikaa muihin tehtäviin. Tämä parantaa työtyytyväisyyttä ja lisää työn tuottavuutta. Automaatiikka myös työskentelee jatkuvasti, joten sillä voidaan saavuttaa huomattavia kustannussäästöjä. Lisäksi automaatio suorittaa tehtävänsä ihmistä tasalaatuisemmin ja nopeammin, mikä voi parantaa työn laatua. (Kaarlejärvi & Salminen 2018, 182–183.) Toivottu kustannustehokkuus edistää taloushallinnon automaation yleistymistä. Automaation lisääntyminen taloushallinnossa muuttaa myös asiantuntijoiden työnkuvaa ja osaamisvaatimuksia. (Pervilä 2020.)

### 3.4 Taloushallinnon prosessit

Taloushallintoon kuuluvat pääkirjanpito, sen esiprosessit ja raportointi. Pääkirjanpito prosessin esiprosesseja ovat ostolaskuprosessi, myyntilaskuprosessi, matka- ja kululaskuprosessi, maksuliikenne ja käyttöomaisuuskirjanpito. Pääkirjanpito kokooa tapahtumia muista prosesseista, täsmäyttää niitä ja tuottaa raportointia. (Kaarlejärvi & Salminen 2018, 93–95.) Kirjanpidon päätarkoitus on yrityksen tuloksen esittäminen selvittämällä, mitä tuottoa ja kuluja yrityksen toiminnasta syntyy. Se toimii myös yrityksen verotuksen perusteena. (Eklund & Hakonen & Roos 2017, 12–13.) Suomessa kirjanpitovelvollisia ovat kirjanpitolain nojalla kaikki oikeushenkilöt ja liike- tai ammattitoimintaa harjoittavat luonnolliset henkilöt (Kirjanpitolaki 1997, 1 luku 1 §; 1 luku 1 §a).

Taloushallinnon prosessit on esitetty kuviossa 11. Myös palkkahallinto on merkittävä osa yritysten hallintoa, ja se voidaan organisoida osaksi taloushallintoa. Suurissa organisaatioissa palkkahallinto on kuitenkin usein rinnakkainen toiminto taloushallinnolle ja organisoitu osaksi henkilöstöhallintoa. Organisaatiomallista riippumatta palkkahallinto on aina merkittävästi sidoksissa osaan taloushallinnon prosesseista, kuten pääkirjanpitoon, raportointiin ja maksuliikenteeseen. (Lahti & Salminen 2014, 135.)



Kuvio 11. Taloushallinnon prosessit (Kaarlejärvi & Salminen 2018, 95).

### 3.4.1 Ostolaskuprosessi

Taloushallinnon näkökulmasta ostolaskuprosessi alkaa siitä, kun vastaanotetaan toimittajalta ostolasku. Sanna Kaarlejärven ja Tero Salmisen mukaan digitaalisessa taloushallinnossa ostolaskuja vastaanotetaan verkkolaskuina tai vaihtoehtoisesti kuvamuotoisena sähköpostitse tai paperilaskulta skannattuna. (Kaarlejärvi & Salminen 2018, 96.) Toisaalta tilannetta, jossa laskut saapuvat paperisina tai kuvana sähköpostin välityksellä ei voida pitää täysin digitaalisena, sillä tällöin laskun mukana ei saada digitaalista laskudataa.

Vastaanotetun ostolaskun tiedot tarkistetaan, ja se joko tiliöidään taloushallinnossa ja laitetaan tarkastusprosessiin tilaajalle tai se täsmäytetään ostotilaukseen tai -sopimukseen. Tilaukseen tai sopimukseen täsmäytetty tai tarkastajan ja hyväksyjän hyväksymä

ostolasku kirjautuu ostoreskontraan ja kirjanpitoon. Viimeiseksi ostoreskontrasta muodostetaan maksuaineisto, joka lähetetään pankkiin, ja maksut kuitataan tiliotteen tai palautusaineiston perusteella. (Kaarlejärvi & Salminen 2018, 96–98.)

Ostolaskujen käsittely on taloushallinnon prosessi, joka usein vaatii eniten niin taloushallinnon kuin muun organisaation aikaa. Tämän vuoksi ostolaskuprosessissa automaatiolla voidaan saada kaikkein eniten hyötyä ja sen tehostaminen on kehittynyt viime vuosina. Ostolaskuprosessin automaation lähtökohtana on verkkolaskujen vastaanottaminen. Toimittajalta vastaanotetulta verkkolaskulta laskudata saadaan suoraan digitaalisessa muodossa järjestelmään, jolloin virheelliset tiedot vähenevät. Verkkolaskujen osuutta yleensä vähentävät pienet ja ulkomaalaiset toimittajat, joilla ei ole valmiutta verkkolaskutukseen. Manuaalinen laskun tiliöintiprosessi voidaan automatisoida luomalla järjestelmään toimittajakohtaisia oletustiliöintejä tai tiliöintisääntöjä. Oletustiliöinnistä järjestelmä tiliöi toimittajan laskut automaattisesti samalla tavalla; tiliöintisääntöjen avulla järjestelmä tiliöi laskut perustuen verkkolaskulta saatuun dataan. Tiliöintisääntöjen luonnissa voidaan hyödyntää myös koneoppimista. (Kaarlejärvi & Salminen 2018, 96–105.)

Verkkolaskutuksen yleistymistä vauhdittaa 1.4.2019 voimaan tullut laki hankintayksiköiden ja elinkeinonharjoittajien sähköisestä laskutuksesta, joka laajeni 1.4.2020 koskemaan kaikkia suomalaisia elinkeinonharjoittajia. Laki on osa Euroopan unionin verkkolaskudirektiiviä, ja sen mukaan elinkeinonharjoittajalla on oikeus vaatia toimittajalta lasku verkkolaskuna. Valtiokonttorin mukaan lain tarkoituksena on nopeuttaa siirtymistä automatisoituun taloushallintoon. (Valtiokonttori 2019.)

Ostoprosessia voidaan tehostaa myös ostotilausten avulla. Tällöin taloushallintojärjestelmään muodostetaan ostotilaus, joka myös lähetetään toimittajalle. Toimittaja toimittaa tavaran tai suorittaa palvelun ja lähettää siitä laskun, jolle on merkitty ostotilauksen tilausnumero. Tilauksen vastaanottaja merkitsee sen järjestelmään vastaanotetuksi. Viimeiseksi vastaanotettu lasku täsmäytetään vastaanotettuun tilaukseen, ja jos ne täsmäävät, lasku voidaan laittaa suoraan maksuun ilman hyväksymiskiertoa. Samoin prosessia voidaan nopeuttaa toistuvien laskujen kohdalla luomalla järjestelmään sopimusrekisteri ostosopimuksista. Sopimukseen kohdistuvalle laskulle saadaan tiliointi järjestelmästä, ja mikäli lasku täsmää sopimukseen, voidaan se laittaa maksuun ilman hyväksymiskiertoa. (Kaarlejärvi & Salminen 2018, 99–102.)

Ostolaskuprosessiin luetaan kuuluvaksi myös toimittajien perustietojen ylläpito. Toimittajarekisteriin tallennetaan tiedot esimerkiksi toimittajien nimistä, osoitteista, maksuehdoista ja maksuyhteyksistä. Laadukkaat ja ajantasaiset ohjaustiedot tehostavat digitaalista ostolaskuprosessia ja pienentävät virheiden riskiä. Myös perustietojen ylläpidossa voidaan hyödyntää automaatiota. (Lahti & Salminen 2014, 59–61.)

### 3.4.2 Myyntilaskutusprosessi

Organisaation myyntilaskutusprosessi voidaan jakaa kahteen pääosaan: laskutukseen ja myyntireskontraan. Laskutusprosessi alkaa myyntilaskun luomisesta. Lasku voidaan muodostaa joko järjestelmässä olevan asiakasdatan perusteella tai syöttämällä tiedot manuaalisesti. Valmis lasku lähetetään verkkolaskuoperaattorille, joka välittää sen vastaanottajalle. Laskutusjärjestelmä luo valmiista laskusta kirjaukset myyntireskontraan ja pääkirjanpitoon. Myyntireskontran tehtäviin puolestaan kuuluu laskutettujen saatavien seuranta, vastaanotettujen suoritusten kohdistus ja mahdolliset perintätoimenpiteet. (Kaarlejärvi & Salminen 2018, 120–131.)

Myyntilaskutusprosessia voidaan tehostaa automatisoimalla laskun muodostuminen järjestelmän datasta. Manuaalinen työ laskutuksessa vähenee, kun laskudata saadaan tuotua suoraan liiketoiminnan järjestelmistä, joihin se on myyntitapahtuman yhteydessä syötetty. Avointen laskujen seuranta myyntireskontrassa on myös helposti automatisoitavissa. Asiakkailta saadut maksut voidaan kohdistaa automaattisesti avoimiin saataviin maksuviitteiden perusteella. Jos maksuviite puuttuu tai on virheellinen, voidaan maksu usein silti kohdistaa automaattisesti esimerkiksi laskunumeron tai summan perusteella. Verkkolaskutus helpottaa automatisointia myös myyntireskontrassa, kun asiakkaan manuaalisen työn väheneminen vähentää inhimillisiä virheitä. Myös maksumuistutuksen muodostuminen ja lähetys erääntyneistä saatavista voidaan automatisoida. (Kaarlejärvi & Salminen 2018, 120–131.)

### 3.4.3 Matkalaskutusprosessi

Matka- ja kululaskutusprosessissa käsitellään työntekijöille työmatkoista tai työnantajan puolesta tehdyistä pienhankinnoista aiheutuneita kuluja (Kaarlejärvi & Salminen 2018, 111). Työmatkoista syntyviä kuluja ovat esimerkiksi kilometrikorvaukset ja päiväraha. Nämä korvaukset ovat verottomia, eli työnantaja ei tee niistä ennakonpidätystä, elleivät

ne ylitä verohallinnon vuosittain asettamia rajoja verottomuudelle. Matkakulujen tositteeksi tarvitaan kuitti maksutapahtumasta. (Eklund & Hakonen & Roos 2017, 198.)

Matka- tai kululaskuprosessi alkaa, kun kulukorvaukseen oikeutettu työntekijä skannaa kuitin maksutapahtumasta ja liittää sen matkalaskulle. Matkalasku tiliöidään, tarkastetaan ja hyväksytään. Hyväksytyistä matkalaskuista luodaan maksuaineisto, ja lähetetään maksu pankkiin. Lopuksi suoritettu korvaus kirjataan pääkirjanpitoon. (Kaarlejärvi & Salminen 2018, 111–112.)

Matka- ja kululaskuprosessia voidaan tehostaa selkeyttämällä ja yhtenäistämällä sitä. Manuaaliset työvaiheet, kuten laskun tiliöinti, voidaan automatisoida ja kuitit kuvata älypuhelimella. Lisäksi on huolehdittava automaattisesta tietojen siirtymisestä ja päivittymisestä erillisten järjestelmien kesken. (Kaarlejärvi & Salminen 2018, 115–120.)

#### 3.4.4 Maksuliikenne

Taloushallinnossa maksuliikenne tarkoittaa maksutapahtumien välitystä pankkien ja organisaation taloushallintojärjestelmien välillä ja niiden käsittelyä järjestelmissä. Lähtevät maksut muodostetaan organisaation taloushallintojärjestelmissä ja lähetetään pankkiin, joka tekee maksuerän mukaiset veloitukset organisaation pankkitililtä. Saapuvat maksut pankki puolestaan kokoaa päivittäin yhteen ja lähettää niiden tiedot tiliotteilla ja viitemaksutiedostoina organisaatiolle. (Kaarlejärvi & Salminen 2018, 132.)

Uloslähtevää maksuliikennettä voidaan tehostaa automatisoimalla maksuerien muodostuminen osto- ja matkalaskujen pohjalta. Automaatio voidaan ajastaa tapahtumaan tietynä ajankohtana. (Kaarlejärvi & Salminen 2018, 134–136.)

#### 3.4.5 Käyttöomaisuuskirjanpito

Käyttöomaisuuskirjanpidolla tarkoitetaan käyttöomaisuusrekisterin ylläpitoa. Rekisteriin on kirjattu yrityksen pitkäaikaiset investoinnit, jotka on aktivoitu sen taseeseen käyttöomaisuudeksi. Käyttöomaisuuskirjanpidon prosessiin kuuluu uusien hankintojen perustaminen rekisteriin, käyttöomaisuuden poistojen laskenta ja kirjaukset sekä sen myynti- tai romutustapahtumien käsittely ja kirjaukset. (Kaarlejärvi & Salminen 2018, 140.)

Käyttöomaisuuskirjanpitoa voidaan tehostaa automatisoimalla hankinnan tietojen tallentuminen ostolaskulta suoraan käyttöomaisuusrekisteriin. Käyttöomaisuushankinta voidaan myös kirjata käyttöomaisuusrekisteriin jo tilausvaiheessa, jolloin hankintahinta ja ajankohta tallentuvat automaattisesti, kun tilaukselle tehdään vastaanotto järjestelmään. Myös käyttöomaisuuden poistoajat voidaan ajastaa tapahtumaan automaattisesti. Poistoaikojen seuraava käyttöomaisuusrekisterin täsmäytys pääkirjanpidon käyttöomaisuustileihin voidaan automatisoida esimerkiksi ohjelmistorobotiikan avulla. (Kaarlejärvi & Salminen 2018, 140–143.)

#### 3.4.6 Pääkirjanpito

Pääkirjanpitoon kuuluu kaikkien organisaation liiketapahtumien yhteen kokoaminen. Kirjanpidon kirjaukset muodostuvat pääkirjanpitoon tehtävistä tositteista, liiketoiminnan prosesseista muodostuvista kirjauksista ja osakirjanpitojen tapahtumista. Suoraan pääkirjanpitoon tehtäviä tositteita kutsutaan yleisesti muistiotositteiksi. Niillä voidaan kirjata esimerkiksi jaksotuksia, oikaisuja tai vyörytyksiä. Pääosa kirjanpidon kirjauksista saadaan kuitenkin liiketoimintaprosesseista tai osakirjanpidoista, kuten osto- ja myyntireskontrasta. (Kaarlejärvi & Salminen 2018, 143–145.)

Osakirjanpitojen tai reskontrien tapahtumien siirtyminen pääkirjanpitoon voidaan automatisoida järjestelmien valmiilla toiminnoilla, liittymätyökaluilla tai ohjelmistorobotiikan avulla. Osakirjanpidot ja pääkirjanpito on täsmäytettävä vähintään kerran kuussa, ja tämäkin voidaan ajastaa tapahtumaan automaattisesti. Myös manuaaliset muistiotositteet voidaan automatisoida usein eri tavoin. (Kaarlejärvi & Salminen 2018, 147–150.)

#### 3.5 Raportointi

Laskentatoimen tärkeänä tehtävänä on tuottaa informaatiota yrityksen toiminnasta sen sidosryhmille. Laskentatoimi kerää numeerista dataa yrityksen taloudellisista aktiviteeteista ja jalostaa siitä erilaisia raportteja. (Jormakka ym. 2015, 11.)

Taloushallinnon raportointi jaetaan tyypillisesti kahteen osaan: ulkoiseen ja sisäiseen raportointiin. Ulkoinen raportointi täyttää yrityksen lakivelvoitteiset raportointitarpeet, joihin sisältyvät tilinpäätösraportointi ja muu viranomaisraportointi. Sisäinen raportointi puolestaan vastaa yrityksen johdon informaatiosta. Sanna Kaarlejärvi ja Tero Salminen jakavat



sisäisen raportoinnin edelleen kolmeen osa-alueeseen: talous- ja tulosraportointiin, talousohjauksen raportointiin ja liiketoimintatiedon hallintaan ja analysointiin. (Kaarlejärvi & Salminen 2018, 187–188.)

### 3.5.1 Ulkoinen raportointi

Yrityksen ulkoisen raportoinnin tehtävän on vastata sen ulkopuolisten sidosryhmien tiedon tarpeeseen. Ulkoisia sidosryhmiä ovat esimerkiksi yrityksen omistajat, rahoittajat, tilintarkastajat, verohallinto ja muut viranomaiset. Yleisimmät ulkoiset raportit ovat tilinpäätösasiakirjat eli tuloslaskelma ja tase. Muita ulkoisia raportteja ovat esimerkiksi vuosisiveroilmoitus ja arvonalisäveroilmoitus. Lisäksi ulkoiseen raportointiin kuuluu mahdollinen konsernikonsolidointi. (Kaarlejärvi & Salminen 2018, 190–195.)

Yrityksen ulkoiset raportit perustuvat yleisimmin kirjanpidon tileihin. Ulkoiset raportit ovat niiden lakisääteisyydestä johtuen luonteeltaan kiinteitä eli staattisia. Tämä tarkoittaa sitä, että raporttien parametrit on vakioitu, ja vain esimerkiksi seurantataso tai raportointiajanjakso ovat muuttuvia. Lisäksi ulkoinen raportointi on luonteeltaan syklistä, eli raportteja tuotetaan tietyin aikaväleihin, kuten kuukausittain, kvartaaleittain tai vuosittain. (Kaarlejärvi & Salminen 2018, 192–193.) Ulkoisissa raporteissa ei yleensä myöskään esitetä tarkkaa informaatiota yrityksen eri laskentakohteista, vaan niissä yritystä käsitellään kokonaisuutena (Järvenpää ym. 2017, 21).

Ulkoinen raportointiprosessi alkaa siitä, kun yrityksen pääkirjanpito ja tilinpäätösluvut valmistuvat. Yrityksillä on lainmukainen velvoite ulkoiseen raportointiin vain kerran vuodessa, tilinpäätöksen jälkeen, mutta käytännössä suuri osa yrityksistä tekee kirjanpitoa kuukausittain melkein tilinpäätöksen tarkkuudella. Lisäksi pörssiyritykset ovat velvollisia raportoimaan osavuosituloksensa kvartaaleittain. (Kaarlejärvi & Salminen 2018, 194.)

### 3.5.2 Sisäinen raportointi

Sisäinen raportointi vastaa yrityksen talousohjauksen informaation tarpeeseen. Raportoinnin on oltava liiketoiminta- ja strategialähtöistä sekä vastattava liiketoimintojen tarpeeseen. Hyvä sisäinen raportointi on myös visuaalista ja nostaa esille trendejä ja poikkeamia. Raportoinnin lähteet eivät ole koottuna yhteen sijaintiin, vaan tietoja täytyy kerätä ja yhdistellä eri lähteistä. (Kaarlejärvi & Salminen 2018, 193; 197.)

Sisäinen raportointi poikkeaa luonteeltaan ulkoisesta raportoinnista. Sisäiset raportit ovat dynaamisia ja vapaamuotoisia, sillä niille ei ole lakisääteisiä vaatimuksia. Raportoinnin dynaamisuus tarkoittaa sitä, että raporttien parametrejä voidaan muokata vapaasti ja järjestelmästä voidaan muodostaa raportteja vapaasti. Tämä helpottaa tiedon analysointia. Lisäksi sisäisen raportoinnin erottaa ulkoisesta se, että raportointi on lähes reaaliaikaista. Digitalisaation myötä sisäisiä raportteja voidaan jakaa raporttiportaaleissa tai käyttäjät voivat itse ajaa tarvitsemiaan raportteja itsepalveluportaaleissa. (Kaarlejärvi & Salminen 2018, 190–193; 197.)

## 4 Tekoäly taloushallinnon automaatiassa

### 4.1 Tekoäly taloushallinnon apuna

Tekoälyyn perustuvien teknologioiden avulla voidaan entisestään nostaa automaation määrää taloushallinnossa (Kaarlejärvi & Salminen 2018, 52). Kuten edellisessä luvussa mainittiin, tekoäly vaatii toimimiseen digitaalista dataa, ja taloushallinnon kontekstissa tämä tarkoittaa siis digitaalista taloushallintoa. Tekoälyä voidaan hyödyntää erityisesti prosesseissa, joissa on paljon toistoa ja samankaltaisuutta. Prosessit voivat olla monimutkaisia ja monivaiheisia, mutta niistä täytyy olla tunnistettavissa toistuva kuvio. (Kananen & Puolitaival 2019, 79, 200.)

Heidi Kananen ja Harri Puolitaival listaavat kuusi edellytystä tekoällyn hyödyntämiselle liiketoiminnassa: liiketoiminnallinen tarve; datan määrä, sijainti ja laatu; tiimin osaaminen, innovointi, eettisyys ja sisäinen viestintä. Liiketoiminnallinen tarve tarkoittaa sitä, että kaiken kehitystyön pitäisi aina lähteä liiketoiminnan tarpeesta. Dataa puolestaan täytyy olla riittävästi, sen on oltava hyvälaatuista ja koossa hyödynnettävässä tietolähteessä. Tiimin jäsenillä on myös oltava riittävästi liiketoiminta- ja teknistä osaamista. Innovointi tarkoittaa sitä, että koko työyhteisössä pitäisi olla innokas oppiva ilmapiiri. Eettisyys puolestaan tarkoittaa sitä, että eettinen näkökulma ja tietosuoja on huomioitava jo projektin alusta. Sisäisellä viestinnällä tarkoitetaan sitä, että yrityksen kulttuuri, rakenne ja tekemisen läpinäkyvyys huomioidaan projektissa. (Kananen & Puolitaival 2019, 56–59.)

## 4.2 Käyttökohteet

Tekoälyn hyödyntämiseksi taloushallinnon automaatiossa on tunnistettava prosesseista ne työvaiheet, joissa siitä on hyötyä. Sanna Kaarlejärvi ja Tero Salminen kertovat tekoälyn yleisimmäksi käyttökohteeksi taloushallinnon automaatiossa ostolaskujen tiliöinnin ja käsittelyn. (Kaarlejärvi & Salminen 2018, 60–61.)

Ostolaskujen käsittelyssä koneoppimista voidaan hyödyntää esimerkiksi tiliöintisääntöjen luomiseen. Tämä toimii siten, että järjestelmä luo vastaanotetulle laskulle automaattisesti tiliöinnin, jonka se on koneoppimisen avulla päätellyt vanhoilta saman toimittajan laskuilta. Koneoppiminen ei kuitenkaan toimi, jos vanhoja laskuja on liian vähän tai laskujen tiliöinti on muuttunut. Tämän takia laskujen käsittelijän pitäisi aina tarkastaa tekoälyn luoma oletustiliöinti. (Kaarlejärvi & Salminen 2018, 105.)

Rajendra Akerkarin mukaan koneoppimista voidaan hyödyntää prosesseissa, jotka sisältävät toistuvan kuvion ja suuren määrän tapahtumia ja joissa mahdollisten virheiden kustannus on matala (Akerkar 2019, 71). Kaarlejärvi ja Salminen kuitenkin näkevät tällä hetkellä tekoälyn tehtävänä ennen kaikkea työntekijän auttamisen heidän hahmottelemassaan älykkäässä taloushallinnossa. Heidän näkemyksensä mukaan tekoälystä ei siis saada toistaiseksi suurinta hyötyä automaatiolla itsessään, vaan kun se helpottaa työntekijän suorittamia prosesseja kuten aiemmassa esimerkissä oletustiliöinnin luomisesta. (Kaarlejärvi & Salminen 2018, 22–23)

## 4.3 Datan käsittely

Digitaalisessa taloushallinnossa perusedellytykset tekoälyn käytölle ovat datan puolesta hyvät. Suomessa taloushallinnon datan sisältö ja formaatit ovat laajalti standardisoituja, mikä parantaa niiden käytettävyyttä. Tekoälyn käyttö myös luo lisää dataa, jota voidaan edelleen hyödyntää. Taloushallinnon tai koko yrityksen IT-järjestelmäarkkitehtuurin suunnittelussa onkin nykyään huomioitava datan hallinta, mikä mahdollistaa datan tehokkaan hyödyntämisen uusissa tekoälysovelluksissa. (Kaarlejärvi & Salminen 2018, 49.) Dataa tekoälylle voidaan saada oman datan lisäksi myös avoimista datakirjastoista tai kolmansien osapuolien maksullisista kirjastoista (Taulli 2019, 31–32).

Olennainen tekijä datan tehokkaan käytön kannalta on yrityksen master datan hallinta. Master data on liiketoiminnalle kriittistä tietoa, jota ilman yritys ei voi toimia ja joka on

jaettu ympäri organisaatiota siten, että kaikki organisaatiossa käyttävät samaa dataa. Taloushallinnon käyttämää master dataa ovat esimerkiksi toimittaja- ja asiakasrekisterit. Master datan hallinnan tarkoituksena on varmistaa datan tarkoituksenmukaisuus. (Väre 2019, 22–23; 37.)

#### 4.4 Tekoäly apuna raportoinnissa

Myös taloushallinnon raportoinnissa voidaan hyödyntää tekoälyyn perustuvia teknologioita. Tämä koskee erityisesti sisäistä raportointia, joka on dynaamista toisin kuin ulkoinen raportointi. Sisäisessä raportoinnissa koneoppimista voidaan käyttää esimerkiksi nostamaan datasta riippuvuussuhteita ja poikkeamia, luokittelemaan dataa tai tekemään siitä ennusteita. (Kaarlejärvi & Salminen 2018, 188–190.)

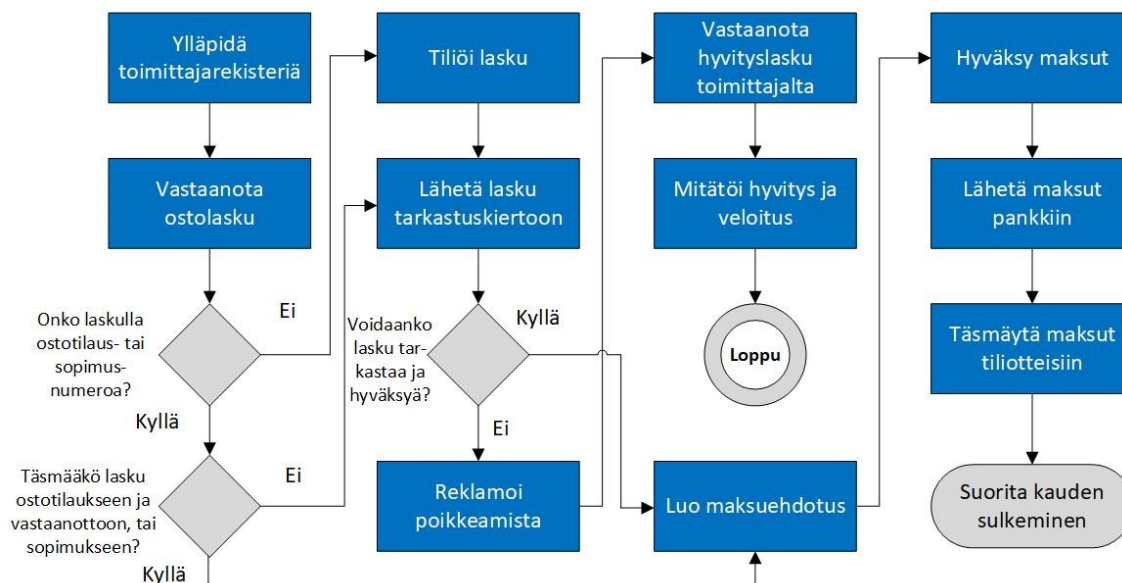
Tekoälyn avulla voidaan kehittää myös raporttien jakelua. Koneoppivat algoritmit voivat esimerkiksi luoda raportille sanallisen esittelyn ja antaa siihen pohjautuvia toimenpideehtotuksia. Lisäksi tekoälyn avulla voidaan kehittää puheohjausta raporttien tulkitsemiseen. (Kaarlejärvi & Salminen 2018, 190.)

#### 4.5 Kohdeyrityksen ostolaskuprosessi

Tämän luvun tarkoituksena on havainnollistaa tekoälyn käyttöä taloushallinnon automaatiassa esimerkkitapauksen avulla. Lukua varten on haastateltu toimeksiantajalla työskentelevää henkilöä, joka työskentelee yrityksessä asiantuntijana ja on ollut mukana tekoälyprojektissa.

Toimeksiantajayritys on ottanut käyttöön tekoälysovelluksen erään asiakasyrityksensä ostolaskuprosessissa. Sovelluksen tarkoituksena on lisätä automaatiota ja vähentää manuaalista työtä tiliöimällä laskut ja reitittämällä ne tarkastuskiertoon.

Kohdeyrityksen ostolaskuprosessi toimii tällä hetkellä pitkälti Sanna Kaarlejärven ja Tero Salmisen kuvailemalla tavalla, joka on esitetty myös kuviossa 12. Vastaanottaessaan ostolaskun järjestelmä tunnistaa sen datasta automaattisesti ostotilaus- tai sopimusnumeron. Laskut, joilta tällaista numeroa ei löydy, lähtevät täysin manuaaliseen käsittelyprosessiin. Tässä vaiheessa tekoälysovellus kuitenkin luo laskulle oletustiliöinnin, joka helpottaa laskun käsittelijän työtä.



Kuvio 12. Ostolaskuprosessi (Kaarlejärvi & Salminen 2018, 99).

Käytettävä tekoälysovellus on koulutettu laskudatalla, jota saadaan sähköisestä laskuarkistosta. Algoritmi ennustaa laskudatan perusteella tiliöintiin tiettyjä dimensioita, kuten kustannuspaikan, kirjanpidon tilin ja verokoodin. Sen tekemät ennusteet myös kehittyvät jatkuvasti, sillä algoritmi saa palautetta luomistaan oletustiliöinneistä. Toistaiseksi algoritmi ainoastaan luo oletustiliöinnin, jonka laskun käsittelijä hyväksyy. Algoritmin ennusteiden tarkentumisen myötä sen on tarkoitus tulevaisuudessa reitittää laskut suoraan tarkastajalle oletustiliöinnin luotuaan.

Tekoälyalgoritmin toiminnasta saadaan reaaliaikaista dataa, jota pystytään tarkastelemaan esimerkiksi dimensioittain tai toimittajittain. Datasta pystytään seuraamaan, kuinka suuren osuuden algoritmin luomista ennusteista laskun käsittelijä on hyväksynyt. Dataan porautamalla ja sitä visualisoimalla voidaan tunnistaa puutteita ja poikkeamia prosessissa.

## 5 Tekoälyn käyttöönotto taloushallinnossa

### 5.1 Valmistautuminen käyttöönottoon

Tekoälyprojekti alkaa siitä, kun yrityksessä tunnistetaan jokin kohde tai ongelma, jota voidaan tehostaa tai korjata tekoälyn avulla. Ennen kuin tekoälyä voidaan ottaa käyttöön, on käytettävä malli tietysti suunniteltava ja koodattava. Päätettävä on esimerkiksi, mitä algoritmia käytetään ja miten malli koulutetaan. Tekoälyn suorituskyky eli siltä vaadittava

tarkkuus on myös määriteltävä jo ennen mallin koodaamista (Kananen & Puolitaival 2019, 61–62).

Ennen tekoälyn käyttöönottoa on suunniteltava, miten paljon mallille ja sen kouluttamiseen tarvitaan dataa ja mistä lähteistä sitä saadaan. Käyttöönottoa varten on kerättävä hyvälaatuista dataa, joka saattaa tarvita valmistelua. Datasta täytyy myös tunnistaa mallissa huomioitavat ominaisuudet. (Taulli 2019, 32–34.) Ralf T. Kreutzer ja Marie Sirrenberg puhuvat oman dataekosysteemin luomisesta. Kun tekoälymallin tarve datalle on määritelty, voidaan nähdä, kuinka hyvin yrityksen omat lähteet riittävät täyttämään tämän tarpeen. Mikäli oma data ei riitä mallille, voidaan joutua luomaan dataekosysteemi yhdessä jonkin kolmannen osapuolen kanssa. (Kreutzer & Sirrenberg 2020, 245–246.)

Myös yrityksen datan hallinnan ja järjestelmäarkkitehtuurin pitää olla tehokkaan tekoälysovelluksen vaatimalla tasolla. Integroidussa digitaalisessa taloushallinnossa data liikkuu tehokkaasti eri järjestelmien välillä, mikä on edellytys prosessiautomaatiolle. Datallaan kanssa toimittaessa on aina huolehdittava myös tietoturvasta. (Kaarlejärvi & Salmi 2018, 42–44; 49–50.)

Yrityksissä tekoälyä testaan yleensä nopeilla kokeiluilla, joista käytetään myös nimitystä proof of concept eli PoC. Kokeilussa käydään läpi, mistä saadaan data mallille ja koulutetaan sen ensimmäinen versio. Tämän tarkoituksena on selvittää, toimiiko malli korjattavaan ongelmaan. Jos testattu malli tuottaa hyviä tuloksia, voidaan sitä lisäkouluttaa ja viedä se tuotantoon. (Kananen & Puolitaival 2019, 59–60.) Myös Sean Stein Smith kehottaa tekoälysovelluksen käyttöönottoa suunnittelevia yrityksiä pilotoimaan sovellusta ensin pienessä kaavassa. Tekoälyprojekti saattaa kohdata merkittäviä vaikeuksia käyttöönotossa, kuten yhteensopivuusongelmia, eikä mikään sovellus toimi täysin oikein vielä ensimmäisellä kerralla. Nämä ongelmat on helpompi korjata silloin, kun käyttöönottoa testataan ensin rajatun joukon järjestelmissä eikä koko yrityksen järjestelmissä yhtäaikaisesti. (Stein Smith 2020, 155.)

Prosessien näkökulmasta on ennen tekoälyn käyttöönottoa huolehdittava siitä, että prosessit ovat itsessään kunnossa. Taloushallinnon prosessien pitää olla standardoituja, dokumentoituja, järkeviä ja tehokkaita ennen kuin niitä on kannattavaa automatisoida. (Stein Smith 2020, 155.) Lisäksi tarpeettomat prosessit kannattaa karsia kokonaan, eikä niiden automatisointiin pidä kuluttaa resursseja.

Dokumentoimalla taloushallinnon prosessit saadaan selkeä käsitys niiden nykytilasta, mikä helpottaa niiden kehittämistä. Laadukas dokumentaatio myös helpottaa organisaation sisäistä tiedonjakoa ja perehdyttämistä. Taloushallinnon prosessit kannattaa kuvata prosessikaavioina jollain siihen soveltuvalla ohjelmistolla. Yleisiä prosessikuvauksia pitää tarkentaa yhteisillä työohjeilla, joissa prosessien vaiheet ja muu tarvittava informaatio on kerrottu sanallisesti. Lisäksi taloushallinnon työntekijöiden tukena ovat tilikartta ja laskentamanuaali. Prosessidokumentaatio on myös apuna päätettäessä, mitä prosesseja halutaan automatisoida. (Kaarlejärvi & Salminen 2018, 169–171.) Myös tekoälysovelluksen toiminta pitäisi dokumentoida. Lisäksi prosessidokumentaatiota voidaan tehostaa nauhoittamalla koulutusvideoita. (Taulli 2019, 157.)

## 5.2 Käyttöönoton toteutus

Tekoälyn käyttöönotossa on huomioitava sitä toteuttavan tiimin osaaminen. Heidi Kananen ja Harri Puolitaipaleen mukaan tekoälyprojektista saadaan eniten hyötyä, kun projektitiimissä yhdistyvät tekninen osaaminen, liiketoimintaosaaminen ja palvelumuotoilu. Heidän mukaansa parhaat onnistumiset saavutetaan, kun koko organisaatio innostuu yhdessä innovoimaan. (Kananen & Puolitaival 2019, 57–58.) Useissa lähteissä painotetaan kokeile ja opi -lähestymistä tekoälyn käyttöönottoon. Ralf T. Kreutzerin ja Marie Sirrenbergin mielestä tekoälyn käyttöönottoprojektin pitäisi olla lähestymistavaltaan alusta loppuun kokeileva ja holistinen. Kun sekä tekniset että operatiiviset esihenkilöt ovat mukana projektissa, ehkäistään eri tiimien siiloutumista. (Kreutzer & Sirrenberg 2020, 244.)

Tom Taullin mukaan tekoälyn käyttöönoton yrityksessä pitäisi aina alkaa henkilökunnan kouluttamisella ja harjoittelulla. Jokaisen yrityksessä – toimenkuvasta riippumatta – pitäisi hallita vähintään tekoälyn perusasiat. (Taulli 2019, 144.) Myös Rajendra Akerkar korostaa henkilökunnan koulutuksen merkitystä käyttöönoton yhteydessä. Hänen mukaansa koulutus on tarpeen, jotta henkilökunta oppii tuntemaan tekoälyn käytön ja soveltamiskohteet sekä pystyy tarvittaessa puuttumaan uuden tekoälysovelluksen toimintaan. (Akerkar 2019, 72.)

Tom Taullin mielestä tekoäly kannattaisi ensin ottaa käyttöön pienellä osalla käyttäjiä. Hän painottaa käyttöönoton tarkoituksena olevan oppiminen, jonka perusteella voidaan tehdä päätöksiä siitä, mitä sovelluksessa muutetaan ja mitä säilytetään. Käyttöönotto-vaihe on iteratiivinen, eikä sitä pidä kiirehtiä liikaa. Kun tekoäly otetaan käyttöön koko

organisaatiossa, saatavilla pitäisi olla tarpeeksi teknistä tukea ja joku johtamassa projektin toteutusta, Taulli toteaa. Lisäksi onnistuneesta projektista pitäisi saada tarpeeksi tunnustusta, mikä rohkaisee työntekijöitä innovoimaan jatkossakin. (Taulli 2019, 157.)

### 5.3 Käyttöönoton jälkeen

Käyttöönotetun tekoälysovelluksen toimintaa on seurattava, jotta varmistutaan sen toiminnasta ja tarkkuudesta. Tekoälymallin seurantaan voidaan käyttää samoja mittareita, jotka esiteltiin suorituskyvyn määrittelyä koskevassa luvussa. (Schreiber 2020.) Sovelluksen seurantaan voidaan luoda myös uusia KPI-mittareita, joiden avulla tarkkaillaan sen toimintaa (Taulli 2019, 149).

Toisaalta ulkoiselta toimittajalta hankittuun tekoälysovellukseen voi kuulua valmis raportointityökalu. Esimerkiksi suomalaisen, tekoälypohjaista ostolaskuautomaatiota tarjoavan, Snowfox.AI:n sovellus tuottaa käyttäjälle myös raportointia, joka yrityksen mukaan visualisoi tekoälyn toimintaa ja tarkkuutta yksityiskohtaisesti ja reaaliaikaisesti. (Snowfox.AI.)

## 6 Pohdinta ja johtopäätökset

Opinnäytetyön tarkoituksena oli tutustua tekoälyyn ja sen hyödyntämiseen digitaalisessa taloushallinnossa sekä selvittää, miten sen käyttöönotto taloushallinnon prosessiautomaatiossa kannattaisi toteuttaa. Tavoitteena oli tuoda esille, miten käyttöönottoon valmistaudutaan, miten se käytännössä toteutetaan ja mitä tapahtuu käyttöönoton jälkeen.

Tekoälyteknologioilla tulee olemaan suuri vaikutus tulevaisuuden liike- ja työelämään, myös taloushallinnossa. Vielä taloushallinnossa ei kuitenkaan ole yleisesti täyden automaation aika, vaan tekoälystä saadaan parhaiten hyötyä, kun sillä voidaan helpottaa ja nopeuttaa asiantuntijoiden työtä.

Taloushallinnon prosessiautomaatiossa tekoälyn käyttöönoton keskeisimmät edellytykset ovat digitaalinen taloushallinto ja laadukkaat prosessit. Jos huono prosessi automatisoidaan, saadaan automatisoitu huono prosessi. Digitaalinen taloushallinto on ehdoton edellytys tekoälylle, mutta toisaalta herättää määrittelyongelman. Sanna Kaarlejärvi ja Tero Salminen (2018, 14) nimeävät digitaalisesti taloushallinnoksi sellaisen, jossa kaikki tietovirrat on digitalisoitu ja tietoa käsitellään vain digitaalisesti. Toisaalta kirjoittajat itse



samassa teoksessa mainitsevat digitaalisen taloushallinnon myös voivan ottaa vastaan paperi- ja sähköpostilaskuja. Tekoälyn hyödyntämiseksi riittää edellä mainittu matalam-pikin digitaalisuusaste, vaikka täysi digitaalisuus varmasti mahdollistaa entistä parempaa automaatiotakin.

Lähdemateriaalista päätellen datan merkittävyyttä tekoälyn yhteydessä ei voi korostaa liikaa. Ennen tekoälyn käyttöönottoa sen kouluttamiseen on kerättävä riittävästi laadukasta dataa, joka usein vaatii myös valmistelua. Lisäksi on määriteltävä, mistä lähteistä saadaan riittävästi laadukasta dataa mallin toimintaan. Tämän vuoksi yrityksessä on tärkeää kiinnittää huomiota datan hallintaan jo ennen kuin tekoälyn käyttöönottoa suunnitellaan. Laadukas järjestelmäarkkitehtuuri ja master datan hallinta varmistavat tehokkaat tietovirrat, jotka puolestaan edistävät digitaalista taloushallintoa ja siinä käytettyjä teko-älysovelluksia.

Tekoälyn käyttöönotto edellyttää myös mallin määrittelyä. Erityisesti monimutkaisimmissa prosesseissa, kuten ostolaskuprosessissa, suurin hyöty saataneen käyttämällä syväoppivia neuroverkkoja. Neuroverkot kykenevät jatkuvaan oppimiseen, mikä on tarpeellista esimerkiksi uusien toimittajien myötä. Taloushallinnon automaatiossa käytettävät mallit lienevät enimmäkseen klassifikaatio- eli luokittelumalleja, koska näihin prosesseihin ei kuulu numeerista ennustamista. Mallin koulutustapa puolestaan lienee ohjattu oppiminen, koska digitaalisen taloushallinnon arkistoista on saatavilla runsaasti jo käsiteltyä dataa. Esimerkiksi ostolaskuarkistosta voidaan löytää runsaasti digitaalisessa muodossa olevia ostolaskuja, jotka on jo valmiiksi tiliöity.

Käyttöönottoprojektin tiimin tulisi koostua sekä taloushallinnon että tekoälyn asiantuntijoista. Useissa lähteissä myös korostetaan henkilöstön koulutuksen tärkeyttä: jokaisen tekoälyn kanssa työskentelevän pitäisi tietää sen toiminnan perusteet. Lisäksi kuvaillaan projektitiimin oikeanlaista ilmapiiriä, jonka pitäisi olla innovatiivinen, kokeileva, kokeilemaan rohkaiseva ja virheitä pelkäämätön. Tällöin väitetään saatavan tekoälyprojektista eniten hyötyä.

Lähdemateriaalissa toistuu myös kehoitus ensin pilotoida tekoälysovellusta pienellä osalla käyttäjiä ja sitten ottaa se käyttöön tälle pienelle osalle. Tällöin voidaan helpommin kontrolloida käyttöönottoa ja siinä aiheutuvia ongelmia. Ensimmäisestä käyttöönotosta saadaan tärkeää kokemusta lopullista käyttöönottoa varten. Käyttöönotossa on myös aina huolehdittava, että teknistä tukea on tarpeeksi saatavilla.

Käyttöön otetun tekoälysovelluksen toimintaa on seurattava, jotta varmistutaan sen toiminnasta. Seurannan toteutukseen ei kuitenkaan oteta kantaa suurimassa osassa aihepiiriä käsittelevästä kirjallisuudesta. Jatkuvasti oppivia neuroverkkoja käytettäessä on relevanttia seurata mallin tarkkuutta suorituskyvyn määrittelyä koskevassa luvussa esitellyin tavoin, koska mallin tarkkuus kehittyy oppimisen myötä. Lisäksi mallin seurannassa voidaan hyödyntää sitä varten suunniteltuja KPI-mittareita. Monien kaupallisten kehittäjien tekoälyautomaatiosovelluksiin puolestaan näyttää kuuluvan valmis raportointityökalu, jolla sovelluksen toimintaa voidaan seurata.

## 7 Lopuksi

Tekoäly osoittautui työtä tehdessä hyvin mielenkiintoiseksi aiheeksi, josta voisi kirjoittaa valtavan määrän, mutta johonkin oli pakko vetää raja. Tämän vuoksi työ jäi lähinnä yleiseksi johdatukseksi tekoälyyn ja sen hyödyntämiseen liiketoiminnassa. Erityisesti syväoppimista käsittelevä osuus on vain pintaraapaisu aihepiiristä. Tekoälystä on helposti saatavilla runsaasti lähdemateriaalia, mutta tämän työn tekemiseen sopivan aineiston löytäminen osoittautui vaikeaksi. Tällä tarkoitan aineistoa, jossa tekoälyä ja sen hyödyntämistä käsitellään riittävän laajasti ja yksityiskohtaisesti, mutta toisaalta yksinkertaisesti, käytännönläheisesti ja selkokielisesti, jotta alaa opiskelemaan voi sitä ymmärtää.

Opinnäytetyötä tehdessä osoittautui ongelmalliseksi myös taloushallintoa käsittelevän lähdemateriaalin hankkiminen. Sanna Kaarlejärven ja Tero Salmisen teosten lisäksi aihepiiristä ei löydy oikeastaan yhtäkään kattavaa ja ajankohtaista suomalaista teosta. Aihepiiriä käsittelevä ulkomainen aineisto puolestaan soveltuu huonosti suomalaista taloushallintoa käsittelevään työhön, koska digitaalisen taloushallinnon kehitys eri maissa vaihtelee voimakkaasti. Laskentatoimea käsittelevissä oppikirjoissakin käsitellään lähinnä kirjanpitoa, eikä käytännön taloushallinnosta kerrota mitään. Työssä käytetyt lähteet on kuitenkin arvioitu luotettaviksi. Lähteisiin sisältyy niin ammatti- ja oppikirjallisuutta kuin tieteellistä tutkimusta ja asiantuntija-artikkeleita. Yksittäisissä kohdissa on käytetty täydentävinä lähteinä myös muita internetsivustoja.

Opinnäytetyössä ei ole eroteltu toisistaan tuloksia ja johtopäätöksiä, sillä tämä työ ei varsinaisesti perustunut kvantitatiivisiin tai kvalitatiivisiin tutkimusmenetelmin saatuihin tuloksiin. Tehdyt johtopäätökset perustuivat kirjallisiin lähteisiin ja haastatteluun. Työtä olisi voitu parantaa tekemällä enemmän ja laajempia haastatteluja, mutta se tarjoaa kuitenkin tekoälyä ja taloushallintoa aiemmin tuntemattomalle hyvän pohjakäsityksen aihepiiristä.

Jatkotutkimusaiheeksi ehdotan erityisesti syventymistä neuroverkkojen hyödyntämiseen taloushallinnon automaatiassa. Tämän työn kannalta liian myöhään selvisi se, miten paljon edistyksellisempää teknologiaa syväoppivat mallit ovat perinteiseen koneoppimiseen verrattuna. Kuten aiemmin mainittiin, lienevät jatkuvaan oppimiseen kykenevät neuroverkot huomattavasti perinteisiä algoritmeja käytännöllisempiä taloushallinnon automaatiassa. Taloushallinnon prosesseissa, joissa data saattaa muuttua nopealla tahdilla, taitavatkin perinteiset koneoppivat algoritmit olla jo vanhentuneita. Tämän vuoksi mielestäni olisi aiheellista tehdä vastaavanlainen selvitys, jossa lähtökohtaisesti käsiteltäisiin syväoppivien mallien hyödyntämistä taloushallinnon automaatiassa. Toisaalta myös tekoälysovellusten toiminnan seuranta tarvitsisi mielestäni lisäselvitystä, sillä aihetta käsitellään vain hyvin harvassa tekoälyn käyttöönottoa käsittelevässä lähteessä.

## Lähteet

Akerkar, Rajendra 2019. Artificial Intelligence for Business. Springer, Cham. SpringerLink, <https://link-springer-com.ezproxy.metropolia.fi/book/10.1007%2F978-3-319-97436-1>. Luettu 15.4.2021.

Eklund, Irina & Hakonen, Marika & Roos, Miia 2017. Taloushallinnon taitajaksi. Sanoma Pro, Helsinki.

Elonen, Antero & Torniainen, Tiina. Taloushallinnon rooli ja haasteet. Talousjohdon ja -hallinnon muuttuvat haasteet. Bonnier Pro, <http://www.bonnierpro.fi.ezproxy.metropolia.fi/fi/app/talous-ja-rahoitus/talousjohdon-ja-hallinnon-muuttuvat-haasteet>. Luettu 16.3.2021.

Jormakka, Raija & Koivusalo, Kaija & Lappalainen, Jaana & Niskanen, Mervi 2015. Laskentatoimi. 4., uudistettu painos. Edita, Helsinki. Ellibs, <https://www.ellibslibrary.com/book/9789513767822>. Luettu 27.3.2021.

Joshi, Ameet V. 2020. Machine Learning and Artificial Intelligence. Springer, Cham. SpringerLink, <https://link-springer-com.ezproxy.metropolia.fi/book/10.1007%2F978-3-030-26622-6>. Luettu 5.4.2021.

Järvenpää, Marko & Länsiluoto, Aapo & Partanen, Vesa & Pellinen, Jukka 2017. Talousohjaus ja kustannuslaskenta. 2.-4. painos. Sanoma Pro, Helsinki. Ellibs, <https://www.ellibslibrary.com/book/978-952-63-2005-2>. Luettu 1.4.2021.

Kaarlejärvi, Sanna & Salminen, Tero 2018. Älykäs taloushallinto. Automaation aika. Alma Talent, Helsinki.

Kananen, Heidi & Puolitaival, Harri 2019. Tekoäly. Bisneksen uudet työkalut. Alma Talent, Helsinki.

Kelleher, John D. 2019. Syväoppiminen. Kuinka tekoäly toimii. Suom. Pietiläinen, Kimmo. Terra Cognita, Helsinki.

Kirjanpitolaki 30.12.1997/1336. Finlex. <https://www.finlex.fi/fi/laki/ajantasa/1997/19971336>. Luettu 8.2.2021.

Kohdeyrityksen työntekijä 2021. Taloushallinnon asiantuntija. Toimeksiantajayritys. Haastattelu 19.2.2021.

Kreutzer, Ralf T. & Sirrenberg, Marie 2020. Understanding Artificial Intelligence. Fundamentals, Use Cases and Methods for a Corporate AI Journey. Springer, Cham. SpringerLink, <https://link-springer-com.ezproxy.metropolia.fi/book/10.1007%2F978-3-030-25271-7>. Luettu 12.4.2021.

Lahti, Sanna & Salminen, Tero 2014. Digitaalinen Taloushallinto. Sanoma Pro, Helsinki.

Massaron, Luca & Mueller, John Paul 2018. Artificial Intelligence for Dummies. John Wiley & Sons, Inc., Hoboken, New Jersey.

Merilehto, Antti 2018. Tekoäly. Matkaopas johtajalle. Alma Talent, Helsinki.

Nielsen, Michael A. 2015. Neural Networks and Deep Learning. Determination press. [Http://neuralnetworksanddeeplearning.com/index.html](http://neuralnetworksanddeeplearning.com/index.html). Päivitetty 26.12.2019. Luettu 1.2.2021.

Niskavaara, Eeva 2017. Yritystaloutta esimiehille. 3., uudistettu painos. Alma Talent, Helsinki. Alma Talent Verkkokirjahylly, [https://verkkokirjahylly-almatalent-fi.ezproxy.metropolia.fi/teos/EACBDXDTEB#/kohta:YRITYSTALOUTTA\(\(20\)ESIMIEHILLE\(\(20\)/piste:b911](https://verkkokirjahylly-almatalent-fi.ezproxy.metropolia.fi/teos/EACBDXDTEB#/kohta:YRITYSTALOUTTA((20)ESIMIEHILLE((20)/piste:b911). Luettu 21.2.2021.

Pervilä, Markku 2020. Robotit rynnivät yritysten taloushallintoon – lisää vierailuja it-osastoilla. Tivi. <https://www.tivi.fi/uutiset/robotit-rynnivat-yritysten-taloushallintoon-lisaa-vierailuja-it-osastoilla/2f5d7847-3782-450f-8982-57121a400171>. Päivitetty 11.3.2020. Luettu 15.2.2021.

Pietikäinen, Matti & Silvén, Olli 2019. Tekoälyn haasteet. Koneoppimisesta ja kokenäöstä tunnetekoälyyn. Oulun yliopisto. Jultika, <http://jultika.oulu.fi/Record/isbn978-952-62-2482-4>. Luettu 15.2.2021.

Schreiber, Simon 2020. How to Measure AI Product Performance the Right Way. Medium. <https://medium.com/swlh/how-to-measure-ai-product-performance-the-right-way-2d6791c5f5c3>. Luettu 28.3.2021.

Smith, Patrick D. 2018. Hands-On Artificial Intelligence for Beginners. An introduction to AI concepts, algorithms, and their implementation. Packt, Birmingham. O'Reilly, <https://learning.oreilly.com/library/view/hands-on-artificial-intelligence/9781788991063/cover.xhtml>. Luettu 4.4.2021.

Snowfox.AI. Palvelun toiminnallisuudet. <https://www.snowfox.ai/toiminnallisuudet>. Luettu 28.3.2021.

Stein Smith, Sean 2020. Blockchain, Artificial Intelligence and Financial Services. Implications and Applications for Finance and Accounting Professionals. Springer, Cham. SpringerLink, <https://link-springer-com.ezproxy.metropolia.fi/book/10.1007%2F978-3-030-29761-9>. Luettu 6.4.2021.

Taulli, Tom 2019. Artificial Intelligence Basics. A Non-Technical Introduction. Apress, New York. SpringerLink, <https://link-springer-com.ezproxy.metropolia.fi/book/10.1007%2F978-1-4842-5028-0>. Luettu 6.4.2021.

Valtiokonttori 2019. Eduskunta hyväksyi lain hankintayksiköiden ja elinkeinonharjoittajien sähköisestä laskutuksesta. <https://www.valtiokonttori.fi/uutinen/eduskunta-hyvaksyi-lain-hankintayksikoiden-ja-elinkeinoharjoittajien-sahkoisesta-laskutuksesta/#fa95fbf8>. Luettu 15.2.2021.

Väre, Taru 2019. Master data. Alma Talent, Helsinki. Alma Talent Verkkokirjahylly, [https://verkkokirjahylly-almatalent-fi.ezproxy.metropolia.fi/teos/CAIBFXDTEB#/kohta:Master\(\(20\)data/piste:t2](https://verkkokirjahylly-almatalent-fi.ezproxy.metropolia.fi/teos/CAIBFXDTEB#/kohta:Master((20)data/piste:t2). Luettu 10.4.2021.