TEKOÄLYPOHJAINEN TYÖMÄÄRÄARVIOINTI ARKKITEHTISUUNNITTELUN PROJEKTILIIKETOIMINNASSA

Lappeenrannan–Lahden teknillinen yliopisto LUT

Tuotantotalouden diplomityö

2025

Henrik Kaasinen

Tarkastajat: Professori Janne Huiskonen

Tutkijaopettaja Petri Niemi

TIIVISTELMÄ

Lappeenrannan–Lahden teknillinen yliopisto LUT

LUT Teknis-luonnontieteellinen

Tuotantotalous

Henrik Kaasinen

Tekoälypohjainen työmääräarviointi arkkitehtisuunnittelun projektiliiketoiminnassa

Tuotantotalouden diplomityö

2025

81 sivua, 26 kuvaa, 1 taulukko ja 1 liite

Tarkastajat: Professori Janne Huiskonen ja Tutkijaopettaja Petri Niemi

Avainsanat: arkkitehtisuunnittelu, koneoppiminen, projektiliiketoiminta, tekoäly, työmääräarviointi

Diplomityön tavoitteena on kehittää tekoälypohjainen työmääräarvioinnin malli arkkitehtisuunnitteluprojektien ennustamiseen. Tutkimuksen kohdeyrityksenä toimii Arco Architecture Company Oy. Tavoitteena on parantaa etenkin kiinteähintaisten suunnitteluprojektien kannattavuutta, parantaa tarjouslaskennan tarkkuutta ja pienentää projektikannattavuuteen liittyvää taloudellista riskiä.

Tutkimus on toteutettu kehittämistutkimuksena. Hyödynnetty teoria koostuu projektiliiketoiminnan ja tekoälyn teoriasta. Tutkimuksen empiirinen osuus perustuu yrityksen toiminnanohjausjärjestelmän historialliseen projektidataan, jota hyödyntäen on rakennettu satunnaismetsäalgoritmiin perustuva koneoppimismalli. Malli kehitettiin pääasiassa Exceliä ja Pythonia hyödyntäen.

Tulokset osoittavat, että koneoppimiseen perustuva malli pystyy tuottamaan luotettavia arvioita suunnitteluprojektien työmäärästä. Malli ennustaa projektin tuntimäärän ja hinnan käyttäjän syöttämän suunnittelukohteen pinta-alan ja maantieteellisen sijainnin perusteella hyödyntäen historiallista projektidataa. Lähtödatan laatu ja kattavuus osoittautui keskeiseksi tekijäksi ennusteen luotettavuuden näkökulmasta. Työmääräarviointimalli tarjoaa helppokäyttöisen ja systemaattisen pohjan tarjouslaskennan tueksi.

Koneoppiminen tuo selkeää hyötyä arkkitehtisuunnitteluprojektien työmäärän arviointiin, etenkin kiinteähintaisissa suunnitteluprojekteissa. Tekoälypohjainen ennustemalli vähentää arvioinnin subjektiivisuutta ja nopeuttaa tarjouslaskentaa. Mallin käyttöönotto luo myös perustaa laajemmalle tekoälyn hyödyntämiselle arkkitehtisuunnittelun liiketoimintaprosesseissa.

ABSTRACT

Lappeenranta–Lahti University of Technology LUT

School of Engineering Science

Industrial Engineering and Management

Henrik Kaasinen

AI-based workload estimation in architectural design projects

Master's thesis

2025

81 pages, 26 figures, 1 table and 1 appendix

Examiners: Professor Janne Huiskonen and Associate Professor Petri Niemi

Keywords: Architectural design, machine learning, project business, artificial intelligence, workload estimation

The objective of this master's thesis is to develop an AI-based workload estimation model for architectural design projects. The case company is Arco Architecture Company Oy. The goal is to improve the profitability of fixed-price design projects, to improve the accuracy of cost estimation and to reduce the financial risk related to project profitability.

The study follows the design science research method. The theoretical framework consists of the literature of project business and artificial intelligence. The empirical part of the research is based on historical project data from the company's ERP system. This data has been utilized to build a machine learning model based on a random forest algorithm. The model was developed mainly using Excel and Python.

The results show that the machine learning model can produce reliable estimates of the workload of architectural design projects. The model predicts the number of hours and price of a project based on the entered building area and geographical location, utilizing historical project data. The quality and comprehensiveness of the input data proved to be a key factor in the reliability of the forecast. The quality of the input data proved to be a critical factor or reliable predictions. The model offers a systematic and user-friendly approach to support the tender process.

Machine learning brings clear benefits to the estimation of the workload of architectural design projects, especially in fixed-price design projects. An AI-based forecasting model reduces subjectivity and speeds up the tender calculation process. The implementation of the model also creates a foundation for a broader utilization of artificial intelligence in architectural design business processes.

KIITOKSET

Tämä diplomityö päättää opintopolkuni kohti diplomi-insinöörin tutkintoa. On ollut antoisa kokemus saada yhdistää opintojen myötä kertynyt osaaminen ja aikaisempi työkokemuksen arkkitehtisuunnittelun parissa.

Esitän lämpimät kiitokset työn ohjaajille sekä yliopiston että Arco Architecture Companyn puolella. Professori Janne Huiskoselle kiitos rakentavasta palautteesta ja oivaltavista kehitysehdotuksista prosessin aikana. Toimitusjohtaja Marko Somermalle ja aluejohtaja Kalle Soinille kiitos hyvästä sparrauksesta ja mahdollisuudesta toteuttaa diplomityö aidosti käytännönläheisen liiketoimintaongelman parissa. Lisäksi kiitän Arcon muuta henkilöstöä arvokkaasta avusta diplomityön teon aikana.

Kiitos LUT-yliopistolle korkeatasoisesta opetuksesta ja inspiroivasta oppimisympäristöstä, jossa olen saanut opiskella lahjakkaiden ja kannustavien kanssaopiskelijoiden parissa.

Erityinen kiitos kuuluu perheelleni ja rakkaalle vaimolleni korvaamattomasta tuesta DI-opintojen ja diplomityön teon aikana.

Turussa 15.6.2025

Henrik Kaasinen

LYHENNELUETTELO

AGI	Yleinen tekoäly (Artificial General Intelligence)
AI	Tekoäly (Artificial Intelligence)
API	Ohjelmointirajapinta (Application Programming Interface)
BI	Liiketoimintatiedon hallinta (Business Intelligence)
ERP	Toiminnanohjausjärjestelmä (Enterprise Resource Planning)
DL	Syväoppiminen (Deep Learning)
LLM	Suuri kielimalli (Large Language Model)
ML	Koneoppiminen (Machine Learning)
NLP	Luonnollisen kielen käsittely (Natural Language Processing)

Sisällysluettelo

Tiivistelmä

Abstract

Kiitokset

Lyhenneluettelo

1 Johdanto 7
1.1 Työn tausta 7
1.2 Tavoitteet ja rajaus 8
1.3 Tutkimuksen toteutustapa 9
1.4 Tutkimusraportin rakenne 10

2 Projektiliiketoiminta ja tarjouslaskenta 11
2.1 Projektinhallinta 11
2.2 Arkkitehtisuunnittelu projektiliiketoimintana 15
2.3 Kustannus- ja resurssilaskennan menetelmät 19

3 Tekoäly ja työmäärän ennustaminen 27
3.1 Tekoälyn määritelmät ja siihen liittyvät teknologiat 27
3.2 Tekoälyn hyödyntäminen organisaatioissa 32
3.3 Regressioalgoritmit 36
3.4 Parametrisen kustannusarvioinnin edut asiantuntija-arvioon verrattaessa 39

4 Nykytila kohdeyrityksessä ja projektidatan hyödyntäminen 40
4.1 Tutkimusprosessin empiirinen osuus 40
4.2 Toiminnanohjausjärjestelmä 40
4.3 Käytössä olevat hinnoittelumallit 41
4.4 Tarjouslaskennan ja työmääräarvioinnin nykytila 42
4.5 Tavoitekate 46

5 Oppivan työmäärälaskentamallin kehittäminen 47
5.1 Mallin kehittämisen lähtökohdat 47
5.2 Hyödynnettävä projektidata 48

5.3 Mallin tekniset lähtökohdat ja kehittäminen 50
5.4 Luotettavuuden ja käytettävyyden arviointi 60
5.5 Kehityskelpoisuus ja hyödynnettävyys 65
6 Johtopäätökset ja suositukset 68
6.1 Vastaukset tutkimuskysymyksiin 68
6.2 Kehittämisehdotukset kohdeorganisaatiolle 70
6.3 Johtopäätökset ja jatkotutkimus 72
Lähteet 75

Liitteet

Liite 1. Haastattelupohja

1 Johdanto

1.1 Työn tausta

Diplomityö käsittelee arkkitehtisuunnitteluprojektien kannattavuutta ja on toteutettu yhteistyössä Arco Architecture Company Oy:n kanssa. Arco on Suomen merkittävimpiä arkkitehtisuunnittelun toimialan yrityksiä. Yrityksen liikevaihto vuonna 2024 oli 15,7 M€ ja henkilöstö 144 hlö. Yrityksellä on toimipisteet Helsingissä, Tampereella, Turussa ja Oulussa.

Aihe on muodostunut kohdeyrityksen tarpeesta kehittää kiinteähintaisten projektien kannattavuutta hyödyntämällä tekoälypohjaisia ratkaisuja. Taustalla on havainto siitä, että erityisesti kiinteähintaisissa projekteissa tarjousvaiheessa tehtyjen työmääräarvioiden epävarmuus voi heikentää projektikohtaista kannattavuutta ja kasvattaa taloudellista riskiä. Arkkitehtisuunnittelu on projektiliiketoimintaa ja yrityksen kannattavuus muodostuu lopulta toimitettujen suunnitteluprojektien kannattavuudesta.

Rakennusala on herkkä reagoimaan talouden suhdanteisiin ja projektiluontoinen liiketoiminta tuo myös mukanaan omat haasteensa yrityksen talouden ennakoitavuuden näkökulmasta. Rakentaminen on ollut Suomessa viime vuodet laskusuhdanteessa, joka on johtanut myös rakennussuunnittelun määrän vähenemiseen. Asuntorakentaminen on ollut erityisen alhaisella tasolla. Heikentynyt volyymi on luonut painetta suunnittelupuolelle ja vaikeuttanut arkkitehtitoimistojen katteiden ylläpitämistä.

Diplomityö jatkaa aiempaa samassa kohdeyrityksessä tehtyä toimitusketjun projektityötä, jossa kartoitettiin haastatteluin projektikannattavuuden nykytilaa ja siihen vaikuttavia tekijöitä projektin eri vaiheissa. Diplomityö syventää projektityössä tehtyjä havaintoja ja kytkeytyy osaksi yrityksen laajempaan tavoitetta hyödyntää projektidataa liiketoiminnassa ja päätöksenteon tukena.

Kehittämisnäkökulmasta diplomityö tuo parannusta tarjouslaskennan toimintamalleihin kehittämällä yksinkertaisen ja helppokäyttöisen historiallisen projektidataan perustuvan työmääräarviomallin, jonka avulla voidaan lisätä työmääräennusteiden luotettavuutta, tukea tarjoushinnoittelua ja edistää projektikatteiden toteutumista.

1.2 Tavoitteet ja rajaus

Diplomityön päätavoitteena on kehittää oppiva ja dynaaminen tekoälypohjainen työmäärälaskentamalli arkkitehtisuunnitteluprojektien tarjouslaskentaa varten. Aineisto rajataan asuntosuunnitteluprojekteihin ja tarkoituksena on parantaa asuntosuunnittelun työmääräarvioinnin tarkkuutta hyödyntäen toiminnanohjausjärjestelmästä (Visma Severa) saatavaa toteutunutta projektidataa.

Liiketoimintanäkökulmasta tavoitteena on tukea entistä tarkempaa ja tietoon perustuvaa tarjoushinnoittelua, jotta erityisesti kiinteähintaisissa projekteissa voidaan vähentä riskiä ja saavuttaa parempi kannattavuus suunnittelutyöhön tarvittavan työmäärän realistisemman arvioinnin avulla. Diplomityöllä on yksi päätutkimuskysymys, joka on jaettu useampaan alakysymykseen.

Päätutkimuskysymys:

1. Kuinka tekoälyn ja projektidatan avulla voidaan kehittää arkkitehtisuunnittelu-projektien työmääräarviointia ja tukea kannattavampaa tarjouslaskentaa?

Alakysymykset:

1.1 Mitkä tekijät vaikuttavat työmäärän ennustamiseen arkkitehtisuunnittelu-projekteissa?

1.2 Miten kohdeyrityksen historiallisen projektidatan analytiikkaa voidaan hyödyntää ennustemallin rakentamisessa?

1.3 Millaisia mahdollisuuksia ja rajoitteita tekoälypohjaiset työkalut tarjoavat tarjouslaskennan kehittämisessä ja liiketoiminnan kannattavuuden tukemisessa?

Diplomityö on rajattu koskemaan kiinteähintaisia asuntosuunnitteluprojekteja ja siinä keskitytään ensisijaisesti tarjouslaskennan työmääräarviontiin, ei muihin tarjousprosessin osa-alueisiin, kuten laadullisiin vaikuttimiin tai sopimustekniikkaan. Empiirisessä osassa kehitetään toimiva konsepti koneoppimiseen perustuvasta työmäärälaskentamallista. Tavoitteena on rakentaa ensisijaisesti kohdeorganisaation tarpeisiin vastaava ratkaisu. Kehitetyn mallin laajamittainen käyttöönotto organisaatiossa ei sisälly tämän diplomityön laajuuteen.

1.3 Tutkimuksen toteutustapa

Diplomityö koostuu teoreettisesta ja empiirisestä osuudesta. Teoriaosassa muodostetaan kirjallisuuskatsauksen avulla kokonaiskuva tutkimuksen kannalta tärkeistä aihealueista. Hyödynnetty tutkimus ja kirjallisuus jakautuu kahteen suurempaan kokonaisuuteen: projektiliiketoiminnan teoriaan ja tekoälyn teoriaan. Näistä aihealueista pyritään muodostamaan kokonaiskuva useita toisiaan täydentäviä teoreettisia näkökulmia yhdistelemällä ja sitomalla tämä teoriatausta yhteen rakennetun työmääräarviointimallin muodossa.

Projektinhallinnan ja kustannuslaskennan teoriaa hyödynnetään erityisesti ymmärtämään projektiliiketoimintaan liittyvää tarjouslaskentaprosessia ja työmääräarviointia. Keskeisiä teemoja ovat mm. projektin johtaminen, työvaiheiden resursointi, riskienhallinta, hinnoittelu ja kannattavuuden johtaminen. Tekoälyn teoriaa hyödynnetään erityisesti ymmärtämään niiden tausta ja soveltuvuus mallin rakentamiseen ja projektidatan analytiikkaan arkkitehtiliiketoiminnan kontekstissa. Tässä osassa keskeisiä teemoja ovat mm. suuret kielimallit, koneoppiminen, syväoppiminen ja generatiivinen tekoäly.

Tutkimus tehdään kehittämistutkimuksena (Kananen 2012; van Aken 2007), jossa ongelmaa jäsennellään käytännönläheisistä lähtökohdista ja ratkaisu muodostetaan osana tutkimusprosessia. Diplomityön prosessi on kuvattu alla hyödyntäen Peffers et al. (2020) kehittämistutkimuksen tutkimusprosessimallia (Design Science Research Process). Lähtökohtana tutkimuksen teolle on ollut tavoitekeskeinen ratkaisu, josta suunniteltu ratkaisu on johdettu.

Diplomityön lopputuloksena rakennettu työmääräarvioinnin malli on kehitetty mainittua kehittämistutkimuksen prosessia hyödyntäen ja sen käytettävyyttä arvioidaan samasta näkökulmasta. Ennustemalli toteutetaan konseptitasoisena ja käytännössä toimivana mallina.

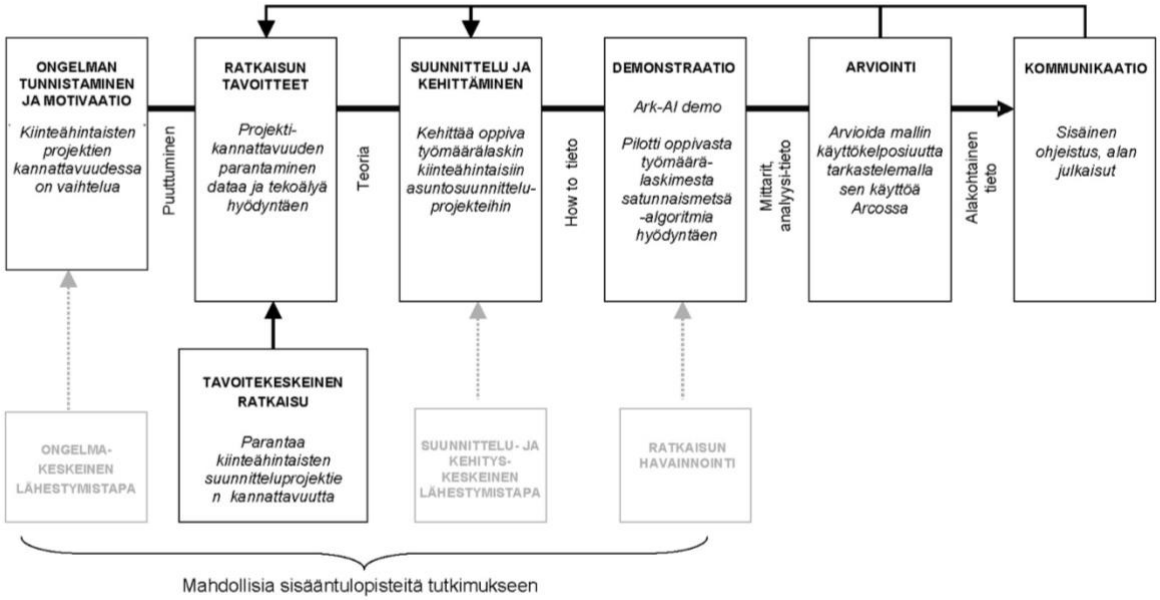

Kuva 1. Diplomityö kehittämistutkimusprosessina (mukaillen Peffers et al. 2020)

Kohdeyrityksessä tehtävä tiedonhankinta perustuu ensisijaisesti toiminnanohjausjärjestelmästä (Visma Severa) saatavaan historialliseen projektidataan. Ymmärrystä täydennetään aikaisemman projektityön aikana tehtyjen haastattelujen tiedoilla ja tämän diplomityön aikaisilla tarkentavilla keskusteluilla.

Diplomityön teossa on hyödynnetty ChatGPT tekoälysovellusta sisällysluettelon ja tekstin jäsentelyyn sekä Python-skriptien koodaamisen apuna LUT-yliopiston Tekoälytyökalujen käytänteiden mukaisesti (5.10.2023).

1.4 Tutkimusraportin rakenne

Diplomityö noudattaa LUT-yliopiston TUTA-käytännön mukaista rakennetta. Työssä on kuusi päälukua. Ensimmäinen luku sisältää johdannon, jossa on määritelty työn tausta, tavoitteet, rajaus ja toteutustapa. Toinen ja kolmas luku sisältävät teoriaosan, jossa käydään läpi työn aiheen kannalta keskeiset havainnot lähdekirjallisuudesta, projektin- ja kustannusjohtamisen sekä tekoälyn osalta. Neljäs ja viides luku ovat työn empiirinen osuus, jossa kuvataan nykytila kohdeyrityksessä, käydään läpi kerätty aineisto, kuvaillaan mallin kehittämisen prosessi ja arvioidaan sen kehityskelpoisuutta ja sovellettavuutta. Kuudes luku on yhteenveto, jossa tiivistetään työn keskeiset tulokset yhteen ja nostetaan esiin tunnistettuja jatkotutkimusaiheita.

2 Projektiliiketoiminta ja tarjouslaskenta

2.1 Projektinhallinta

2.1.1 Projektin määritelmä

Projektille löytyy kirjallisuudessa useita määritelmiä. Tiiviisti ilmaistuna projekti on: *”työkokonaisuus, joka tehdään määritellyn kertaluonteisen tuloksen aikaansaamiseksi”* (Pelin 2009, s. 25). Hieman laveammin ilmaistuna projekti on: *”ennalta määritettyyn päämäärään tähtäävä, monimutkaisten ja toisiinsa liittyvien tehtävien muodostama ajallisesti, kustannuksiltaan ja laajuudeltaan rajattu ainutkertainen kokonaisuus”* (Artto et al. 2006).

Projekti eroaa muista yrityksessä tehtävistä aktiviteeteista siten, että projektilla on aina alku ja loppu, se on siis aina luonteeltaan väliaikainen (Tonchia 2008, s. 3, Scwalbe 2015, s. 5). Jokainen projekti ja sen lopputulos on aina myös jossain määrin uniikki luonteeltaan, jonka seurauksena siihen liittyy myös epävarmuutta ja riskejä (PMI 2013, s. 3). Projektit voivat olla laajuudeltaan, kestoltaan tai kustannuksiltaan hyvin eri kokoisia (Schwalbe 2015, s. 4–5).

Projektiliiketoiminta on yrityksen liiketoiminnan muoto, joka on *”projekteihin liittyvää johdettua ja tavoitteellista toimintaa, joka palvelee yrityksen päämäärien saavuttamista”* (Artto et al. 2006, s. 17). Tämä voidaan nähdä sekä ratkaisujen toimittamisen (toimitusprojekti) tai oman liiketoiminnan kehittämisen (kehitysprojekti) näkökulmasta. Arkkitehtisuunnittelu on hyvä esimerkki projektiliiketoiminnasta.

2.1.2 Projektin tavoitteet

Projektin tavoitteita voidaan katsoa kolmen ulottuvuuden kautta: *aika*, *laajuus* ja *kustannus* (Artto et al. 2006, s.32) Laajuus viittaa projektin tuotteena syntyneen lopputuloksen teknisiin ja laadullisiin ominaisuuksiin, jotka ilmenevät asiakkaan suuntaan projektista saatavana hyötynä tai lisäarvona. Aika viittaa projektin aikatauluun, eli onko projekti ja sen tuotos

toimitettu sovitussa ajallisessa rajauksessa. Kustannustavoite liittyy projektiin tuottotavoitteeseen, eli projektin tulee olla tuottojen ja kustannusten erotuksena projektin toimittajalle kannattava.

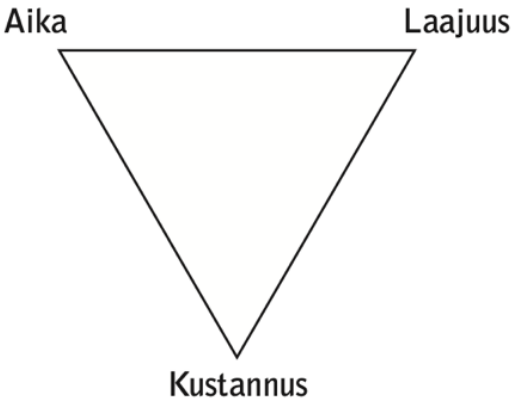

Kuva 2. Projektin keskeiset tavoitteet (Artto et. al 2006, s. 32)

Mainitut kolme ulottuvuutta ovat sidoksissa toisiinsa ja niiden väliset painotukset vaihtelevat projektikohtaisesti (Artto et al. 2006, s. 34). Projektin alussa on kolmelle ulottuvuudelle asetettava tavoitteet, joiden avulla niiden toteutumisen arviointi on mahdollista. Edellä mainittujen lisäksi myös *laatu, riski* ja *resurssit* voidaan nähdä keskeisinä projektin muina ulottuvuuksina (Schwalbe 2015, s. 6–7, PMI 2013, s. 6, Pelin 2009 s. 33).

Projektit voidaan jakaa viiteen perustyyppiin: tuotekehitysprojekti, tutkimusprojekti, toiminnan kehittämisprojekti, toimitusprojekti ja investointiprojekti (Pelin 2009, s.35–36). Tässä projektityössä käsitellään erityisesti toimitusprojektia, joka tarkoittaa projektia yrityksen toimeksiantona maksavalle tilaajalle (Pelin 2009, s. 36).

Projektin tavoitteisiin sisältyy projektin eri sidosryhmien välillä ristiriitaistenkin tarpeiden ja odotusten tyydyttäminen. Sidosryhmiä ovat kaikki ne tahot, jotka ovat mukana projektissa tai joihin projekti vaikuttaa, kuten projektin asiakas, projektin sponsori, projektin työryhmä, tukihenkilöstö, käyttäjät, toimittajat ja jopa vastustajat (PMI 2013, s. 8).

2.1.3 Projektin vaiheet

Projektin elinkaari voidaan toimittajan näkökulmasta jakaa karkeasti kolmeen vaiheeseen: markkinointi ja myynti, toteutus sekä käytön tukeminen (Artto et al. 2006, s. 50). Näiden kolmen vaiheen väliin sijoittuvat markkinointi ja myyntivaiheen jälkeen tehtävä sopimus ja

toteutusvaiheen jälkeen tapahtuva projektin luovutus asiakkaalle. Kukin kolmesta vaiheesta voidaan jakaa edelleen pienempiin osakokonaisuuksiin. Alla on avattu toimitusprojektin markkinointi- ja myyntivaihe, jonka aikana tehtävillä päätöksillä on merkittävä vaikutus projektin aikana muodostuviin kustannuksiin ja kannattavuuteen (Artto et al. 2006, s. 55).

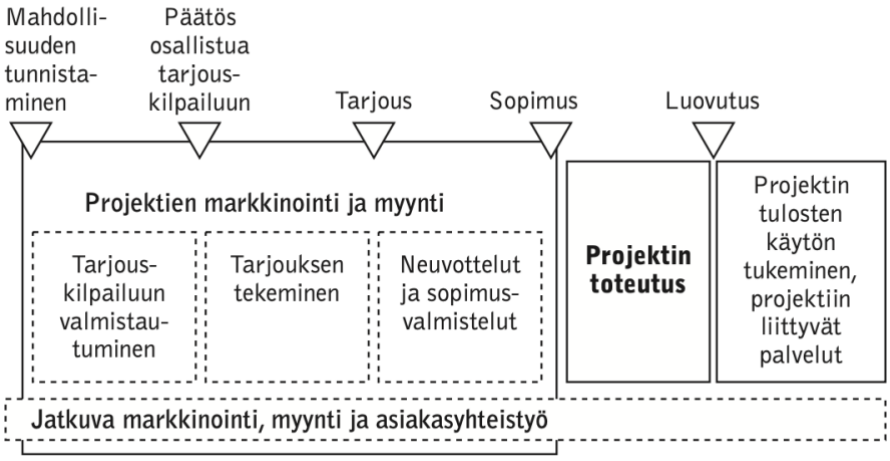

Kuva 3. Toimitusprojektin markkinointi- ja myyntivaihe projektin toimittajan näkökulmasta (Artto et al. 2006, s. 55)

2.1.4 Projektinhallinta

Projektinhallinta (Project Management) on: ”projektin tavoitteiden ja päämäärän saavuttamiseksi tähtäävien johtamistapojen soveltamista” (Artto et al. 2006, s.35). Tämä sisältää projektin tavoitteisiin pääsemiseen tarvittavien tietojen, taitojen, työkalujen ja menetelmien soveltamista (PMI 2013, s. 5, Schwalbe 2015, s. 8). Projektinhallintaa voidaan katsoa kolmesta näkökulmasta: tietoalueena- ja prosessina, osaamisena ja ominaisuuksina sekä työvälineinä ja dokumentaationa (Artto et al. 2006, s. 36–41, PMI 2013, s. 10–12).

Mainituista näkökulmista ensimmäisessä korostuvat mm. prosessit ja ISO-standardit. Toisessa korostuvat projektityöryhmän ja projektipäällikön osaaminen. Kolmannessa korostuvat projektinhallinnan ohjeistukset ja välineet, kuten tietotekniset järjestelmät. Kustakin projektinhallinnan osa-alueesta ja niihin liittyvästä sisällöstä on kirjoitettu laajasti kirjallisuutta (esim. PMI 2013, Vartiainen et al. 2003).

Projektinhallinnan prosessi voidaan jakaa seuraaviin vaiheisiin: ongelman määrittely, ratkaisuvaihtoehtojen kehittely, projektin suunnittelu, suunnitelman toteutus, edistymisen

seuranta ja valvonta sekä projektin sulkeminen (Lewis 2007, s. 15–16, PMI 2013, s.10). Projektinhallinta kattaa yhdeksän yleisesti tunnistettua osa-aluetta, jotka ovat: kokonaisuuden hallinta, laajuuden hallinta, aikataulun hallinta, kustannusten hallinta, resurssien ja henkilöstön hallinta, viestintä, riskienhallinta, hankintojen hallinta sekä laadunhallinta (Artto et al. 2006, s. 37–38).

2.1.5 Projektin organisointi ja johtaminen

Projektiorganisaatio on yksinkertaisesti *”projektin toteuttamista varten muodostettu tarkoituksenmukainen organisaatio”* (Pelin 2009, s. 67). Projektin koko, tyyppi ja kesto määrittävät mitä tarkoituksenmukainen organisaatio tarkoittaa kussakin tapauksessa. Projektiorganisaation tyypit voidaan jakaa alla kuvattuihin viiteen luokkaan (Pelin 2009, s. 76). Jako perustuu siihen, että kuinka suuri osa päätöksenteosta tapahtuu projektin sisällä ja kuinka suuri osa laajemman organisaation piirissä. Harva yritys edustaa puhtaasti kumpaakaan ääripäätä.

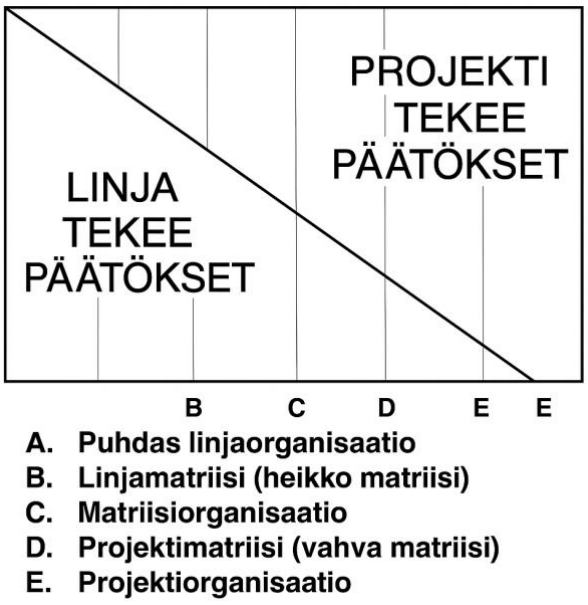

Kuva 4. Projektiorganisaation tyyppejä (mukaillen Pelin 2009, s. 76).

Projektin johtamisen ja läpiviennin kannalta keskeisessä roolissa on projektissa mukana oleva henkilöstö. Osallisina ovat yleensä projektiryhmä, projektipäällikkö ja projektin ohjausryhmä ja johtoryhmä. Projektiorganisaation tulee kyetä toimimaan organisaationa sekä oman yrityksensä että ulkoisen toimintaympäristön ja sidosryhmien kanssa.

2.1.6 Projektipäällikön rooli

Projektipäällikön tehtävänä on olla projektin ”toimitusjohtaja”. Pääasiallisena vastuuna projektipäälliköllä on varmistaa, että projektin kolme ulottuvuutta täyttyvät, jotta projekti valmistuu ajallaan, budjetissa ja siinä laajuudessa ja laatutasossa kuin on sovittu (Lewis 2007, s. 24). Projektipäällikköön kohdistuu erilaisia odotuksia ja tarpeita tilaajalta, oman organisaation johdolta, projektitiimin henkilöstöltä sekä yhteistyökumppaneilta (Artto et al. s. 274). Projektipäällikön tuleekin osata luovia erilaisten odotusten ja vaatimusten keskellä siten, että projektin tavoitteet täyttyvät.

Projektipäällikön tehtävän menestyksellinen suorittaminen edellyttää sekä henkilökohtaisia ominaisuuksia että tietoa ja osaamista. Johtamistutkimuksessa on havaittu, että hyvin erilaiset persoonat voivat menestyä tässä roolissa (Artto et al. s. 274). Sopivan luonteen, asenteen ja projektinhallinnan taitojen lisäksi projektipäällikkö tarvitsee teknistä, liiketoiminnallista, sosiaalista ja organisatorista osaamista. Lisäksi tarvitaan alakohtaista spesifiä osaamista ja tietoa.

Yleiset johtajuuden ja johtamisen taidot ovat projektipäällikölle tärkeitä. Mitä vaativampiin projektikokonaisuuksiin siirrytään, sitä enemmän projektipäällikkö tarvitsee yleisjohtamistasoista liiketoiminnallista ja vuorovaikutuksellista osaamista. Projektipäällikön tulee osata hyödyntää projektiryhmän erilaista osaamista. Projektin ryhmän jäsenten osaaminen kokonaisuutena on projektin tuloksellisuuden kannalta kaikista tärkeintä (Artto et. al 2006, s. 39)

2.2 Arkkitehtisuunnittelu projektiliiketoimintana

Arkkitehtisuunnittelu on moniulotteinen prosessi, joka sisältää erilaisten rakennukseen ja rakentamiseen liittyvien teknisten, esteettisten, toiminnallisten ja taloudellisten vaatimusten huomiointia ja yhteensovittamista. Arkkitehtisuunnittelu on suunnitteluprojektien toimittamista asiakkaalle (AIA & Hayes 2014 s. 770), joka yleisimmin tarkoittaa rakennussuunnitelmien tuottamista. Yksinkertaistettuna arkkitehtitoimiston kannattavuus muodostuu projektien yhteenlasketusta tuloksesta suhteessa yrityksen kiinteisiin ja muuttuviin kuluihin.

Arkkitehtisuunnittelun vaiheet noudattavat rakennushankkeen vaiheita. Alalla hyödynnetään yleisesti Arkkitehtisuunnittelun tehtäväluetteloa ARK18 (Rakennustieto 2020, RT 103253) sekä Pääsuunnittelun tehtäväluetteloa PS18 (Rakennustieto 2020, RT 103254). Arkkitehtisuunnittelun vaiheet on näiden korttien mukaisesti jaettu seuraaviin vaiheisiin: A. Tarveselvitys, B. Hankesuunnittelu, C. Suunnittelu valmistelu, D. Ehdotussuunnittelu, E Yleissuunnittelu, F. Rakennuslupatehtävät, G. Toteutussuunnittelu, H. Rakentamisen valmistelu, I. Rakentaminen, J. Käyttöönotto ja K. Takuuaika.

Mainittuja tehtäväluetteloita käytetään toimeksiannon sisällön määrittelyyn, suunnittelun hallintaan ja laadunvarmistukseen. (Rakennustieto 2020, RT 103253). Suunnittelusopimuksen osalta alalla sovelletaan yleisesti konsulttitoiminnan yleisiä sopimusehtoja (KSE), joita käytetään useimmiten perustana suunnittelusopimuksen ehdoille (Carenholm 2007, s. 45).

Nykypäivänä arkkitehtisuunnittelussa hyödynnetään yhä enemmän digitaalisia työkaluja ja tietomallipohjaista suunnittelua (BIM). Tietomallinnuksen ymmärtäminen helpottaa projektinhallintaa ja suunnitelmien yhteensovittamista sekä tehostaa suunnittelua, mutta tuo mukanaan yhden lisäalueen hallittavaksi osana projektin johtamista (AIA & Hayes 2014, s. 987).

2.2.1 Rakennushankkeen organisointi

Rakennushanke organisoidaan tyypillisesti niin, että rakennushankkeeseen ryhtyvä määrittelee hankeorganisaation ja nimeää siihen projektinjohtajan ja pääsuunnittelijan (Rakennustieto 2005, RT 13-10860). Pääsuunnittelija voi olla arkkitehti tai insinööri. Arkkitehdin rooli organisaatiossa voi olla suunnittelija ja/tai pääsuunnittelija. Pääsuunnittelijan tehtäviin kuuluvat suunnittelun johtaminen, eri alojen suunnitelmien yhteensovittaminen sekä vuorovaikutus rakennuttajan ja viranomaisten suuntaan. Pääsuunnittelijan ja vastaavan rakennussuunnittelijan tehtäviin liittyy lisäksi lakisääteisiä vastuita.

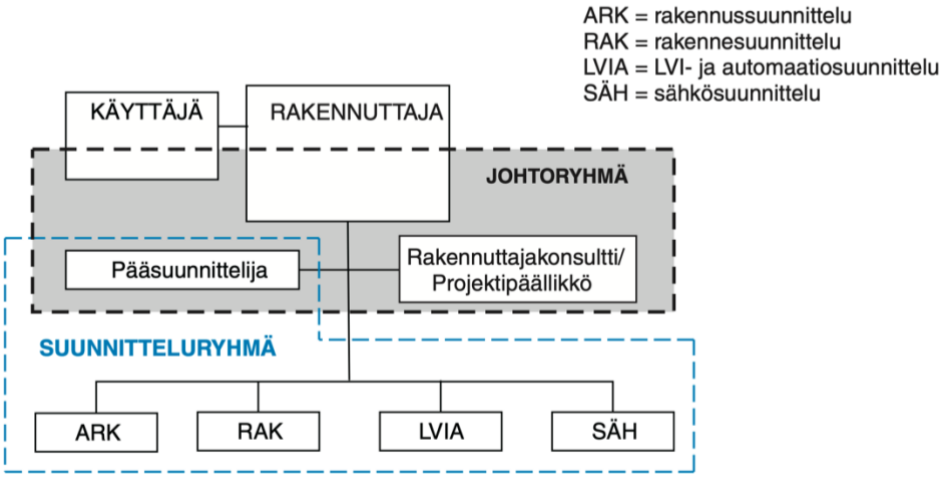

Kuva 5. Tyypillinen hierarkkinen organisaatiomalli rakennussuunnitteluhankkeessa (Rakennustieto 2005, RT 13-10860)

Rakennushanke voi toteutua usealla erilaisella toteutusmuodolla. Yleisimpiä rakennusurakkasopimuksen malleja ovat mm. jaettu urakka, kokonaishintainen urakka, kokonaisvastuurakentaminen (KVR), projektinjohtourakka (PJU) ja allianssi. Sopimus- ja alistussuhteet eri osapuolten välillä poikkeavat jonkin verran toisistaan näissä eri toteutusmuodoissa (Koskenvesa et.al. 2018), jonka seurauksena arkkitehdin asema ja vuorovaikutus suhteessa hankkeen muihin osapuoliin vaihtelee. Esimerkiksi allianssimallissa on yhteinen päätöksenteko ja läpinäkyvyys suuremmassa roolissa kuin perinteisessä rakennusurakassa.

Käytännössä kaikissa hankemuodoissa arkkitehdin sidosryhmiin kuuluvat mm. tilaaja, rakennuttaja, urakoitsija, viranomaiset, suunnitteluryhmä sekä muut erikoissuunnittelijat ja asiantuntijakonsultit. (Walker 2015, s. 259). Projektipäällikkönä tai pääsuunnittelijana toimivan arkkitehdin tulee hallita suunnittelun teknisen sisällön lisäksi tarvittavat yleisjohtamisen taidot sekä projektinjohtoon liittyvät aikataulu-, kustannus-, viestintä- ja laadunhallintataidot. Huolimatta rakennushankkeen toimitusmuodosta on projektissa aina jossain muodossa mukana kolme tahoa: omistaja, suunnittelija ja urakoitsija (AIA & Hayes 2014, s. 676).

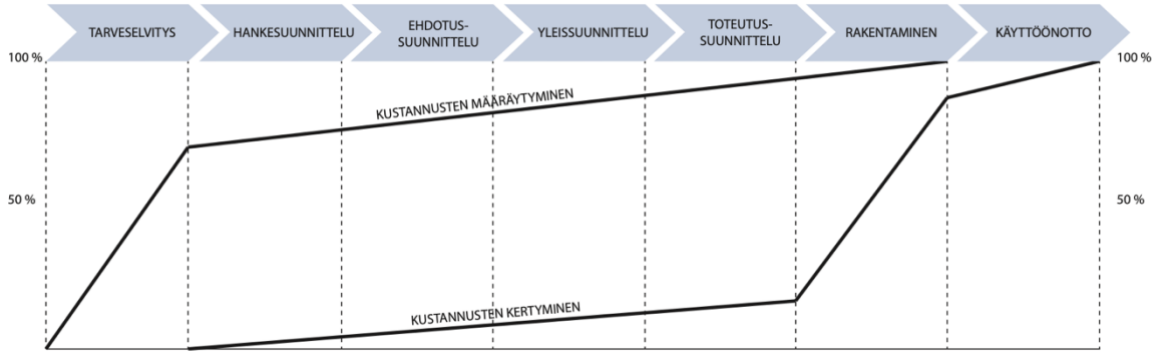

Kuva 6. Rakennushankkeen kustannusten määräytyminen ja kertyminen rakennushankkeen eri vaiheissa (Rakennustieto 2016. RT 10-11226)

2.2.2 Moniprojektiympäristö ja resurssien hallinta

Moniprojektiympäristö tarkoittaa tilannetta, jossa organisaatiossa on samanaikaisesti käynnissä useita eri projekteja (Hans et al. 2007). Arkkitehtitoimisto on tyypillisesti tämän tyyppinen ympäristö, jossa on useita samanaikaisia projekteja sekä eri erikoisosaamisen ja roolin omaavia suunnittelijoita. Resurssien allokointiin liittyvät päätökset vaikuttavat organisaatiossa epäsuorasti useisiin projekteihin samanaikaisesti (Engwall & Jerbrant 2003). Muutokset aikataulussa tai resursseissa aiheuttaa epävarmuutta ja ristiriitoja etenkin resurssien jakamisen osalta (Pelin 2009, s. 76).

Tilanteessa, jossa samaa resurssipoolia hyödynnetään usealle eri projektille, tulee tarve puhua resurssienhallinnasta ja projektisalkun hallinnasta (Artto et al. 2009, s. 391). Resurssien onnistunut allokointi on kriittistä kokonaisuuden onnistuneessa hallinnassa. Tähän tarvitaan lähestymistapa, joka mahdollistaa nopean reagoimisen muutoksiin ja tiedon jakamisen päätöksenteon tueksi (Momeni & Martinsuo, 2018).

2.2.3 Työmäärän arviointi arkkitehtisuunnittelussa

Rakennustieto on laatinut RT-kortin Arkkitehdin työmäärän arviointi rakennushankkeessa, joka antaa ohjeita suunnittelutyömäärän arvioimiseksi (Rakennustieto 2013, RT 13-11117). Ohjeessa esitetty malli perustuu kohteen bruttoalaan sekä suunnittelutehtävän vaativuusluokkaan, jolle on määritelty luokat VII-I. Tämän pohjalta muodostuu tunnusluvuksi tuntia per bruttoneliömetri (h/brm^2). Ohjekortin tausta-aineistona on käytetty

Arkkitehtitoimistojen liiton kokoamaa aineistoa. Hankkeiden luokittelu vaativuusluokkiin on aina jossain määrin subjektiivista, vaikka kortissa onkin esitelty suunnittelukohteen vaativuusluokan tyypillisiä piirteitä.

2.3 Kustannus- ja resurssilaskennan menetelmät

2.3.1 Projektin kustannusohjauksen tehtävä

Kustannustavoite on yksi projektin kolmesta tavoitteesta. Kustannusohjauksen tehtävä on: *”taloudellisesti edullinen projektin toteutus”* (Pelin 2009, s. 170). Käytännössä kustannustavoitteen täyttyminen tarkoittaa sitä, että projekti saadaan toteutettua ennalta määritellyssä budjetissa (Artto et al. 2006, s.33). Projektin kustannusohjaus on, yrityksen kirjanpidollisesta kustannuslaskennasta poiketen, luonteeltaan ennakoivampaa ja usein epätarkempaa (Pelin 2009, s. 170).

2.3.2 Projektin kustannusohjaus ja kannattavuus

Projektin kustannustenhallinta voidaan jakaa kolmeen vaiheeseen (PMI 2017):

1. Kustannusarviointi, jossa projektin resurssien kustannukset ennustetaan hankkeen kokonaiskustannusten arvioimiseksi
2. Kustannusbudjetointi, jossa laaditaan budjetti tekemällä yhteenveto työpakettien arvioiduista kustannuksista, optimoimalla tämä budjetti käytettävissä olevaan rahamäärään ja määrittämällä käyrä, joka kuvaa kuluja projektin elinkaaren läpi.
3. Kustannustenhallinta, jossa menojen edistymistä seurataan analysoimalla reaaliaikaisesti poikkeamat budjetoituun ennusteeseen.

Projektin kustannusohjaus pitää sisällään kustannusten arvioinnin, budjetoinnin, aikataulun ja kustannusten optimoinnin, kassavirtalaskelman, kustannusraportoinnin, ohjauspäätöksen sekä seurannan ja jälkilaskennan (Artto et al. 2006, s. 37, Tonchia 2008, s. 121, Pelin 2009, s. 170). Kokonaisuuteen sisältyy mm. projektin hinnoittelu, kannattavuuden arviointi, budjetin laatiminen, kustannusten ja tuottojen arviointi sekä kassavirran ja rahoituksen suunnittelu (Artto et al 2006, s. 150).

Kustannusten arviointi toimii pohjana projektin kannattavuuslaskelmille (Pelin 2009, s. 174). Kustannusarviossa otetaan huomioon kaikki projektiin liittyvät kustannukset ja saadaan käsitys projektin kokonaiskustannuksista (Tonchia 2008, s. 121–122). Arvio tarkentuu vaiheittain projektin edetessä (Pelin 2009, s. 174–179). Linjaorganisaation kustannuskirjanpidosta poiketen projektien kustannusvalvonta on tulevaisuuteen katsovaa, ennakoivampaa ja osittain epätarkempaa (Pelin 2009, s. 170).

Projektibudjetti on *”aikaan sidottu projektin taloudellinen toimintasuunnitelma”*, joka perustuu kustannusarvioon ja projektin tehtäviin sekä aikatauluun (Pelin 2009, s. 179). Käytännössä tämä tarkoittaa projektin kustannusten allokointia projektin aikataulun ja tehtäväjärjestyksen mukaiseen järjestykseen. Tyypillisesti projektibudjetti sisältää vain projektin kustannukset eli menot, projektin tulot voidaan kuvata erillisessä rahoitusbudjetissa tai kassavirtakaaviossa (Pelin 2009, s. 179).

Kustannusten seuranta tarkoittaa kustannusten valvontaa ja jälkilaskentaa (Pelin 2009, s. 182–187). Projektin menoja seurataan reaaliajassa projektin etenemisen kanssa, jotta projektin toteuman poikkeamat budjetista havaitaan (Tonchia 2008, s. 122). Kustannusvalvonta linkittyy keskeisesti tuntiraportointiin (Pelin 2009, s. 185) ja toiminnanohjausjärjestelmään. Jälkilaskelman tarkoituksena on projektin valmistuttua muodostaa yhteenveto projektin kustannuksista ja kannattavuudesta. Tätä tietoa voidaan hyödyntää poikkeamien analysoinnissa ja myös seuraavien projektien kustannuslaskelmien lähtötietona esimerkiksi tunnuslukuina (Pelin 2009, s. 186).

2.3.3 Projektin kustannusten arviointi

Projektin kustannuksia voidaan arvioida sekä laadullisilla että määrällisillä menetelmillä. Laadulliset menetelmät voidaan jakaa edelleen intuitiivisiin ja analogisiin menetelmiin sekä määrälliset menetelmät parametrisiin ja analyyttisiin menetelmiin (Niazi et al. 2006, s. 563). Käytännössä intuitiiviset ja analogiset menetelmät voivat tarkoittaa aikaisemman projektin kustannustiedon tai yksinkertaisesti yhtiön palveluksessa olevan kokeneen asiantuntijan arvion hyödyntämistä (Artto et al. 2006, s. 159, Niazi et al. 2006, s. 564). Parametriset ja analyyttiset menetelmät tarkoittavat käytännössä kustannusten jakamista sen osamuuttujiin eli kustannustekijöihin ja erilaisia tilastollisten menetelmien hyödyntämistä (Niazi et al. 2006, s. 567).

Kustannusarvio tarkentuu projektin edetessä vaiheittain (Pelin 2008, s.175, Artto et al. 2006, s. 163) ja sen tarkkuus riippuu siitä, kuinka tarkasti projektin laajuus ja riskit on mahdollista määritellä (Artto et al. 2006, s. 162). Kustannusarvion vaiheet voidaan jakaa karkeasti kolmeen: alustava kustannusarvio, peruskustannusarvio ja lopullinen kustannusarvio (Pelin 2008, s. 175). Alustavan kustannusarvion tarkkuus voi olla vaihteluvälillä -30/+50%, peruskustannusarvio -15/30% ja lopullinen kustannusarvio taas välillä -5/+15%. (AACE International 2021, s. 11)

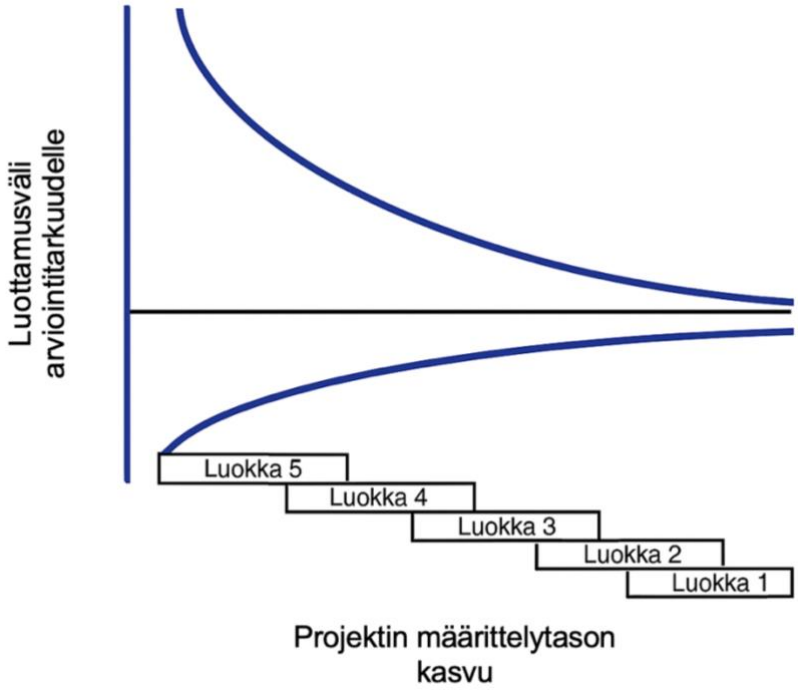

Kuva 7. Projektin kustannusarvion tarkentuminen vaiheittain (mukaillen AACE International 2021, s. 11)

Suurin osa projektin kustannuksista määräytyy jo projektin alkuvaiheessa ja erityisesti laadullisten kustannusarviointimenetelmien hyödyntäminen on kirjallisuuden mukaan osoittautunut hyödylliseksi alkuvaiheen karkean kustannusarvion laadintaa varten (Niazi et al. 2006, s. 570–572). Kun tietoa alkaa olla enemmän käytettävissä, voidaan kvantitatiivisia menetelmiä hyödyntäen muodostaa tarkempia arvioita (Niazi et al .2006, s. 572).

2.3.4 Kustannuksiin vaikuttaminen projektin elinkaarella

Projektin kustannushallinnassa tulee onnistuneesti tasapainottaa projektin aikataulu sekä resurssien ja kustannusten suunnittelu. Projektin kannattavuutta voidaan arvioida

hyödyntämällä ns. elinkaarikustannuslaskelmaa, joka ottaa huomioon koko projektin elinkaaren kustannukset ja tuotot (Artto et al. 2006, s.151). Projektin kustannuksiin voidaan vaikuttaa eniten projektin alussa, määrittely- ja suunnitteluvaiheessa (Artto et al. 2006, s. 151).

Alkuvaiheessa määritellään mm. projektin laajuus, resursointi ja aikataulu, kustannusten hallinta on kriittistä juuri tässä projektivaiheessa. Sama pätee kustannusten lisäksi myös tehtäviin päätöksiin, alkuvaiheessa tehtävien päätösten lukumäärä on pienempi, mutta niiden merkitys on suurempi (Artto et al. 2006, s. 153). Esimerkiksi päätös liian alhaisesta myyntihinnasta voi aiheuttaa tappiollisen projektin, jota ei enää kyetä kuromaan kiinni toteutusvaiheessa tehtävillä päätöksillä.

Määrittely- ja suunnitteluvaiheen aikana tehtävien päätösten myötä muodostuu 60–80 % projektin aikana toteutuvista kustannuksista (Pelin 2009, s.171). Tämän vuoksi kustannusohjauksen näkökulmasta on järkevää keskittyä etenkin näihin projektin alkuvaiheessa tehtäviin päätöksiin, koska toteutusvaiheessa vaikutusmahdollisuus on huomattavasti pienempi. Kustannusarvion tarkkuuteen vaikuttavat projektin laajuuteen ja siihen liittyen riskien määrittelyn tarkkuus ja kustannusarvio tarkentuu projektin aikana (Artto et al. 2006, s. 162).

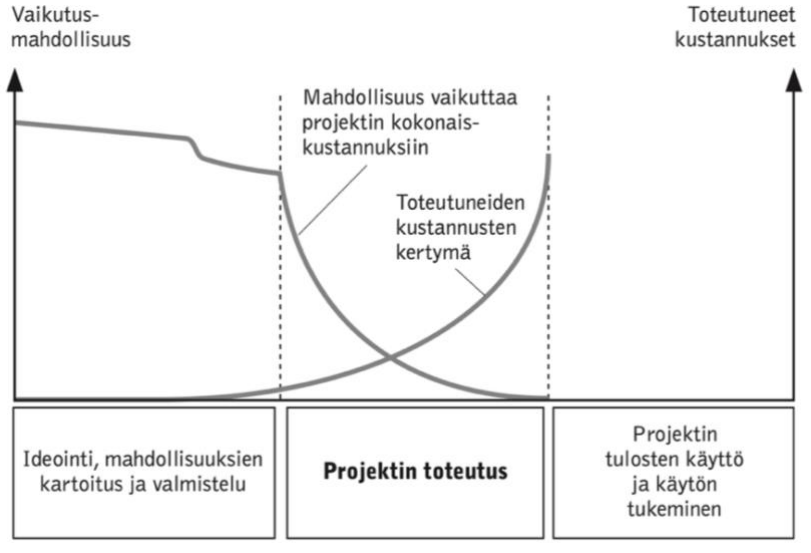

Kuva 8. Vaikutusmahdollisuus kustannuksiin ja kustannusten toteuma projektin elinkaarella (Artto et al. 2006, s. 52)

2.3.5 Kiinteähintaiset sopimukset

Projektiliiketoiminnan sopimustyypit määritellään hinnan määräytymisperusteen mukaisesti. Sopimustyypit voidaan karkeasti jakaa jatkumoon, jonka kahtena ääripäänä ovat kiinteähintaiset sopimukset ja laskutustyönä tehtävät sopimukset (Artto et al. 2006, s. 84–85).

Kiinteähintaisessa sopimuksessa toimittaja sitoutuu kiinteään hintaan, jonka puitteissa sovitun laajuinen tuotos toimitetaan tilaajalle (Artto et al 2006, s. 84). Tällöin toimittaja kantaa riskin projektin kustannuksista ja työ hinnoitellaan sisältäen oletettu kate. Tämä sopimustyyppi on tilaajalle turvallinen, mutta voi pahimmassa tapauksessa olla toimittajalle tappiollinen, jos projektia ei kyetä toimittamaan riittävän tehokkaasti.

Laskutustyössä tilanne on päinvastainen, sopimus on toimittajalle käytännössä riskitön, kun kaikki kustannukset voidaan laskuttaa tilaajalta (Artto et al. 2006, s. 85). Työn johtamiseen käytettävä työmäärä ja sen jakautuminen osapuolten kesken mukailee riskin jakautumista. Laskutustyössä tilaajan tulee panostaa merkittävästi toimittajan työn valvontaan ja johtamiseen, kun taas kiinteähintaisessa sopimuksessa toimittajan tulee taas itse panostaa työn johtamiseen, jotta se saadaan suoritettua sovitussa kehyksessä (Artto et al. s. 87)

Sopimustyyppi vaikuttaa vastuiden ja riskien jakautumiseen tilaajan ja toimittajan välillä. Kahden ääripään välinen jatkumo noudattelevat alla olevaa kuvaajaa. Tilaajan riski kasvaa siirryttäessä janalla kohti laskutustyötä, kun taas toimittajan riski kasvaa kohti kiinteähintaista sopimusta siirryttäessä.

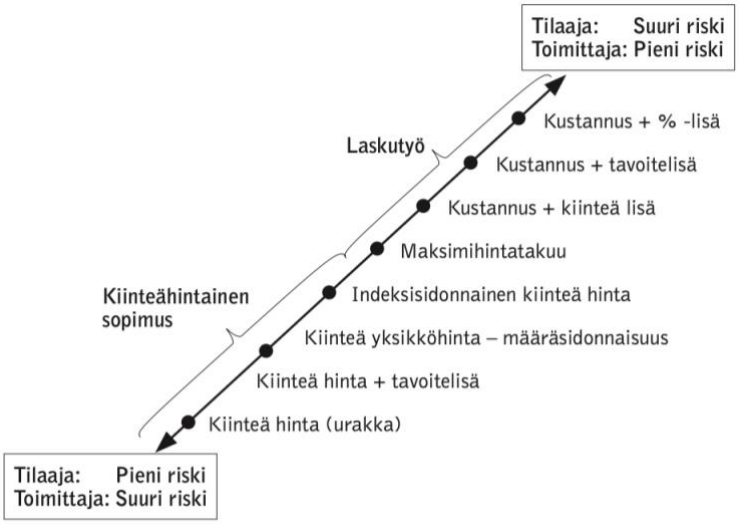

Kuva 9. Erilaisia sopimustyyppejä ja riskin käyttäytyminen (Artto et al. 2006, s. 86)

Sopimustyypin valintaan vaikuttavat mm. toimeksiannon määrittelyn täsmällisyys, käytettävissä oleva aika ja työn johtamisen jakaminen tilaajan ja toimittajan välillä (Artto et al. s. 86–87). Esimerkiksi hyvin laveasti määriteltyä toimeksiantoa ei ole järkevää tilata kiinteähintaisena, koska toimittaja joutuisi asettamaan työlle korkean hinnan, jotta siinä on riittävästi ”turvamarginaalia” huomioiden toimeksiannon epämääräisyys.

2.3.6 Projektin kannattavuus ja hinnoittelu

Hinnoittelu kuuluu oleellisena osana projektin tarjous- ja sopimusvaiheeseen ja sillä on suuri vaikutus projektin sekä yrityksen kannattavuuteen. Pienelläkin vaihtelulla hinnassa voi olla jopa 20–50 % vaikutus kannattavuuteen (Hinterhuber & Liozu 2012, s. 2).

Hinnoittelustrategiat voidaan jakaa kolmeen ryhmään (Hinterhuber 2008):

1. Kustannusperusteinen hinnoittelu
2. Kilpailuun perustuva hinnoittelu
3. Asiakkaan arvoon perustuva hinnoittelu

Kustannusperusteinen hinnoittelu tarkoittaa kustannuslaskennasta saatujen tietojen hyödyntämistä hinnan määrittelyssä. Tätä lähestymistapaa voidaan käyttää projektin tarjoushinnan arvioinnissa ja jälkilaskennassa. Kilpailuun perustuva hinnoittelu tarkoittaa ns. markkinahinnan määrittelyä hyödyntäen kilpailijoiden hintatasoa.

Asiakasarvoon perustuva hinnoittelu tarkoittaa hinnan määrittelyä asiakkaalle tuotetun lisäarvon kautta. Tutkimusten mukaan arvoon perustuva hinnoittelustrategia on muita malleja parempi, mutta se on käytännössä jäänyt melko pienelle käytölle (Hinterhuber 2008).

2.3.1 Laskentatoimen näkökulmia projektien kustannuslaskentaan

Projektien kannattavuutta ja kustannusrakennetta voidaan arvioida erilaisilla laskentamalleilla, joista käydään tässä luvussa läpi muutamia. Voiton saamiseksi tulee projekti hinnoitella siten, että tuotot ovat suuremmat kuin yritykselle aiheutuvat kustannukset. Kustannukset voivat olla muuttuvia tai kiinteitä ja ne voidaan kohdistaa projektille suoraan tai epäsuorasti, jotain parametriä hyödyntäen. (Tonchia 2008, s. 121).

Kustannuslaskennan (cost accounting) avulla voidaan määrittää paljonko tuotteen, tai tämän projektityön tapauksessa projektin, toimittaminen yritykselle tulee maksamaan (Neilimo & Uusi-Rauva 2005, s. 37).

Katetuottolaskennassa kustannukset jaetaan muuttuviin ja kiinteisiin kustannuksiin. Kun myyntituotoista vähennetään muuttuvat kustannukset, saadaan laskettua katetuotto. Katetuotosta voidaan vähentää kiinteät kustannukset, jolloin saadaan tulos (Neilimo & Uusi-Rauva (2005, s. 67). Lähtökohtana on yksinkertaistettu oletus, että muuttuvat kustannukset kasvavat lineaarisesti volyymin kasvaessa, kiinteiden kustannusten pysyessä vakiona. Malli auttaa arvioimaan kuinka suuri laskutettavan työn määrän tulee olla, jotta projektin kiinteät kulut saadaan katettua ja syntyy voittoa. Etenkin yksilöllisissä asiantuntijaprojekteissa katetuottolaskelman heikkoutena on muuttuvien ja kiinteiden kustannusten jaottelun tarkkuus (Neilimo & Uusi-Rauva 2001, s. 68).

Muita kustannuslaskennan perusmenetelmiä ovat kustannuslajilaskenta, tuotekohtainen kustannuslaskenta ja suoritekalkyylit. Kustannuslajilaskennassa kustannuksia ryhmitellään tuotannontekijöiden mukaisesti. Tuotannontekijät voidaan jakaa neljään kokonaisuuteen: työsuorituksiin, aineksiin, sekä lyhytvaikutteisiin ja pitkävaikutteisiin tuotannonvälineisiin (Neilimo & Uusi-Rauva 2005, s. 84). Tuotekohtaisessa kustannuslaskennassa tuotteen tai palvelun kustannukset kohdistetaan suoritteelle aiheuttamisperiaatetta hyödyntäen (Neilimo & Uusi-Rauva 2005, s. 108–109). Palveluliiketoiminnan tapauksessa on aineeton palvelusuorite kyettävän määrittämään riittävän tarkasti ja työn kustannusosuus on myös merkittävä (Neilimo & Uusi-Rauva 2005, s. 109).

Suoritekalkyyleissä kustannukset jaetaan muuttuviin ja kiinteisiin kustannuksiin. Yhteiset kustannukset voidaan kohdistaa aiheuttamisperiaatetta hyödyntämällä (Neilimo & Uusi-Rauva 2005 s. 116). Erilaisia suoritekalkyylityyppejä ovat minimikalkyyli, keskimääräiskalkyyli ja normaalikalkyyli. Minimikalkyyli huomioi vain muuttuvat kustannukset ja keskimääräis- ja normaalikalkyylit kohdistavat myös kiinteät kustannukset eri tavoin riippuen toiminta-asteesta. Nämä laskentamenetelmät soveltuvat parhaiten tuotantoon ja voivat olla sovellettavissa myös projektimuotoiseen suunnittelutyöhön, riippuen mittarien ja tietojärjestelmien tasosta.

Toimintoperusteisessa kustannuslaskennassa (Activity-Based Costing) kustannukset kohdistetaan ensin resursseille, sitten resursseja hyödyntävälle toiminnolle ja lopulta

projektille. (Tonchia 2008, s.123–125, Neilimo & Uusi-Rauva 2005, s. 145). Malli mahdollistaa toimintojen ja projektien välisen resurssien käytön ja kustannustehokkuuden vertailun, joten se voi sopia erityisesti asiantuntija- ja palveluliiketoimintaan. Toiminnot voidaan jakaa perus- ja tukitoimintoihin ja niitä voidaan edelleen jakaa useampaan toimintotasoon (Neilimo & Uusi-Rauva 2005, s. 150). ABC-laskenta voi olla hyödyllinen mm. kustannusten tarkempaan kohdistamiseen, asiakasarvon analysointiin ja sisäisen toiminnan tehostamiseen.

3 Tekoäly ja työmäärän ennustaminen

3.1 Tekoälyn määritelmät ja siihen liittyvät teknologiat

Generatiivisen tekoälyn (Generative AI) kaupalliset sovellukset ovat saanet aikaan laajan tekoälybuumin noin vuodesta 2022 lähtien. Nämä suuriin kielimalleihin perustuvat teknologiat voivat tulevaisuudessa vaikuttaa laajasti eri ammatteihin ja työnkuviin (Eloundou et al. 2024). Diplomityön aiheen näkökulmasta on kiinnostavaa, miten nämä vaikutukset voivat heijastua arkkitehtisuunnittelun kaltaiseen vaativaan asiantuntijatyöhön ja projektiliiketoimintaan.

Tekoälyjärjestelmät ovat käytännössä yhdistelmä eri teknologioita ja niiden tyypit vaihtelevat riippuen tehtävästä, johon ne on suunniteltu (SAP n.d.). Euroopan komissio jakaa tekoälyn kahteen eri muotoon: ohjelmistoihin, kuten esimerkiksi virtuaaliset avustajat sekä ruumiillistettuun tekoälyyn, kuten esimerkiksi itseohjautuvat autot (Euroopan parlamentti 2020). Tässä luvussa käydään läpi tekoälyn, koneoppimisen ja syväoppimisen yleisperiaatteet, joihin myös generatiivinen tekoäly perustuu.

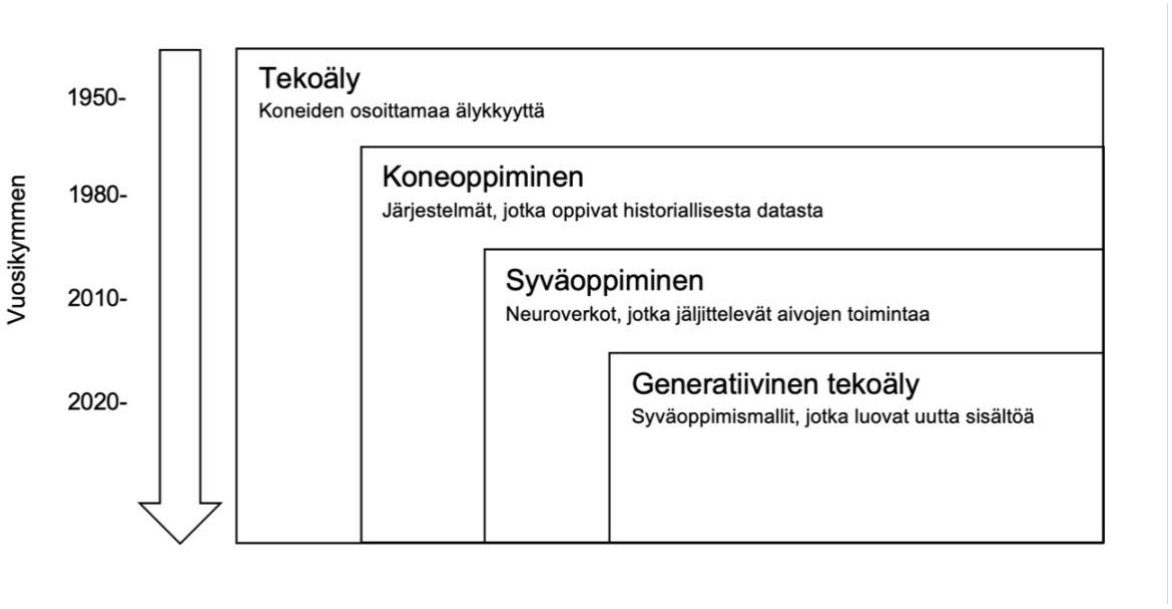

Kuva 10. Tekoälyn osa-alueiden liittyminen toisiinsa (mukaillen Rankovic et al. 2024, s. 10, IBM 2024b)

3.1.1 Tekoäly

Tekoäly (Artificial Intelligence, AI) on tietojenkäsittelytieteen osa-alue, joka keskittyy älykkään käyttäytymisen automatisointiin (Chowdhary 2020, s. 1). Tässä työssä tekoälyllä tarkoitetaan järjestelmää, joka kykenee tunnistamaan tiedossa olevia yhteyksiä, tekemään päätöksiä ja ratkaisemaan ongelmia (Rankovic et al. 2024, s. 4). Tekoälyjärjestelmillä voidaan suorittaa inhimillistä älykkyyttä vaativia tehtäviä ja niitä voidaan hyödyntää käytännössä esimerkiksi päättelyssä, suunnittelussa, oppimisessa, ongelmanratkaisussa, visuaalisessa hahmottamisessa ja kielen käsittelyssä (Chowdhary 2020, s. 10, IBM 2024b., Google Cloud n.d.a).

Tekoäly voidaan käsitteellisesti jakaa kapeaan tekoälyyn (Weak AI), yleiseen tekoälyyn (Strong AI) sekä supertekoälyyn (Artificial Superintelligence ASI). Kapea tekoäly tarkoittaa tekoälyä, joka on rakennettu suorittamaan tiettyä tarkkaan rajattua tehtävää, kuten pelaamaan shakkia tai vastaamaan ihmisen esittämään kysymykseen (IBM 2023a). Yleinen tekoäly on vielä teoreettinen konsepti, joka tarkoittaa tekoälyä, jolla on ihmisen kaltaista älykkyyttä ja se kykenee ratkaisemaan useita erilaisia ongelmia. Supertekoäly on toinen vielä toistaiseksi teoreettinen tekoälyn muoto, joka ylittäisi ihmisen kyvyt (IBM 2021).

3.1.2 Koneoppiminen

Koneoppiminen (Machine Learning, ML) on tekoälyn osa-alue, joka keskittyy algoritmeihin, joiden avulla koneet voivat tehdä ennusteita ja päätöksiä datan pohjalta. Tämä tapahtuu ilman, että niitä tarvitsee erikseen ohjelmoida kutakin tehtävää varten. Oppiminen perustuu tilastollisiin algoritmeihin, viritettäviin parametreihin ja datasta oppimiseen (VanderPlas 2016a, Telivuo 2018, s. 5). Oppimiskyky voidaan nähdä älykkään käyttäytymisen yhtenä perustekijänä, joten koneoppiminen on keskeinen osa tekoälyn tieteenalaa (Chowdhary 2020, s. 377). Koneoppimisen menetelmien soveltamista laajoihin datamääriin kutsutaan datalouhinnaksi (Alpaydin 2014, s. 2).

Koneoppiminen on hyvä tehtävissä, joissa täsmällisen jos-niin ohjeketjun kirjoittaminen on vaikeaa tai mahdotonta (Telivuo 2018, s. 5). Käytännössä koneoppimiseen perustuvia malleja hyödynnetään laajasti mm. konenäössä, suurissa kielimalleissa ja puheen tunnistuksessa (IBM 2023b). Koneoppimisen menetelmät jaetaan kolmeen pääkategoriaan

(Kananen & Puolitaival 2019 s. 44, VanderPlas 2016a): ohjattuun oppimiseen (supervised learning), ohjaamattomaan oppimiseen (unsupervised learning) ja vahvistusoppimiseen (reinforcement learning).

Ohjattu oppiminen tarkoittaa, että algoritmia opetetaan esimerkkiaineistolla, jossa tietojoukko on luokiteltu. Tällöin tavoitteena on oppia tunnistamaan yleistettävä sääntö datan pohjalta. (IBM 2023b, Google Cloud n.d.b). Ohjattua oppimista sovelletaan yleisesti esimerkiksi kuvantunnistuksessa ja ennakoivassa analytiikassa. Se sisältää useita erilaisia algoritmeja, kuten regressio-, luokittelu- ja satunnaismetsäalgoritmit sekä naiivi Bayesin luokitin ja neuroverkot (IBM 2023b).

Ohjaamaton oppiminen tarkoittaa menetelmä, jossa algoritmi etsii nimeämättömästä datasta rakenteita ja säännönmukaisuuksia ilman erityisiä ohjeita (Google Cloud n.d.b). Yksi yleisimmistä menetelmistä on klusterointi, jossa algoritmi ryhmittelee havaintoja arvojen samankaltaisuuden perusteella. Klusterointiin on eri menetelmiä, kuten K-means-klusterointi, hierarkkinen klusterointi ja todennäköisyyspohjainen klusterointi (IBM 2023b). Vahvistusoppimisessa ohjelma oppii tekemän päätöksiä dynaamisessa ympäristössä tavoitellessaan ennalta määriteltyä tavoitetta, yritykseen ja erehdykseen perustuvassa oppimisprosessissa. Agenttia palkitaan ja rankaistaan mittareiden perusteella, joka kannustaa sitä jatkamaan toimivia käytäntöjä ja hylkäämään huonot (Amazon Web Services n.d.a).

3.1.3 Neuroverkot

Neuroverkot ovat koneoppimisen muoto, joka muistuttaa ihmisaivojen toimintaa. Ne koostuvat toisiinsa kytketyistä neuroneista, jotka käsittelevät tietoa painotettujen yhteyksien kautta (Rankovic et al. 2024, s. 33). Neuronit on järjestetty useaan eri kerrokseen: syöte-, piilo- ja ulostulokerroksiksi (Merilehto 2018, s. 51–52). Neuroverkot pystyvät oppimaan tunnistamaan monimutkaisia rakenteita suurista tietomääristä, ja tässä keskeistä on painokertoimien säätäminen harjoittelun aikana.

Nykyisin käytössä olevan neuroverkkopohjaiset oppimisalgoritmit vaativat yleensä ihmisen osallistumista ja perustuvat ohjattuun oppimiseen (Chowdhary 2020, s. 431). Neuroverkkoja hyödynnetään laajasti eri sovelluksissa, kuten puheentunnistuksissa ja luonnollisen kielen käsittelyssä (Amazon Web Services n.d.c, IBM n.d.b). Projektinhallintaan liittyviä neuroverkkopohjaisia sovelluksia on jo olemassa mm. projektin keston, riskin ja suorituskyvyn ennustamiseksi (Rankovic et al. 2024, s. 34).

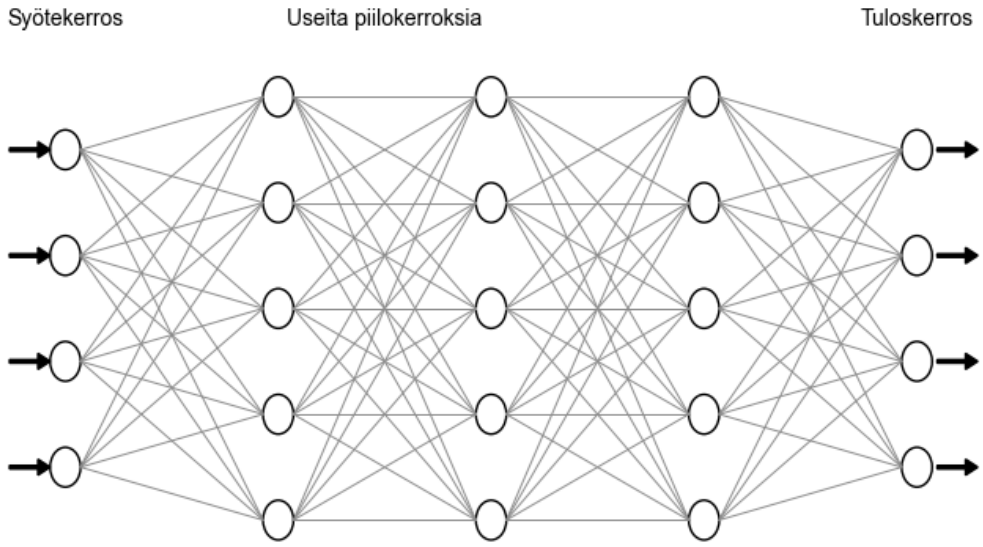

Kuva 11. Syvän neuroverkon toimintaperiaate (mukaillen Rankovic et. al. 2024, s. 36, IBM n.d.b)

3.1.4 Syväoppiminen

Syväoppiminen on koneoppimisen osa-alue, joka hyödyntää useista kerroksista koostuvia syviä neuroverkkoja, jäljitellen näin ihmisaivojen kompleksista päätöksentekoa. Syväverkot sisältävät satoja kerroksia, joka mahdollistaa suurten merkitsemättömien aineistojen automaattisen tulkinnan ohjaamatonta oppimista hyödyntäen. Syväoppiminen soveltuu erityisesti tehtäviin, joissa tarvitaan nopeaa monimutkaisten rakenteiden tunnistamista, kuten esimerkiksi luonnollisen kielen käsittely tai konenäkö (Chowdhary 2020, s. 436, IBM 2024b).

Konvoluutioverkot (Convolutional Neural Network) ovat neuroverkkoja, jotka ovat erityisen hyvä esimerkiksi kuvien lukemiseen, mutta voivat olla sovellettavissa myös esimerkiksi projektin keston arviointiin (Rankovic et al. 2024, s. 37) Rakenteellisesti ne

eroavat muista neuroverkoista siten, että kaikkien kerrosten neuronit eivät ole yhteydessä kaikkiin toisen kerroksen neuroneihin (Merilehto 2018, s. 53). Konvoluutioverkkojen rakenne on saanut inspiraatiota näköaivokuoren monikerroksisesta rakenteesta, joka vastaanottaa visuaalisen syötteen silmästä (Chowdhary 2020, s. 436).

3.1.5 Generatiivinen AI

Generatiivinen tekoäly (Generative AI) viittaa syväoppimismalleihin, jotka pystyvät tuottamaan uutta sisältöä, kuten tekstiä, kuvia, ääntä ja videota, käyttäjän ohjelmalle antamien kehotteiden perusteella. Mallit oppivat tunnistamaan koulutusaineistostaan olennaiset piirteet ja hyödyntävät tätä tietoa luodakseen uutta samankaltaista sisältöä (IBM 2024b).

Generatiivisen tekoälyn nopea kehitys viime vuosikymmenen aikana on ollut mahdollista etenkin kolmen keskeisen syväoppimismallityypin ansiosta: vaihtelevat automaattiset kooderit, diffuusiomallit sekä erityisesti transformer-mallit, jotka ovat useiden nykyisten kaupallisten tekoälysovellusten, kuten ChatGPT:n, Copilotin ja Midjourneyn ytimessä (IBM 2024b, Amazon Web Services n.d.b).

Generatiivinen tekoäly toimii tyypillisesti kolmessa vaiheessa. Ensin perusmalli koulutetaan laajalla määrällä dataa, sitten se mukautetaan käyttötarkoitukseensa ja lopuksi sisältöä generoidaan ja arvioidaan mallin hienosäätämiseksi (IBM 2024b). Perusmalli on usein suuri kielimalli (LLM), joka luodaan kouluttamalla syväoppimisalgoritmia valtavalla määrällä jäsentelemätöntä dataa, kuten esimerkiksi tekstillä ja kuvilla internetistä.

Koulutuksen tuloksena syntyy neuroverkko, jolla on todella suuri määrä parametreja, joka oppii tunnistamaan tiedon rakenteita ja joka kykenee tuottamaan sisältöä itsenäisesti sille annettujen kehotteiden pohjalta. Kun perusmalli on koulutettu, se voidaan virittää tiettyyn tehtävään. Tämä voidaan toteuttaa joko hienosäätämällä tai vahvistusoppimisen avulla (IBM 2024b).

3.1.6 Agenttimainen tekoäly

Agenttimainen tekoäly (Agentic AI) tarkoittaa tekoälyä, joka voi tehdä päätöksiä ja suorittaa tehtäviä ilman ihmisen puuttumista (IBM 2024b). Agentti on tietokonejärjestelmä, joka on jossakin ympäristössä ja osaa havaita ja toimia itsenäisesti kyseisessä ympäristössä tavoitteidensa saavuttamiseksi (Chowdhary 2020, s. 471). Erona generatiiviseen tekoälyyn on se, että nämä järjestelmät voivat oppia palautteesta ja tekemistään havainnoista sekä muuttaa toimintaansa uuden tiedon pohjalta. Joidenkin ennusteiden mukaan vuoteen 2028 mennessä 15 % työssä tehtävistä päätöksistä tehdään autonomisten agenttien toimesta (Salesforce 2024).

Tulevaisuudessa agenttimainen tekoäly voi muuttaa työtä huomattavasti. Rutiininomaisten tehtävien automatisointi ja hajautettujen agenttien itsenäinen päätöksenteko voivat lisätä huomattavasti tuottavuutta ja innovatiivisuutta työpaikoilla. Erityisen kiinnostavaa on, että miten agenttimainen tekoäly saadaan turvallisesti integroitua osaksi yritysten dataa ja tietokantoja, sillä juuri näihin tietoihin pääsy ja niiden hyödyntäminen on kyseisen teknologian arvon luomiseen liittyvän potentiaalin ytimessä.

3.2 Tekoälyn hyödyntäminen organisaatioissa

Yrityksen nykyinen kulttuuri, toimintamallit ja datakyvykkyys vaikuttavat siihen, miten onnistuneesti tekoälyä kyetään hyödyntämään (Kananen & Puolitaival 2019 s. 55). Tekoälyn käyttöönotossa on tällä hetkellä ”tekoälykuilu” edelläkävijöiden ja keskiverto-organisaatioiden välillä, jonka ylittäminen vaatii panostuksia teknologiaan ja henkilöstön osaamiseen (Savolainen 2024, s. 74).

Everett Rogersin innovaatioteorian mukaan uudet teknologiat, kuten tekoäly, otetaan aluksi käyttöön vain harvojen edelläkävijöiden toimesta (Savolainen 2024, s. 74). Alkuvaiheessa käyttö laajenee hitaasti ja vasta kun suurempi joukko eli ns. varhainen enemmistö kiinnostuu teknologiasta, alkaa nopeamman kasvun vaihe. Myöhemmin kasvu alkaa jälleen hidastua, kun tekoälyratkaisujen käyttö on yleistynyt toimialan standardiksi ja myöhäinen enemmistö siirtyy teknologian käyttäjiksi.

Tekoälyn suorituskykyyn vaikuttaa ensisijaisesti datan määrä. Kiinnostavana huomiona on se, että koneoppimisen menetelmät saavuttavat melko nopeasti pisteen, jonka jälkeen lisädata ei enää merkittävästi paranna mallin suorituskykyä. Sen sijaan syväoppimismallit ja niiden ennustetarkkuus paranee datan määrän lisääntyessä (Kananen & Puolitaival 2019, s. 62).

Tekoälyteknologiat tarjoavat tehokkaita työkaluja suurten tietomäärien analysointiin. Organisaatioiden tulisi kehittää teknistä kyvykkyyttään datan hyödyntämisessä. Tekoälyn arvo syntyy vasta, kun sille syötetään laadukasta dataa ja kun analyysistä saatuja tuloksia voidaan soveltaa käytännön päätöksenteossa (Savolainen 2024 s. 96–98).

3.2.1 Tekoäly osana liiketoimintastrategiaa

Porterin mallin mukaan yrityksen kilpailuetu perustuu kolmeen vaihtoehtoiseen suuntautumiseen: kustannusjohtajuus, erikoistuminen tai keskittyminen (Porter 1985). Tekoäly tarjoaa strategisia mahdollisuuksia liiketoiminnan uudistamiseen (Ruokonen, Mero, Ritala 2024). Tekoälyn sisällyttäminen yrityksen liiketoimintastrategiaan vaatii yrityskohtaista ja yksilöllistä lähestymistapaa. (Savolainen 2024, s. 151). Tekoälyn hyödyntämistä yrityksessä voidaan tarkastella neljän lähestymistavan kautta (Ruokonen, Mero, Ritala 2024):

1. Evoluutiostrategia (tekoälyosaamisen rakentaminen vaiheittaisesti ja toimintamallin muuttaminen vähitellen)
2. Parantelustrategia (tekoälyn hyödyntäminen nykyisten prosessien optimointiin ja tehostamiseen)
3. Laajentumisstrategia (uusien liiketoimintamahdollisuuksien ja palvelumallien löytäminen tekoälyn avulla)
4. Murrosstrategia (toiminnan mullistaminen tekoälyn avulla)

Tekoälyn sisällyttäminen osaksi yrityksen liiketoimintaa vaatii strategista arviointia sekä toimintaympäristön ja omien resurssien huomiointia (Ruokonen, Mero, Ritala 2024). Tekoälystrategiaa suunniteltaessa on tärkeää tunnistaa ne ajurit, jotka ohjaavat tekoälyn käyttöönottoa liiketoiminnan näkökulmasta. Onko tekoälyjärjestelmien käyttöönoton

tavoitteena esimerkiksi sisäisten kustannusten alentaminen, asiakasarvon lisääminen vai datan tehokkaampi hyödyntäminen (Savolainen 2024, s. 167). Tekoälyn hyödyntämisen tulee toisin sanoen olla linjassa liiketoiminnan tavoitteiden kanssa.

3.2.2 Datan laadun merkitys

Tekoälyjärjestelmän käytössä olevan datan laatu vaikuttaa järjestelmän tehokkuuteen (Kontio & Puttonen 2024). Yrityksen, joka haluaa hyödyntää tekoälyä ja dataa kannattaakin sisällyttää datan laadun ja hallinnan kehittäminen osaksi strategiaa. Tämä edellyttää datan laadun jatkuvan parantamisen asettamista systemaattiseksi tavoitteeksi.

Datan laadun merkitys korostuu tekoälyn ja koneoppimisen onnistuneessa hyödyntämisessä (Redman 2018). Virheellinen data aiheuttaa vastaavasti vääristymiä koneoppimista hyödyntävän mallin ennusteissa. Liiketoiminnan kannalta tekoälyratkaisuilla saavutettu lisäarvo on riippuvaista datan ja sen hallinnan laadusta. Datan laadulle on kehitetty oma ISO-standardinsa ISO 8000-8:2015 (ISO 2022).

Yrityksissä muodostuu sekä strukturoitua että strukturoimatonta dataa suuria määriä (Bhansali 2013). Valtaosa datasta on strukturoimatonta ja sen hyödyntäminen on vaikeampaa kuin strukturoidun. Semistrukturoitu data tarkoittaa strukturoimatonta dataa, johon on liitetty metatietoa (Salo 2013).

Datasta muodostuvan informaation, tiedon ja viisauden välistä suhdetta voidaan kuvata DIWK-pyramidilla, joka kuvaa näiden välistä hierarkkista suhdetta (Rowley 2007). Tässä mallissa jokaisella pyramidin tasolla syntyy lisäarvoa edelliseen tasoon nähden ja ylemmät tasot ovat kaikki riippuvaisia alimmasta datan tasosta.

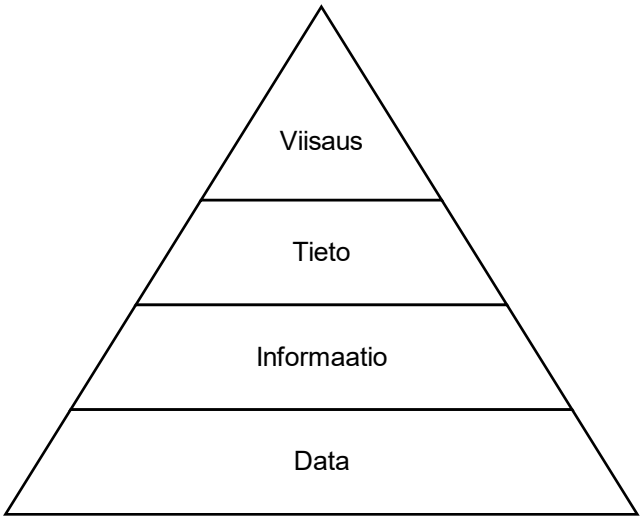

Kuva 12. DIWK-pyramidi (mukaillen Rowley 2007)

Yrityksen operatiivisesta toiminnasta syntyy paljon dataa, josta usein vain pieni osa päätyy hyödynnettäväksi. Datan hallinnan, analysoinnin ja viestinnän puutteet estävät usein sen täysimittaista hyödyntämistä. Parhaiten tekoälyratkaisuista hyötyvät organisaatiot, jotka pystyvät käyttämään dataa monipuolisesti eri päätöksenteon tasoilla (Kananen & Puolitaival 2019, s. 76).

Data voidaan nähdä omaisuuseränä ja sen laatu liittyy suoraan yrityksen arvoon. Datan laadun parantamisen voidaan hyödyntää laatu- ja prosessijohtamisen oppeja. (Redman 1995). Tekoälyratkaisut vaativat kehittynyttä datan hyödyntämistä ja henkilöstön luottamusta dataan. Tekoälyn käyttöönotto voi olla haastavaa teknisesti ja asenteellisesti, jos yrityksessä ei ole pohjalla dataperustaista toimintakulttuuria. Tämän vuoksi datan hyödyntäminen kannattaakin aloittaa visuaalisesta analytiikasta, joka valmentaa organisaatiota kohti dataohjautuvaa päätöksentekoa (Kananen & Puolitaival 2019, s. 76–78).

Yrityksessä käytettävissä oleva data voi olla peräisin monista eri lähteistä. Ensimmäisen osapuolen dataksi (first-party data) kutsutaan yrityksen itse luomaa dataa, kuten esimerkiksi asiakasrekisterien, talousraporttien, myyntilukujen, anturien jne. kautta syntyvä. Toisen osapuolen data (second-party data) taas tarkoittaa yhteistyökumppaneilta saatavaa dataa. Kolmansien osapuolten datalähteet (third-party data) tarkoittaa julkisia datalähteitä (Kananen & Puolitaival 2019, s. 83–84).

Tekoälyn kouluttamiseen tarvittavan datamäärän suuruus riippuu siitä, mitä ongelmaa ollaan ratkaisemassa. Mitä monimutkaisempi ongelma ja mitä suurempi vaihtelu ilmiössä on, niin sitä enemmän dataa tarvitaan (Kananen & Puolitaival 2019).

Yli- ja alisovittaminen ovat tekoälymallin laadun kannalta keskeisiä käsitteitä ja ne kuvaavat kahta ääripäätä datan sovittamisesta. Alisovittaminen tarkoittaa tilannetta, jossa malli on liian yksinkertainen eikä se kykene tunnistamaan datasta olennaisia piirteitä. Malli toisin sanone yleistää liikaa, jonka vuoksi sen suorituskyky jää heikoksi. Ylisovittaminen taas tarkoittaa tilannetta, jossa malli on liian monimutkainen ja ”oppii ulkoa” koulutusdatasta epäolennaisia asioita, kuten kohinaa. Malli toimii hyvin harjoitusaineistolla, mutta ennusteet epäonnistuvat uusilla aineistoilla (Kananen & Puolitaival 2019, s. 101). Tavoitteena on löytää tasapaino näiden kahden ääripään välillä, siis malli, joka toimii luotettavasti todellisessa käyttötarkoituksessaan.

3.3 Regressioalgoritmit

Koneoppiminen perustuu algoritmeihin, jotka käsittelevät dataa eri tavoin. Nämä algoritmit on mahdollista jakaa viiteen luokkaan (Kananen & Puolitaival 2019 s. 113): regressio-, luokittelu-, ryhmittely-, sijoitus- ja generaatioalgoritmeihin. Regressioalgoritmeilla voidaan mallintaa ja ennustaa numeeristen muuttujien välistä yhteyttä x-y-koordinaatistossa. Lineaarinen regressio ja satunnaismetsä (random forest) ovat molemmat yleisesti käytettyjä regressioalgoritmeihin perustuvia ennustemalleja, jotka eroavat toisistaan toimintalogiikaltaan.

Lineaarinen regressio olettaa, että muuttujien ja ennustettavan muuttujan välillä on suora yhteys, joiden välille voidaan sovittaa kulkemaan suora (Kämäräinen 2023, s. 20). Malli on nopea käyttää, mutta edellyttää tilastollisten ehtojen täyttymistä, esimerkiksi että myös virheet ovat normaalisti jakautuvia ja muuttujat eivät ole keskenään voimakkaasti riippuvaisia. Lineaarinen regressio on yksi yleisimmin käytetyistä koneoppimisalgoritmeista (Rankovic et al. 2024, s. 10).

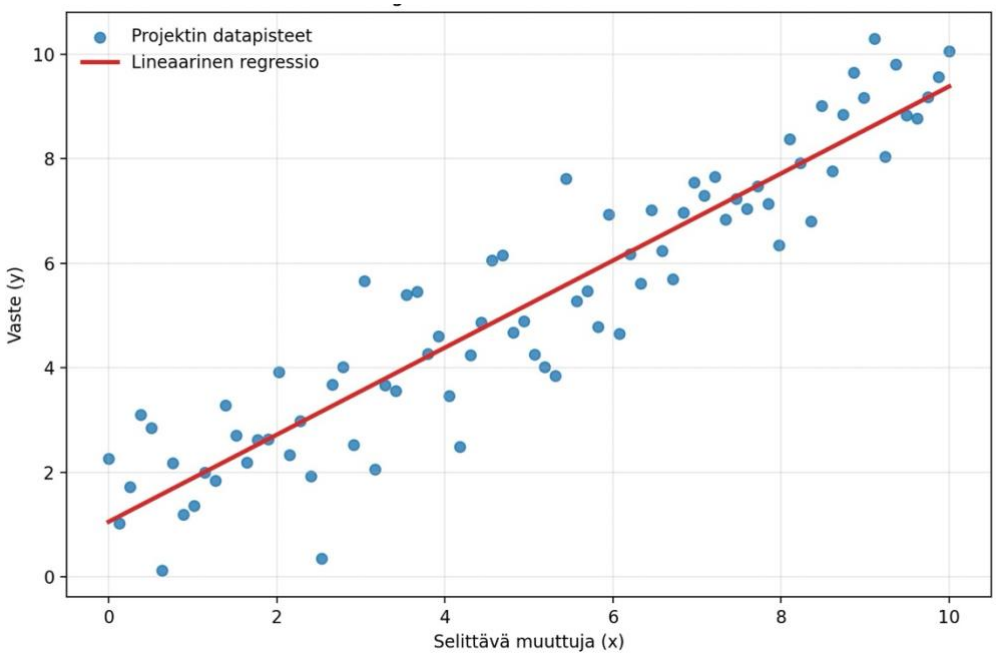

Kuva 13. Yksinkertainen esimerkki lineaarisesta regressiosta (mukaillen VanderPlas 2016a)

3.3.1 Satunnaismetsä

Satunnaismetsä on päätöspuihin perustuva luokittelumalli, joka koostuu lukuisista päätöspuista, joiden ennusteet yhdistetään tulokseksi. Jokainen puu käyttää satunnaisesti valittua lähtödatan osajoukkoa ja menetelmä kykenee mallintamaan monimutkaisia ei-lineaarisia suhteita (Rankovic et al. 2024, s. 20). Satunnaismetsä on usein lineaarista regressiota tarkempi monimutkaisessa datassa ja tutkimuksen mukaan satunnaismetsä onkin paras luokittelumalli sen tarkkuuden vuoksi (Telivuo 2018, s. 4) Satunnaismetsän etuna ovat myös se, että sen toimintaperiaate on suhteellisen helposti ymmärrettävissä ja se on myös melko immuuni lähtödatan kohinalle (Telivuo 2018, s. 40–41).

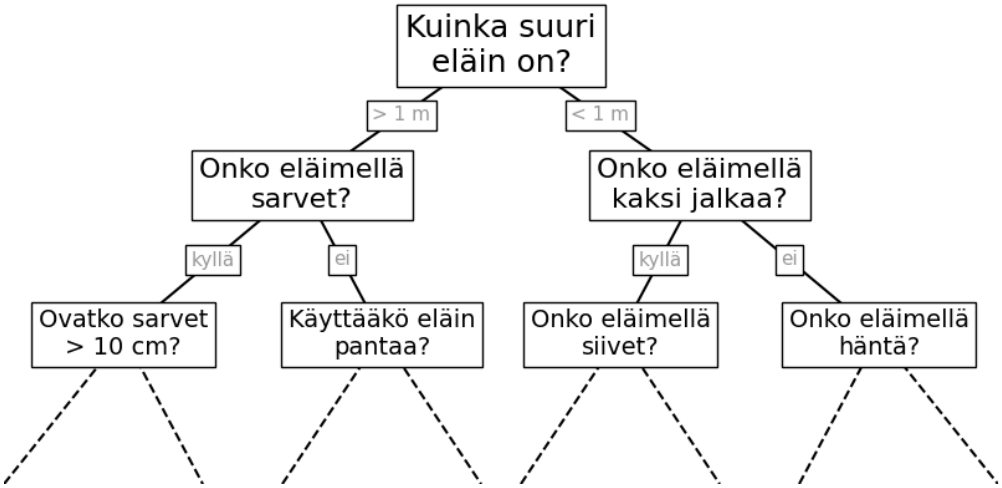

Kuva 14. Esimerkki yksinkertaisesta päätöspuusta (mukaillen VanderPlas 2016a)

Satunnaismetsä-algoritmi hyödyntää lukuisia päätöspuita rinnakkain ja sitä voidaan hyödyntää regressio- ja luokitteluongelmien ratkaisemiseen (IBM n.d.a). Menetelmän etuna on se, että sen koulutus ja ennustaminen on todella nopeaa taustalla toimivien päätöspuiden yksinkertaisuuden takia (VanderPlas 2016a). Päätöspuiden potentiaalisena haittapuolena on ns. ylioppiminen (Kämäräinen 2023, s. 147). Kun useasta päätöspuusta muodostetaan satunnaismetsä, on niiden ennusteet kuitenkin tarkempia, varsinkin jos yksittäiset puut eivät korreloi keskenään (IBM n.d.a). Satunnaismetsäalgoritmissa on kolme pääasiallista parametria: solmun koko, puiden lukumäärä ja hyödynnettävien ominaisuuksien lukumäärä.

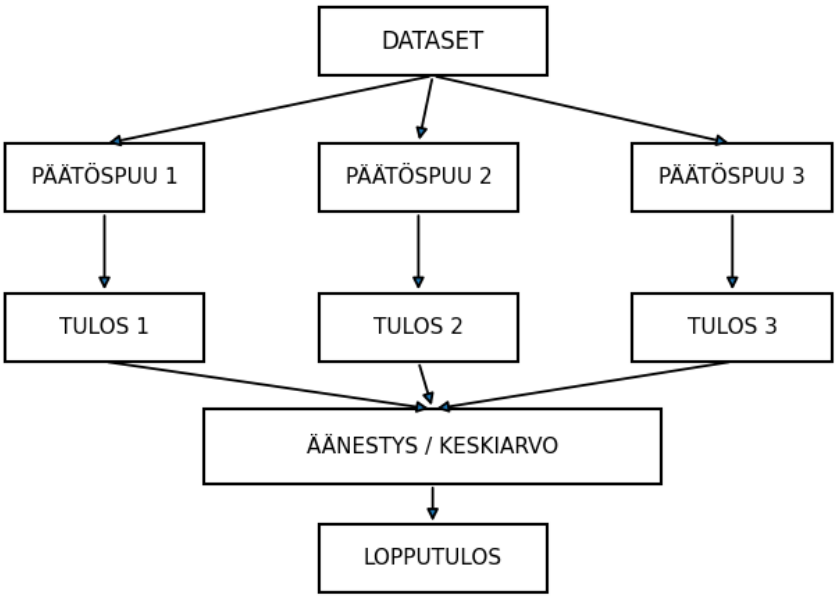

Kuva 15. Esimerkki yksinkertaisesta satunnaismetsä-mallista (mukaillen VanderPlas 2016a)

Arvioidessa satunnaismetsäalgoritmin soveltuvuutta arkkitehtisuunnitteluun, voidaan vertailukohdaksi ottaa rakennushankkeiden kustannusten ennustaminen. Satunnaismetsä ja gradientin tehostamisen menetelmien yhdistelmä on osoittautunut tarkemmaksi kuin muut koneoppimismenetelmät rakennushankkeiden kustannusarvioinnin puolella (Habib 2025). Tämä tulos vahvistaa oletusta mallin soveltuvuudesta myös arkkitehtisuunnittelun työmääräennustamiseen. Muita mahdollisia menetelmiä rakennusalan puolelta ovat neuroverkot ja hybridimallit (Cheng et al. 2025)

3.4 Parametrisen kustannusarvioinnin edut asiantuntija-arvioon verrattaessa

Asiantuntija-arvioon perustuva ennustaminen on menetelmä, joka perustuu vastaavanlaisen projektin kanssa työskennelleen asiantuntijan kokemukseen. Menetelmää käytetään sen yksinkertaisuuden ja nopeuden vuoksi monella alalla, kuten myös arkkitehtisuunnittelussa. Malli voi johtaa tehokkaaseen ja luotettavaan arviointiin, jos arvioitavan ja aikaisempien projektinen välillä on selkeitä analogioita (Rankovic et al. 2024, s. 295). Asiantuntija-arviot ovat kuitenkin aina subjektiivisia ja tulokset voivat vaihdella henkilökohtaisista kokemuksista, mielipiteistä, intuitiosta ym. johtuen.

Dataan perustuvat kustannusarviointimenetelmät taas perustuvat laskennallisiin algoritmeihin, kuten esimerkiksi työmäärän ja kustannusten arviointi projektin koon pohjalta. Arviointimenetelmällä on useita etuja, mm. nopeus, objektiivisuus ja helppokäyttöisyys. Näistä objektiivisuus on yksi tärkeimmistä, kun projektin työmäärän tai kustannusten arviointi perustuu numeerisiin arvoihin ja analyysiin (Rankovic et al. 2024, s. 295). Kun malli on kerran saatu rakennettua, voidaan sitä nopeasti käyttää seuraavan kohteen arviointiin hitaamman empiirisen arvioinnin sijasta. Tämä edellyttää kuitenkin historiallisen datan saatavuutta ja kattavuutta, jotta algoritmin antamat arviot ovat luotettavia.

Tekoälyyn perustuvat menetelmät vaikuttavat parantavan projektien kustannusarvioinnin ennustetarkkuutta. Regressiomallit suoriutuvat kustannusarviointitehtävistä n. 70–80 % ennustetarkkuudella, kun vastaava luku koneoppimismallien osalta on n. 75–80 % ja syväoppimismallien osalta n. 85–90 %. Hybridimallit saavuttivat keskimäärin 80–90 % tarkkuuden (Shamim et. al 2025). Korkein luotettavuus saavutetaan siis hybridi- ja syväoppimismalleilla, mutta regressio- ja koneoppimismallit tarjoavat edelleen luotettavia tuloksia etenkin tarkoin määriteltyihin tehtäviin.

4 Nykytila kohdeyrityksessä ja projektidatan hyödyntäminen

4.1 Tutkimusprosessin empiirinen osuus

Diplomityön taustana toimii samassa kohdeorganisaatiossa tehty toimitusketjun projektityö. Projektityön alussa kohdeyrityksen toimitusjohtaja pohjusti toimeksiantoon liittyvää problematiikkaa, joka liittyi siihen, että kiinteähintaisten projektien kannattavuudessa on ollut yrityksessä vaihtelua. Mukana keskustelussa olivat myös talousjohtaja ja Helsingin aluejohtaja. Sovittiin, että kiinteähintaisten töiden kustannusohjauksen tilannetta kartoitetaan tarkemmin haastatteluiden avulla.

Haastattelut pidettiin yrityksen avainhenkilöiden kanssa alkuvuoden 2025 aikana. Niissä haastateltiin Helsingin yksikön aluejohtajaa, Tampereen yksikön operatiivista johtajaa, Helsingin yksikön projektilaatupäällikköä sekä eri yksiköiden operatiivista tarjoustoimintaa tekeviä henkilöitä. Haastatteluissa saadun tiedon perusteella muodostettiin kuva kiinteähintaisten töiden kustannusohjauksen nykytilasta ja tunnistettiin haastavaksi koettuja aihealueita. Haastateltujen henkilöiden mainitsemat havainnot koottiin yhteen ja esitettyjä näkemyksiä vertailtiin keskenään kattavan kokonaiskuvan muodostamiseksi.

Projektityön loppuraportin viimeistelyn yhteydessä kävin keskusteluja uudestaan kohdeorganisaation edustajien kanssa. Toimitusjohtaja ehdotti, että diplomityön aihe voisi syventää samaa teemaa, mutta sisällyttää mukaan myös tekoälyn hyödyntämisen näkökulmaa.

4.2 Toiminnanohjausjärjestelmä

Kohdeyrityksessä on käytössä toiminnanohjausjärjestelmänä Visma Severa, joka on pilvipohjainen ja erityisesti asiantuntijatyön ja projektiliiketoiminnan johtamiseen suunniteltu. Severa yhdistää keskeiset liiketoiminnan prosessit yhdeksi järjestelmäksi, mahdollistaen mm. projektinhallinnan, asiakkuuksien hallinnan (CRM), resurssien suunnittelun, työajanseurannan, laskutuksen ja raportoinnin (Visma 2025). Lisäksi Severa

on mahdollista integroida usean muun järjestelmän, kuten Netvisorin, Zapierin ja Microsoftin ohjelmistojen kanssa.

Myyntiprosessin etenemistä hallitaan kohdeyrityksessä Severan myyntiputken kanban-näkymän avulla. Myyntiputkeen on tehty myyntityön etenemistä noudattelevat neljä vaihetta. Kun myyntityö merkitään tilatuksi, luo Severa siitä automaattisesti projektityön, jota voidaan käyttää projektin resursointiin ja johtamiseen. Järjestelmä siis tukee hyvin jouhevaa siirtymistä myyntityöstä projektiksi.

Myyntiputkeen kirjattujen myyntitöiden euromääräiset myyntiarviot voidaan ottaa huomioon liikevaihtoraporteilla, jolloin ennusteessa käytetään painokertoimena myynnin todennäköisyyttä, joka on käyttäjän lisäämä prosentuaalinen arvo. Tämä osaltaan tukee resurssienkäytön ja talouden ennakointia

Asiakastiedot, asiakkaiden yhteyshenkilöt ja mahdolliset asiakas- tai projektikohtaiset erikoishinnastot on kaikki tallennettu Severaan. Järjestelmä mahdollistaisi tarjouksen laatimisen suoraan järjestelmässä (Visma 2025a), mutta kohdeyrityksessä tämä ominaisuus ei ole käytössä, vaan tarjoukset tallennetaan pdf-tiedostona Severan projektitietojen liitteisiin.

4.3 Käytössä olevat hinnoittelumallit

Yrityksessä on käytössä useita hinnoittelumalleja suunnittelutarjouksille ja -sopimuksille riippuen toimeksiannosta ja asiakkaasta. Tyypillisiä alalla ja yrityksessä käytössä olevia hinnoittelumalleja ovat mm.:

- Kokonaishinta tai kokonaispalkkio (kiinteä hinta)
- Yksikköpalkkio (esim. €/asm2)
- Aikapalkkio henkilöryhmittäin (€/h)
- Tavoitepalkkio
- Arviohinta

Hinnoittelumalleissa on eroavaisuuksia ennakoitavuudessa sekä riskin jakautumisen tilaajan ja toimittajan välillä (Artto et al. 2006, s. 86). Kiinteään hintaan perustuva toimeksianto

siirtää riskiä toimittajalle, mutta mahdollistaa periaatteessa hyvinkin korkean katteen, jos projekti kyetään toimittamaan tehokkaasti. Epäonnistuessaan se voi johtaa yrityksen kannalta tappiolliseen projektiin. Aikaveloitusperusteinen hinnoittelu puolestaan siirtää puolestaan riskiä tilaajalle ja takaa resurssien laskutuksen. Toisaalta tämä malli ei kannusta toimittajaa tehokkuuteen. Tavoitepalkkio on riskin ja kannattavuuden jakamisen kannalta hyvä malli, mutta se vaatii yhteistä sopimista tavoitteista. Alalla on vakiintuneita käytäntöjä veloitusperusteiden osalta (Rakennustieto 2015, RT 13-11182).

4.4 Tarjouslaskennan ja työmääräarvioinnin nykytila

Tarjouslaskennan prosessia on kehitetty kohdeyrityksessä viimeisten vuosien aikana, joka kävi ilmi myös haastatteluista. Aikaisemmin tarjouksissa ja tarjousprosessissa oli melko suuriakin yksikkö- ja henkilökohtaisia eroja, mutta toimintatapaa on saatu yhtenäistettyä. Haastattelin projektin aikana kunkin yksikön operatiivisesta tarjoustoiminnasta vastaavat henkilöt, jotka pitävät säännöllisesti sisäisiä tarjouspalavereja yksiköiden johdon kanssa. Haastattelujen perusteella vaikutti siltä, että tämä toimintamalli on ollut toimiva.

Tarjouspohjia (Word) ja laskentapohjia (Excel) on yrityksissä viime vuosina kehitetty yhtenäisempään ja laadukkaampaan suuntaan. Excel-pohjaisesti on kehitetty melko pitkälle vietyjäkin malleja projektien suunnitteluvaiheet huomioivaan työmäärän laskentaan, mutta nämä mallit vaativat edelleen suhteellisen paljon manuaalista työt. Oppivaa tai tekoälypohjaista ratkaisua ei tähän tarkoitukseen ole yrityksessä aikaisemmin kehitetty. Toiminnanohjausjärjestelmässä olevan lähtödatan osittainen puutteellisuus etenkin vanhojen projektien osalta oli tunnistettu aiheena jo ennen tämän kehitystyön aloittamista. Projektidatan parantamiseksi oli aloitettu ”talkoot” samoihin aikoihin tämän tutkimuksen teon kanssa.

4.4.1 Kiinteähintaiset projektit

Haastatteluiden ja toiminnanohjausjärjestelmän tietojen perusteella lähes kaikkia suunnittelukohdetyyppejä tarjotaan myös kiinteähintaisina. Hinnoitteluperuste tulee yleensä tilaajalta tai se on määritelty valmiiksi tarjouspyynnössä. Erityisesti asuntosuunnittelussa hinta on tyypillisesti neliöperusteinen. Toiminnanohjausjärjestelmän tiedoista nousi esiin

myös kaupunkisuunnittelun projekteja, jotka ovat tyypillisesti maankäytön suunnittelua tai tontinkäyttöluonnoksia, ja myyntiarvoltaan usein suhteellisen pieniä kokonaisuuksia. Kaupunkisuunnittelun ja asuntosuunnittelun lisäksi kokonaispalkkiota käytetään ERP:n tietojen mukaan useassa muussakin rakennussuunnittelutyypissä.

Tarjouslaskennassa hyödynnetään pääasiassa kolmea näkökulmaa: laajuus, työmäärä ja osuus rakennuskustannuksista. Laajuus tarkoittaa suunniteltavan rakennuksen pinta-alaan pohjautuvaa ns. neliöpohjaista hinnoittelua (€/brm^2, €/kem^2, €/asm^2). Tätä hinnoittelua hyödynnetään paljon esimerkiksi asuntosuunnittelukohteissa, joissa suunnitteluratkaisut ovat pitkälti vakioituja ja joissa tilaaja myös vaatii €/asm^2 -pohjaista hintaa tarjouspyynnöissä. Toteutuneista projekteista on käytettävissä verrokkidataa toiminnanohjausjärjestelmästä (mm. laajuus, €/m2, tarjousvaiheen tuntiarvio, toteutuneet tunnit, kate-% jne.).

Työmääräpohjainen hinnoittelu tarkoittaa työmääräarvion laatimista huomioiden toimeksiannon sisältö, työryhmä ja mahdollinen aikataulu. Käytännössä tämä tarkoittaa toimeksiannon suorittamiseen vaadittavien tuntimäärien sijoittamista aikajanalle tarjouspyynnössä pyydetyn tehtävänsisällön mukaisesti. Erityisesti laajemmissa tarjouskokonaisuuksissa tuntimäärät eritellään suunnittelijoiden SKOL-luokkien mukaisesti, jolloin saadaan hinnaston mukaisilla tuntihinnoilla kerrottaessa tarkempi arvio kokonaisuudesta. Osittain sovelletaan myös keskituntihintaa, etenkin suppeammissa tarjouksissa.

Rakennuskustannuksiin perustuva hinta-arvio tarkoittaa arkkitehtisuunnittelun prosenttiosuutta hankkeen arvioiduista kokonaiskustannuksista. Kokonaiskustannuksia ei välttämättä ole tarjousvaiheessa tiedossa, mutta se voidaan arvioida kohteen laajuudesta ja aikaisempaa tietoa hyödyntäen. Lisäksi esiin nousi myös ammatilliseen kokemukseen perustuvan subjektiivisen kokemuksen hyödyllisyys hinnoittelussa (esimerkiksi kaupunkikuvallinen haastavuus, viranomainen, hankekoko).

Haastattelujen perusteella kävi ilmi, että etenkin laajoissa hankkeissa vertaillaan näitä kaikkia kolmea lähestymistapaa samanaikaisesti oikean hinnan ”haarukoimiseksi”. Jos hanke on laajuudeltaan suppeampi tai tarjouslaskentaan ei ole riittävästi aikaa käytössä voidaan joskus hyödyntää vain osaa (esimerkiksi €/m^2 pohjainen hinnoittelu on yksinkertainen ja nopea tapa). Edellä mainittujen lisäksi on myös ns. markkinahinnoittelu,

josta on dataa erityisesti mm. asuntosuunnittelukohteiden ja julkisten hankkeiden osalta. Tämä tarkoittaa kilpailijoiden tarjoaman hintatason hyödyntämistä hinnan määrittelyssä.

4.4.2 Työmääräarviointi ja tarjouslaskenta käytännössä

Haastatteluiden perusteella tarjouksen laajuus ja tarjouksen laadintaan käytössä oleva aika vaikuttavat käytännössä siihen, kuinka kattavasti mitäkin kolmesta näkökulmasta (laajuus, työmäärä, osuus rakennuskustannuksista) voidaan laskennassa hyödyntää. Tarjouslaskennan prosessia on yhtenäistetty yksiköiden kesken, mutta sen osalta on edelleen joitain eroavaisuuksia käytännöissä. Tämä on seurausta yksikköjen kokoeroista ja erilaisista henkilörooleista.

Tyypillinen kiinteähintaisen tarjouksen laatimisen prosessi etenee käytännössä seuraavasti (kuvattuna yhden yksikön nykykäytäntö). Ensin määritetään, onko kyse asuinkerrostalosta vai muusta rakennustyypistä. Jos kysymyksessä on asuinkerrostalo, tilaaja edellyttää lähes aina hinnan esittämistä €/asm²-perusteisesti, jolloin paikallinen markkinataso rajaa palkkion ylärajan. Mikäli tilaaja ei rajoita hintaa neliökohtaisesti, prosessi etenee neljässä vaiheessa.

1. Tarkastetaan vertailuprojekteista toteutuneet tunnit ja aiemmat tarjoukset, joilla saadaan karkea tuntihaarukka ja viitesuhdeluku €/brm².
2. Analysoidaan tilaajan esittämä aikataulu ja määritellään työryhmä, jolloin selviää, miten työ jakautuu kalenterikuukausille.
3. Jaetaan työmäärä suunnitteluvaiheille ja SKOL-rooleille, mistä saadaan toimiston keskimääräinen tuntihinta.
4. Yhdistetään nämä luvut, €/brm², vaihe- ja rooliprosentit, keskituntihinta, ja sovitetaan kokonaistuntimäärä tavoiteltuun kateprosenttiin.

Tämä prosessi sitoo tarjouksen sekä markkinaehtoiseen neliöhintaan että toimiston omiin historiatietoihin ja kustannusrakenteeseen.

4.4.3 Käytössä olevat Excel-pohjat

Yrityksessä on käytössä useita valmiita Excel-pohjia työmäärän arvioinnin ja tarjouslaskennan tukena. Tarjouslaskentaan on käytössä kaksi perustaulukkoa ”Tarjouslaskentapohja” sekä ”Tarjouslaskentapohja lyhyt”. Näistä ensimmäinen on tarkoitettu laajempien hankkeiden työmäärän laskentaan ja jälkimmäisen on tarkoitus olla suppeampi ja nopeakäyttöisempi, pääasiassa pienempien tarjousten tarpeisiin.

Kummassakin laskentapohjassa taulukon täyttäminen lähtee liikkeelle tuntien syöttämisestä. Peruspohjassa tunnit jaotellaan tarkemmin työvaiheittain, kuukausittain ja SKOL-luokittain. Lyhyemmässä taulukossa syötetään vain kokonaistunnit SKOL-luokittain. Molemmissa taulukoissa on valmiiksi syötetty tuntihinnat, joita kaavat hyödyntävät. Taulukot laskevat lisäksi kate-%:n työkustannusten ja hinnaston mukaisen tuntihintojen erotuksena. Laajempi taulukko myös visualisoi syötetyistä tunneista graafisen kuvaajan. Tämä malli on varsin hyvä etenkin projektin resursoinnin näkökulmasta. Taulukkoon vaiheittain ja kuukausittain kirjatut tunnit voidaan siirtää toiminnanohjausjärjestelmään henkilöresursseiksi.

Kummassakaan käytössä olevassa tarjouslaskentapohjassa ei oteta sinänsä kantaa suunniteltavan rakennuksen tyyppiin tai historialliseen projektidataan. Käytännössä tarjouslaskija hyödyntää itse omaa kokemusperäistä arviointiaan ja referenssikohteiden tietoja toiminnanohjausjärjestelmästä. Hinnan arviointi lähtee liikkeelle puhtaasti työmäärän arvioimisen kautta.

Edellä mainittujen lisäksi on laadittu Excel-taulukko, joka on rakennettu RT-kortin RT 13-11117 (Arkkitehdin työmäärän arviointi rakennushankkeessa) pohjalta. Taulukkoon syötetään hankkeen bruttopinta-ala (brm^2) ja malli laskee RT-kortin kertoimien mukaiset tuntimäärän I-VII vaativuusluokan kohteille. Malli on yksinkertaistus siinä mielessä, että se ei ota kantaa suunniteltavan rakennuksen tyyppiin tai huomioi historiallista dataa. Kyseinen malli kuitenkin havainnollistaa hyvin suunnittelun vaativuuden vaikutusta työmäärään ja se hyödyntää h/brm^2 tunnuslukua työmäärän laskemiseen. Työmäärän ja rakennuksen pinta-alan suhde ole lineaarinen vaan pikemminkin se muistuttaa eksponentiaalista/logaritmista funktiota.

4.5 Tavoitekate

Kohdeyrityksessä on määritelty tietty minimitavoitekate, johon suunnitteluprojekteissa pyritään. Tämä kate-% lasketaan tarjousvaiheessa mukaan asiakkaalle tarjottavaan hintaan ja sen saavuttamista seurataan toiminnanohjausjärjestelmän ja sinne kirjattujen tuntikirjausten avulla. Projektin taloudellista kannattavuutta mitataan ensisijaisesti kate-% tunnusluvun avulla. Lisäksi ERP:stä kunkin yksikön huonoiten kannattavimpia projekteja otetaan erityistarkasteluun ja näistä projekteista laaditaan analyysit tappiollisuuden syistä. Analyysin tarkoituksena on tunnistaa tappiollisen projektin syyt ja keinot, joilla tilannetta voitaisiin parantaa. Johto käsittelee analyysit ja jakaa tietoa takaisin projektipäälliköille.

Haastatteluiden perusteella kävi ilmi, että tavoitekate voi kuitenkin käytännössä olla alhaisempikin esimerkiksi asuntosuunnitteluprojekteja tarjottaessa, koska näissä tilaaja yleensä vaatii hinnan €/asm^2-perusteisesti ja markkinahinnoittelu ei aina käytännössä mahdollista korkeita katteita. Hinnan määrittelyssä tulee tällöin noudattaa kyseisen alueen markkinahintatasoa ja kilpailupaine voi johtaa tavoiteltua alhaisempaan katteeseen. Toisaalta asuntosuunnittelun kaltaisia, sisällöltään vakioituja suunnittelutoimeksiantoja, on myös helpompi hinnoitella. Joissain tapauksissa on myös tietoisesti päätetty, että tavoitekatteesta joustetaan esimerkiksi referenssin saamisen takia tai jos kyseessä on ollut suunnittelukilpailu.

5 Oppivan työmäärälaskentamallin kehittäminen

5.1 Mallin kehittämisen lähtökohdat

Tekoälyhankkeen onnistunut käynnistäminen edellyttää suunnittelua ja yhteistä käsitystä siitä mitä sillä tavoitellaan. Keskeinen lähtökohta on määritellä, mitä liiketoimintahyötyä tekoälyn käytöllä tavoitellaan. Arvolupauksen määrittelyn tulisi toimia koko projektin perustana (Kananen & Puolitaival 2019 s. 66). Tässä diplomityössä käytännön liiketoimintaongelmana oli parantaa kiinteähintaisten asuntosuunnitteluprojektien kannattavuutta ja tähän kehitettäväksi ratkaisuksi valikoitui oppivan työmääräennustemallin kehittäminen.

Oppivan työmääräennustemallin toteutuksen lähtökohtana oli rakentaa malli, jonka toimintaperiaatteen pystyisin itse hallitsemaan ja ymmärtämään. Suunnittelussa nousivat keskeisiksi lähtökohdiksi mallin tekninen toteutettavuus ja helppo käytettävyys, yhdessä ennusteen tarkkuuden kanssa. Lineaarinen regressio osoittautui ennustetarkkuudeltaan liian heikoksi ja neuroverkko taas tekniseltä toteutukseltaan liian monimutkaiseksi malliksi. Satunnaismetsä osoittautui sopivaksi analyysimenetelmäksi, ottaen huomion ennustetarkkuus ja riittävän suoraviivainen tekninen toteutuskelpoisuus. Satunnaismetsä myös kykenee mallintamaan epälineaarisia suhteita paremmin kuin lineaarinen regressio.

Mallin rakentamisen lähtökohdaksi otettiin kehittämistutkimuksen hengessä iteratiivinen lähestymistapa. Tarkoituksena oli rakentaa ensin karkea testimalli ja jatkojalostaa sitä tehtyjen havaintojen ja palautteen pohjalta. Teknisessä toteutuksessa oli tarkoitus hyödyntää toiminnanohjausjärjestelmästä saatavaa projektidataa Excel-muodossa. Itse ennustemalli oli tarkoitus toimia Python-ohjelmana, scikit-learn sekä Pandas -kirjastoja hyödyntäen. Mallin visuaalinen käyttöliittymä olisi mahdollista toteuttaa selainpohjaisesti esimerkiksi Streamlit tai FastAPI ohjelmia hyödyntäen.

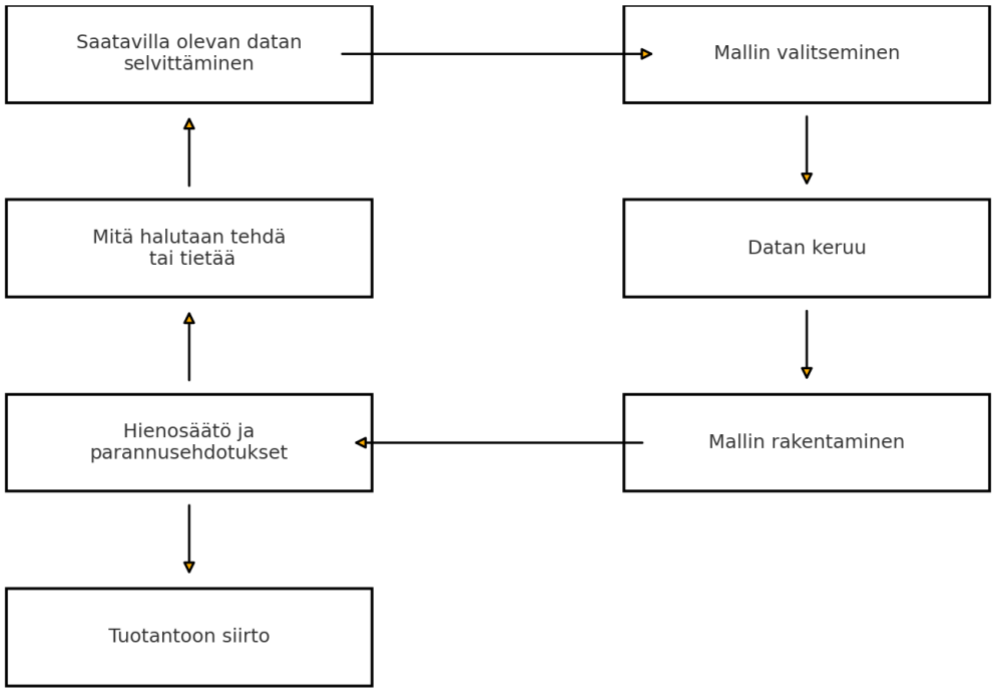

Kuva 16. Tiedonlouhinta liiketoimintaprosessina (Telivuo 2018, s. 40)

5.2 Hyödynnettävä projektidata

Tutkimuksessa hyödynnettiin kohdeyrityksen toiminnanohjausjärjestelmässä (Visma Severa) olevaa projektidataa. Tarvittava aineisto koostettiin ERP:n raportointityökalulla, johon suodatettiin näkyviin hyödynnettävät arvot. Raportointityökalusta tietoa on mahdollista ladata ulos Excel- ja CSV-tiedostoina. Suodattimiksi raportille valikoituivat kaikki asumisen kustannuspaikalle merkityt projektit, jotka ovat päättyneet (taloudellinen lopputulos on varma), liikevaihto on yli 3000 € ja huoneistoala yli 1 htm^2 (ei huomioida projekteja, joille ei ole merkitty pinta-alatietoa). Näillä suodattimilla saatiin aineisto rajattua 72 projektiin.

Tämän jälkeen aineistosta suodatettiin vielä käsin pois joitain yksittäisiä projekteja, jotka sisälsivät esimerkiksi ainoastaan asemakaavavaiheen suunnittelua tai lisätöitä. Lisäksi joidenkin projektien osalta tuntikirjaukset olivat joidenkin yksiköiden aikaisemmissa toiminnanohjausjärjestelmissä, josta tietoja käytiin vielä tarkistamassa ja korjattiin manuaalisesti Excel-taulukkoon. Tämänkaltaiset vinoumat lähtödatassa olisivat voineet aiheuttaa vääristymää ennusteissa.

Raportille tulostettiin mukaan seuraavat arvot projektitiedoista:

- Työnumero
- Yksikkö
- Työn nimi
- Työn vastuuhenkilö (projektipäällikkö)
- Paikkakunta (suunnittelukohteen)
- Aloituspäivä (pvm)
- Päättymispäivä (pvm)
- Valmiusaste (%)
- Huoneistoala (htm^2)
- Huoneistoalan neliöhinta (€/htm^2)
- Bruttoala (brm^2)
- Kerrosala (kem^2)
- Alkuperäinen myyntiarvio (€, arvio)
- Liikevaihto (€, toteuma)
- Työmääräarvio (h, arvio)
- Työtunnit (h, toteuma)

ERP:stä otettiin siis ulos melko suuri määrä projektitietoa, josta muodostui perusraportti, joka ladattiin Excel-tiedostona edelleen hyödynnettäväksi. Tämän lisäksi lähtötietona hyödynnettiin erillisinä raportteina asuntosuunnitteluprojektien tuntikirjauksia, suunnittelijoiden SKOL-luokkia sekä yksikkökohtaisia työtuntihinnastoja. SKOL-luokka on alalla yleisesti käytössä oleva henkilöryhmittelyn luokittelujärjestelmä, jota käytetään suoritettavan tehtävän vaativuuden ja siitä maksettavan palkkion määrittelyyn.

Arkkitehtisuunnittelun työmäärän arviointi perustuu alalla usein suunniteltavan kohteen laajuuteen ja vaativuuteen (Rakennustieto 2013, RT 13-11117). Tämän vuoksi erityisesti projektin laajuustiedot ja niihin liittyvät lasketut euro- ja tuntimääräiset tunnusluvut ovat tärkeitä. Tiedonkeruuprosessin alussa havaittiin, että yllättävän monesta päättyneestä projektista puuttui etenkin htm^2, €/htm^2, brm^2 ja kem^2 -lisätietokentät, jolloin niitä ei ollut mahdollista saada raportille mukaan ja tämä osaltaan rajasi hyödynnettävien projektien

määrää. Asuntosuunnitteluhankkeita hinnoitellaan alalla yleisesti asuntoneliöpohjaisesti, joten etenkin htm^2-tieto oli tärkeä. Yhteistyössä tarjous- ja talousvastaavien sekä projektipäälliköiden kanssa aineistoa saatiin jonkin verran täydennettyä toiminnanohjausjärjestelmän puolelle ja näin aineiston kattavuutta parannettua. Osa tiedoista jouduttiin käydä manuaalisesti koostamassa laadituista suunnitelmista, jonka seurauksena tämä vaihe oli yllättävän työläs.

Työmäärä- ja liikevaihtodata oli hyvin kattavaa ja luotettavaa, koska se perustuu suoraan tuntikirjauksiin ja laskutukseen. Raportille otettiin mukaan sekä projektien tarjousvaiheen työmääräarviot että toteutuneet tunnit sekä tarjottu hinta ja toteutunut liikevaihto. Näiden vertailu keskenään mahdollisti tarjotun ja toteuman välisten erojen tarkastelun. Aineistona hyödynnettiin lisäksi aikaisemmassa projektityössä toteutettuja haastatteluita ja diplomityön aikana käytyjä jatkokeskusteluja yrityksen avainhenkilöiden kanssa.

5.3 Mallin tekniset lähtökohdat ja kehittäminen

5.3.1 Python

Ennen diplomityön aloittamista itselläni ei ollut koodaustaustaa tai kokemusta Pythonista, joten tutkimuksen teko oli oppimiskokemus myös tästä näkökulmasta. Hyödynsin opettelussa Helsingin yliopiston Data Analysis with Python 2024–2025 MOOC-verkkokurssia (Helsingin yliopisto 2024), ChatGPT tekoälyä sekä kirjallisuutta (mm. Downey 2015, Kämäräinen 2023, Sweigart 2015, VanderPlas 2016a, 2016b,).

Python on alun perin 1980-luvun lopulla kehitetty ohjelmointikieli, josta on muodostunut keskeinen työkalu ohjelmoinnin, tutkimuksen ja data-analytiikan käyttöön (VanderPlas 2016b). Python on ns. korkean tason ohjelmointikieli (Downey 2015). Toisin sanoen siinä on korkea abstraktion aste ja se muistuttaa luonnollista ihmisen kieltä. Pythonin hyödyllisyys perustuu pitkälti sen laajaan kirjastoekosysteemiin, joista esimerkkejä ovat (VanderPlas 2016a, 2016b):

- NumPy – tehokas tietojoukkojen käsittely ja laskenta
- SciPy – matemaattisia työkaluja, kuten integraatio ja interpolointi

- Pandas – DataFrame -objekti ja menetelmät tietojen käsittelyyn, suodattamiseen, ryhmittelyyn ja muuntamiseen
- Matplotlib – laadukkaiden kuvaajien ja visualisointien tuottaminen (jota on hyödynnetty myös tämän raportin kuvien tekemisessä)
- Scikit-learn – työkalut yleisimpien koneoppimisalgoritmien soveltamiseen
- IPython/Jupyter – parannettu käyttöliittymä ja muistikirjaympäristö dokumentointia ja havainnollistamista varten

Scikit-learn kirjasto osoittautui tärkeäksi diplomityössä kehitetyn ennustemallin kannalta, koska se mahdollisti erilaisten luokittelu-, regressio- ja klusterointialgoritmien hyödyntämisen Python-ohjelmassa, kuten lineaarisen regression ja satunnaismetsän (Kämäräinen 2023, VanderPlas 2016a).

5.3.2 Power Query ja Microsoft Power BI

Power Query on Excelin sisäänrakennettu tiedon käsittelyn ETL-työkalu (Extract, Transform, Load), jonka avulla voidaan tuoda, muokata ja yhdistellä tietoa eri lähteistä (Microsoft n.d.b). Tietoa on mahdollista tuoda useasta eri lähteestä, kuten esimerkiksi Excel-taulukoista, CSV-tiedostosta, tekstitiedostoista, tietokannasta tai verkkosivulta (Microsoft n.d.d). Tietojen muokkaamisessa käyttäjän tekemät vaiheet tallentuvat ja niitä voidaan toistaa automaattisesti, joka mahdollistaa toistuvien tehtävien automatisoinnin.

Power Query perustuu M-kaavakieleen, jota voidaan kuitenkin pääasiassa käyttää graafisen käyttöliittymän kautta, joka mahdollistaa sen hyödyntämisen myös ilman ohjelmointiosaamista (Microsoft n.d.c). Edistyneempiä toimintoja voidaan suorittaa ja muokata myös komentosarjoina ohjelmointikielellä. Pythonin hyödyntäminen on myös mahdollista Power BI:n Power Query Editorissa, joka mahdollistaa vielä monipuolisemman datan muotoilun, analytiikan ja ennustamisen tietojoukoista (Microsoft n.d.d).

Käyttäjä voi mm. yhdistellä, muokata ja karsia tietoja useasta eri lähteestä ja luoda niiden pohjalta erilaisia raportteja ja visualisointeja (Microsoft n.d.e.). Datan visualisointi on keino havainnollistaa ilmiöitä, joiden kokonaisuuden ymmärtäminen on haastavaa pelkän tilastotiedon perusteella. Power Queryä voidaan hyödyntää useassa Microsoftin

sovelluksessa, kuten mm. Excelissä, Power BI:ssä, Power Appsissa ja Dataveresessä (Microsoft n.d.c).

5.3.1 Mallin kehittäminen

Aloitin mallin rakentamisen koostamalla Visma Severassa raportin, johon rajasin projektidatasta haluamani arvot taulukoksi ja vein tämän raportin Excel-taulukoksi. Python-pohjainen satunnaismetsää hyödyntävä ennustemalli hyödyntäisi tätä taulukkoa lähtödatana.

Ensimmäinen versio mallista otti huomioon seuraavat piirteet ERP:stä ladatusta Excel-tiedostosta:

- Huoneistoala (htm^2), kuvaa projektin kokoa huoneistoneliömetreinä
- Log-huoneistoala (log_htm^2), sama tieto kompensoituna (logaritmi), jotta suuret ja pienet kohteet eivät dominoi liikaa
- €/htm^2, toteutunut liikevaihto jaettuna huoneistoalalla tai vaihtoehtoisesti tarjottu hinta jaettuna huoneistoalalla, jos liikevaihto puuttuu – kertoo hintatason
- h/htm^2, toteutuneet työtunnit suhteessa huoneistoalaan – kertoo työmäärän
- Projektin kesto (kk), kalenterikuukausina aloituksesta valmistumiseen, erottelee lyhyet ja pitkät hankkeet
- Paikkakunta (sijainti), huomioidaan kaupunkikohtainen hintataso

Jokaisesta Excelin rivistä otetaan yllä mainitut numeeriset arvot ja nämä jaetaan satunnaismetsän hyödynnettäväksi. Satunnaismetsä koostuu suuresta määrästä päätöspuita, joista jokainen rakennetaan eri satunnaisotoksella samoista projektiriveistä ja vain osalla yllä listatuista selittävistä tekijöistä. Näin ollen puut tutkivat dataa hieman eri kulmista, eivätkä yksittäiset poikkeushankkeet pääse hallitsemaan lopputulosta.

Kun puuta koulutetaan, se katsoo kaikkia selittäviä tekijöitä ja käy läpi useita mahdollisia raja-arvoja. Jokaisesta kokeillaan miten hyvin se erottelee rivit kahteen ryhmään. Puu valitsee sen tekijän ja raja-arvon, jolla vaihtelu pienenee eniten. Esimerkiksi ”Onko huoneistoala > 4500 m^2?” saattaa osoittautua parhaaksi ensimmäiseksi kysymykseksi. Tämän jaon pohjalta muodostuu kaksi haaraa ja niissä olevista riveistä puu etsii uudestaan

parhaan jatkokysymyksen. Esimerkiksi ”Onko sijainti = Helsinki?”. Kysymysten avulla jakaminen jatkuu, kunnes lisäkysymykset eivät paranna tulosta ja saavutaan ns. lehteen. Lehteen kuuluville projekteille lasketaan keskiarvoinen työtuntiluku. Tämä arvo on kyseisen puun ennuste kaikille uusille kohteille, jotka vastaavat samoihin kysymyksiin samalla tavalla.

Kun käyttäjä syöttää uuden projektin esimerkiksi 3500 m^2, Helsinki, käy puu läpi löytämänsä kysymysten polun ja päätyy johonkin lehdistä. Metsän tasolla tämä toistuu lukuisissa puissa ja näiden lehtien keskiarvo muodostaa lopullisen ennusteen. Näin puu tekee päätöksensä täysin datan sisältämien havaintojen perusteella. Käyttäjä antaa vain lähtötiedon, jonka perusteella puu valmiiksi oppimansa logiikan mukaisesti, luokittelee projektin oikeaan koriin.

Tämän prosessin avulla satunnaismetsä oppii mallissa ennustamaan työtunnit (h) ja €/htm^2-kertoimen, josta saadaan hinta (€). Ratkaisu koostuu kahdesta erillisestä ’metsästä’: RF-Tunnit (joka ennustaa projektin työtunteja) sekä RF-Hinta (joka ennustaa €/htm^2-kertoimen, jonka kautta työtunnit muutetaan euroiksi). Molemmat mallin hyödyntävät samoja piirteitä. Mallia visualisoidaan selainkäyttöisenä Streamlit-sovelluksena, johon käyttäjä lataa lähtötietona käytettävän Excelin, syöttää kohteen huoneistoalan ja valitsee paikkakunnan, jonka jälkeen Laske-painike näyttää tuloksen.

5.3.1 Testimalli

Mallin ensimmäinen kehitysversio laskee lähtödatataulukosta satunnaismetsää hyödyntäen kuvattua ennustetta ja perustuen käyttäjän syöttämään htm^2 -lukuun sekä suunnittelukohteen sijaintiin. Vertailukohtana tälle arvolle ensimmäinen malli kertoi myös yksinkertaiseen mediaaniin perustuvat vastaavat luvut kyseessä olevaan paikkakuntaan rajattuna. Näiden alle malli tulostaa kuvaajan, josta voidaan arvioida mallin luotettavuutta ja kattavuutta sekä 10 samankaltaisinta hanketta. Tämä tieto on avuksi tarjoustyötä tekeville, koska he voivat nopeasti käydä katsomassa näitä referenssihankkeita tarkemmin. Nimesin tämän perusmallin estimator_rf.py.

Viivakuvaaja ei ollut paras mahdollinen valinta luotettavuuden esittämiseen ja se muutettiin jatkokehityksessä. Tässä vaiheessa käytössä olleen lähtödatan heikko laatu näkyi myös

ennusteiden epäluotettavuudessa, koska vanhoista toiminnanohjausjärjestelmistä manuaalisesti koostettuja datoja ei ollut vielä täydennetty aineistoon.

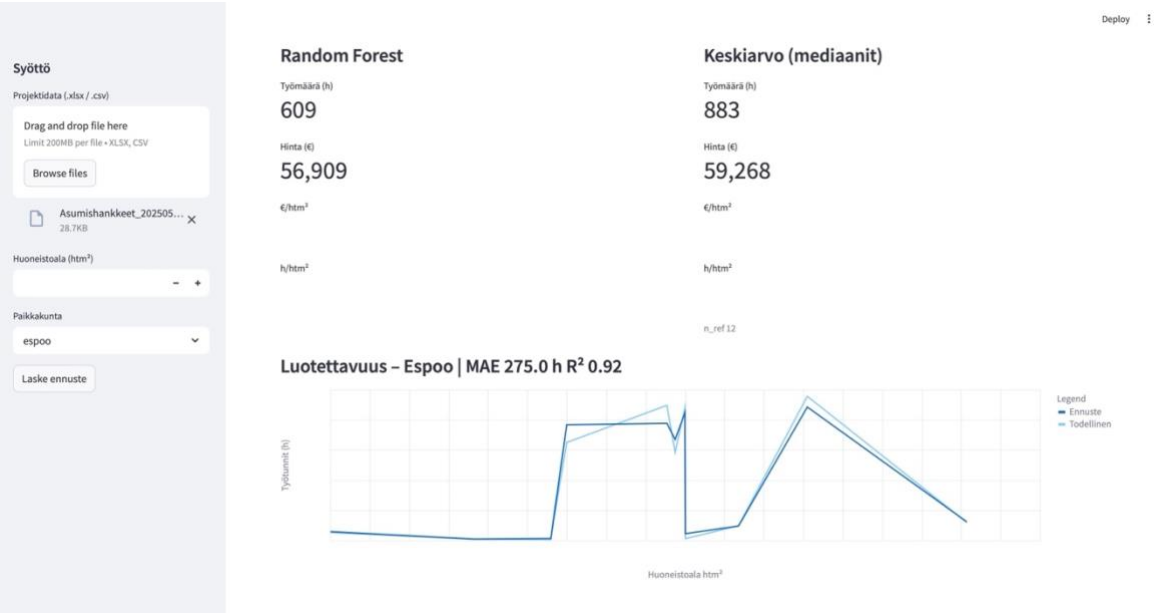

Kuva 17. Ensimmäinen estimator_rf.py -mallin selainkäyttöinen visualisointi Streamlitilla (htm^2, €/htm^2, h/htm^2 sekä kuvaajan x- ja y-akselien arvot piilotettu)

Tästä kokonaistuntimäärää laskevasta mallista tuli mieleen, että todellisuudessa hankkeet ja niiden hinnoittelu perustuu myös työryhmän laskutushintoihin ja hankkeessa hyödynnettävään SKOL-jakaumaan. Kiinteähintaisissa projekteissa tarjotaan toki vain kokonaishinta, mutta päätin kokeilla lisätä malliin ominaisuuden, jolla lasketun kokonaistuntimäärän SKOL-jakaumaa voidaan käyttäjän toimesta manuaalisesti säätää ja kokeilla miten se vaikuttaa kokonaishintaan. Se osaltaan myös määrittää yrityksen sisäisiä kustannuksia, sillä korkeamman SKOL-luokan työntekijästä aiheutuu yritykselle korkeammat kustannukset. Tämä on ikään kuin lisävaihe hinnan ja työmäärän muodostuksen validoinnille.

Laskin mallissa olleille projekteille tuntikirjausten ja työntekijöiden SKOL-luokkien kautta Power BI:llä keskiarvon. Todellisuudessa suunnitteluprojektissa harvoin on kaikkia eri ryhmiä edustavia työntekijöitä ja käyttäjä voi itse syöttää haluamansa painotuksen. Malli laskee hintaa hyödyntäen valittua hinnastoa. Tätä tuntijakaumaa voidaan peilata kokonaishintaan ja toisaalta käyttää myös resurssoinnin ja projektisuunnittelun pohjana ja mahdollisesti myös projektiin sopivan työryhmän haarukointiin ja resurssitilannevertailuun. Nimesin tämän laajennetun mallin estimator_rf_plus.py.

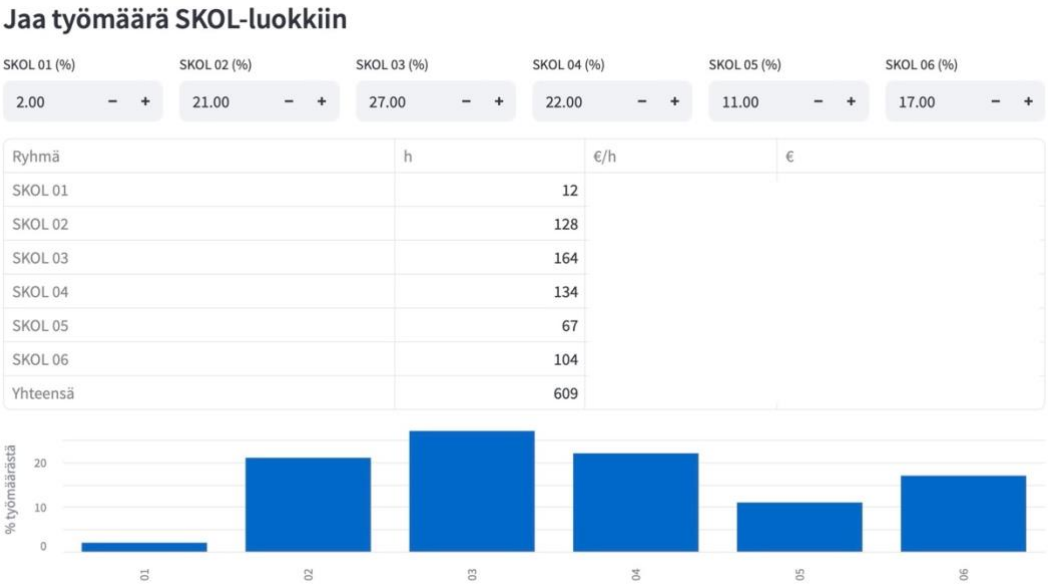

Kuva 18. estimator_rf_plus.py -malliin lisätty ominaisuus, jaottelu SKOL-luokkiin (€/h ja € arvot piilotettu)

Malli ei suoranaisesti muodosta ennustetta syötetyn kohteen ennustetusta SKOL-jakaumasta, mutta käyttäjä voi hyödyntää sitä tarjoustyön tukena ja nopeiden arviointien tekoon. SKOL-jakauma riippuu pitkälti myös suunnitteluprojektiin kiinnitettävästä suunnitteluryhmästä ja katetavoitteesta. Laskin vielä Power Querya hyödyntämällä Exceliin kullekin historialliselle projektille SKOL-jakauman toteuman hyödyntäen ERP:stä ladattua taulukkoa, jossa on kaikkien suunnitteluhankkeiden tuntikirjaukset ja toista taulukkoa, jossa on suunnittelijoiden SKOL-luokat. En kuitenkaan kokenut, että tämän tuominen ennusteen piiriin olisi tuonut merkittävää lisäarvoa konseptitason mallille. Ominaisuuden hyödyllisyyttä voitaisiinkin tutkia jatkokehityksessä.

Toinen tähän kehitettyyn malliin lisäämäni ominaisuus oli scikit-learn kirjaston feature_importances, jota voidaan hyödyntää piirtämään kuvaaja, joka kertoo mitkä algoritmin piirteet ovat kyseisessä laskutoimituksessa vaikuttaneet eniten lopputulokseen. Tältä pohjalta käyttäjä voi arvioida myös mallin luotettavuutta nopeasti. Oheisen kuvan esimerkissä on käytetty 3000 htm2 kohdetta Espoossa, ja tässä tapauksessa tärkeimmät piirteet ovat htm^2, log-htm^2, h/htm^2, €/htm^2 ja sijainti. Näistä pinta-ala on merkittävämpi kuin sijainti.

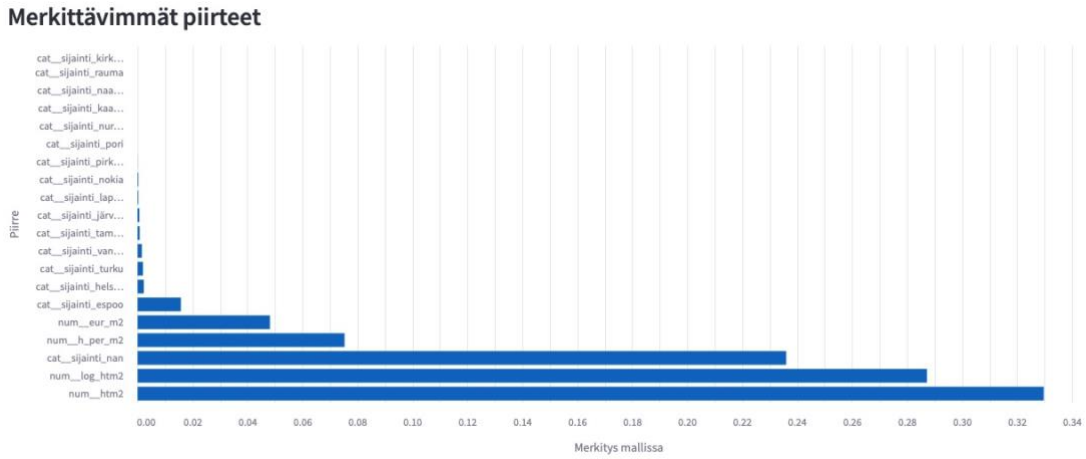

Kuva 19. estimator_rf_plus.py -malliin lisätty feature_importances -kuvaaja

Kehitysvaiheessa ajoin ohjelmaa paikallisesti selaimessa, mutta se olisi mahdollista ajaa esimerkiksi Sharepoint-nettisivulla. Tämä kuitenkin edellyttää, että selaimeen ladataan manuaalisesti uusin Excel-taulukko lähtödatasta, kunnes mahdollinen Severa REST API rajapinta saataisiin linkitettyä malliin.

5.3.1 Kehittyneempi malli

Alkuperäisen mallin lähtödata oli tässä vaiheessa vielä puutteellista ja käytimme merkittävästi aikaa sen laadun parantamiseen yhteistyössä projektipäälliköiden ja ERP:n pääkäyttäjän kanssa. Tunnistimme samalla, että alkuperäisen mallin kuvaaja ei ollut kovin havainnollinen ja pistekaavio havaittiin paremmaksi ja havainnollisemmaksi vaihtoehdoksi.

Lisäsin malliin ominaisuuden, joka piirtää haetusta suunnittelukohteen paikkakunnasta pistekaavion (scatter plot), joka näyttää mihin kohtaan haetun pinta-alan kohde sijoittuu kuvaajalla. Kuvaaja auttaa käyttäjää arvioimaan ja vertailemaan itse ennusteen luotettavuutta ja vastaavia hankkeita. Tämän pohjalta oli mahdollista tehdä esimerkiksi laadullista arviointia piirteiltään lähimpien referenssihankkeiden osalta. Pisteet eivät jakaudu kuvaajalle täysin lineaarisesti, mutta lisäsin malliin havainnollistamaan myös visuaalisen ominaisuuden, joka laskee yksinkertaisen lineaarisen regressioviivan havainnollistamaan kulmakerrointa.

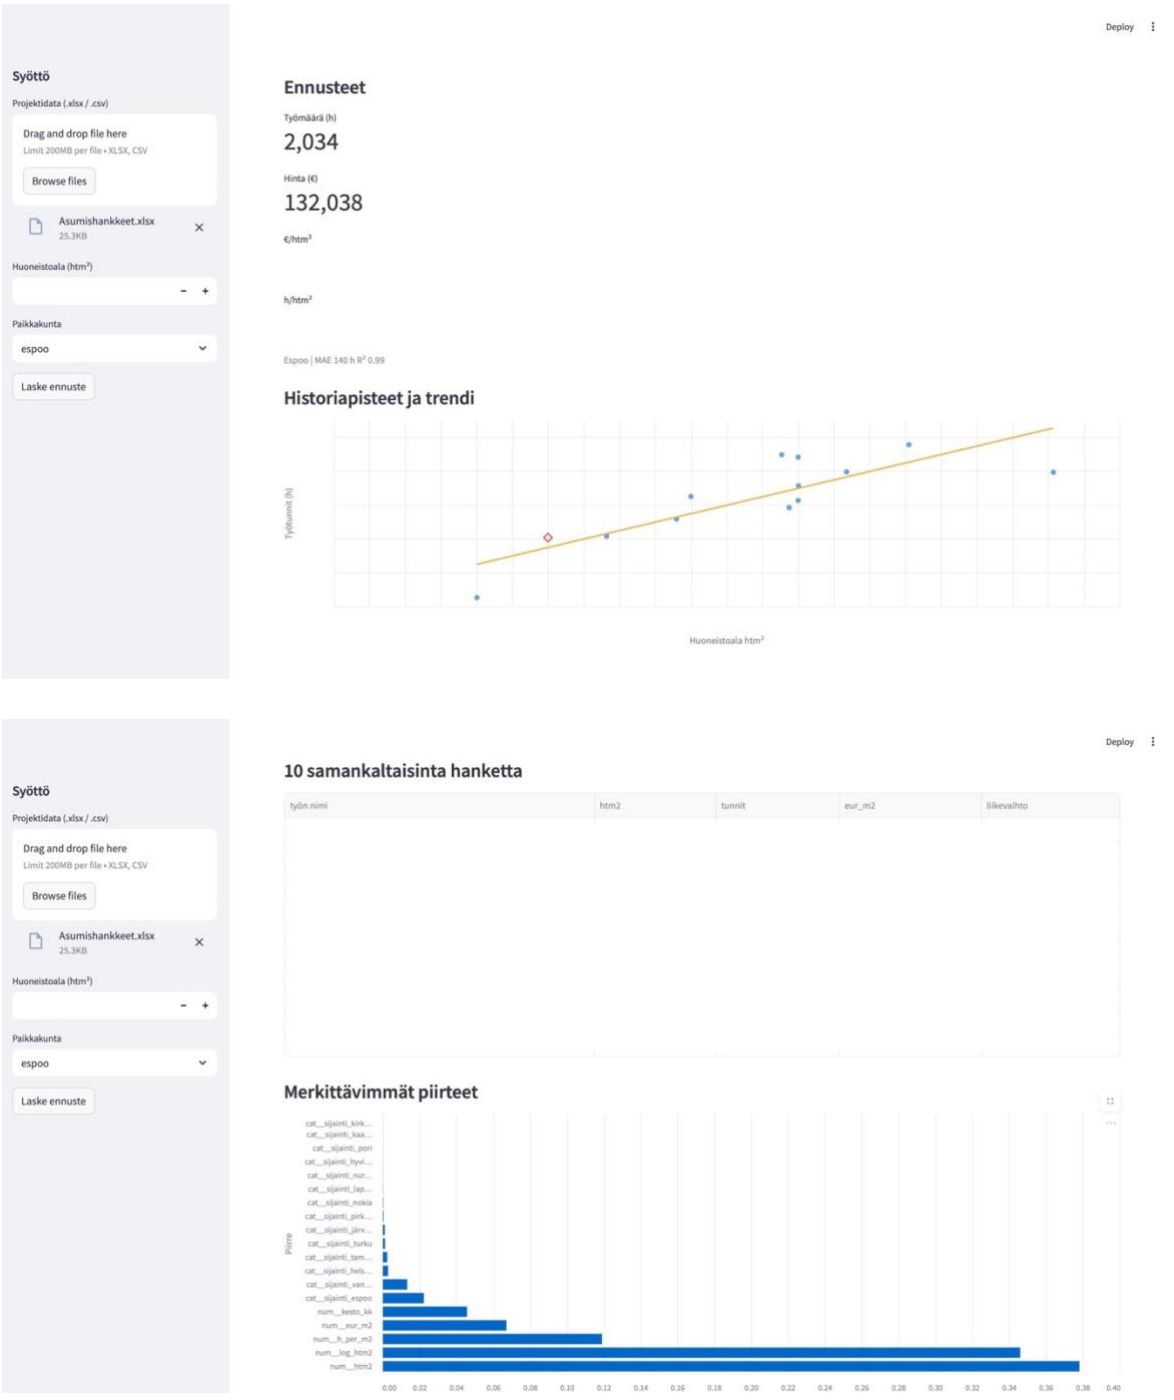

Kuva 20. estimator_rf_scatter_v3 ja malliin lisätty pistekaavio (htm^2, €/htm^2, h/htm2, pistekaavion x- ja y-akselien arvot sekä samankaltaisten projektien tiedot piilotettu)

Paikkakuntakohtaiset pistekaaviot tarjoavat mielenkiintoista tietoa analysoitavaksi. Samalla kaavioista osoittautuu selkeästi paikkakuntakohtaiset erot ja myös dataotannan puutteet. Esimerkiksi Espoon ja Turun osalta lähtötieto oli saatu jo melko kattavaksi, mutta Helsingin osalta se oli vielä puutteellinen (lähtödatassa ei riittävästi datapisteitä). Viemällä hiiri kunkin

sinisen datapisteiden päälle näkee käyttäjä mistä hankkeesta on kyse ja voi käydä toiminnanohjausjärjestelmän puolella katsomassa lisää tietoa kyseisestä projektista.

Kuva 21. Pistekaavio Helsinki, huomionarvoista referenssikohteiden suhteellinen vähäisyys (x- ja y-akseleiden arvot piilotettu)

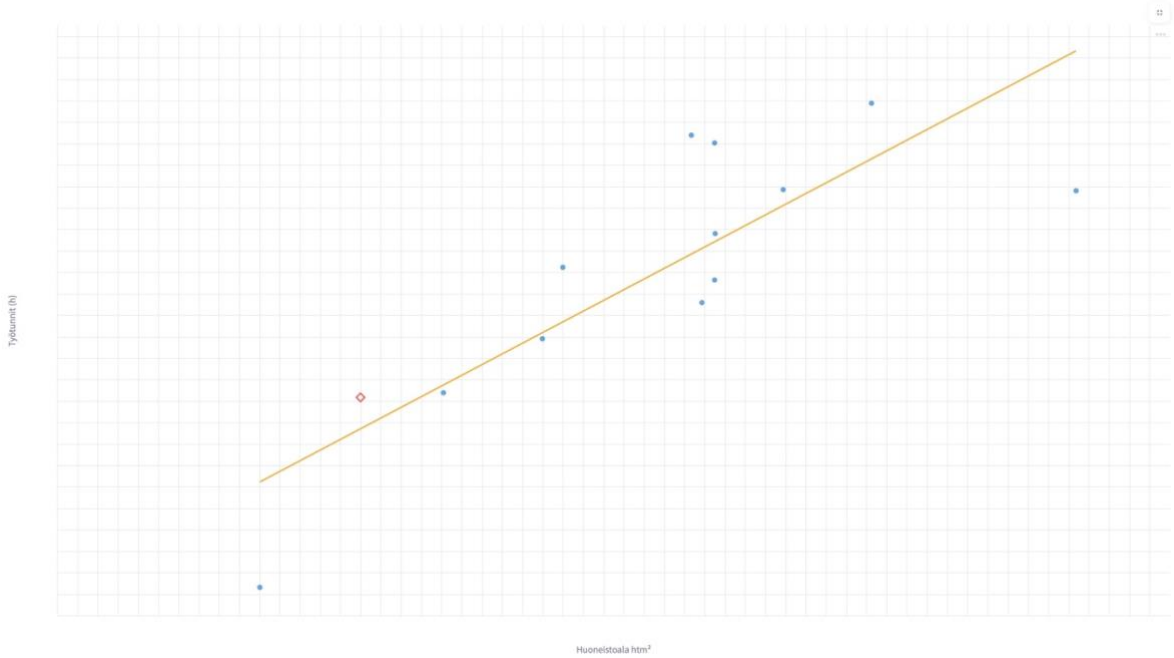

Kuva 22. Pistekaavio Espoo, huomionarvoista referenssikohteiden melko suuri keskimääräinen pinta-ala (x- ja y-akseleiden arvot piilotettu)

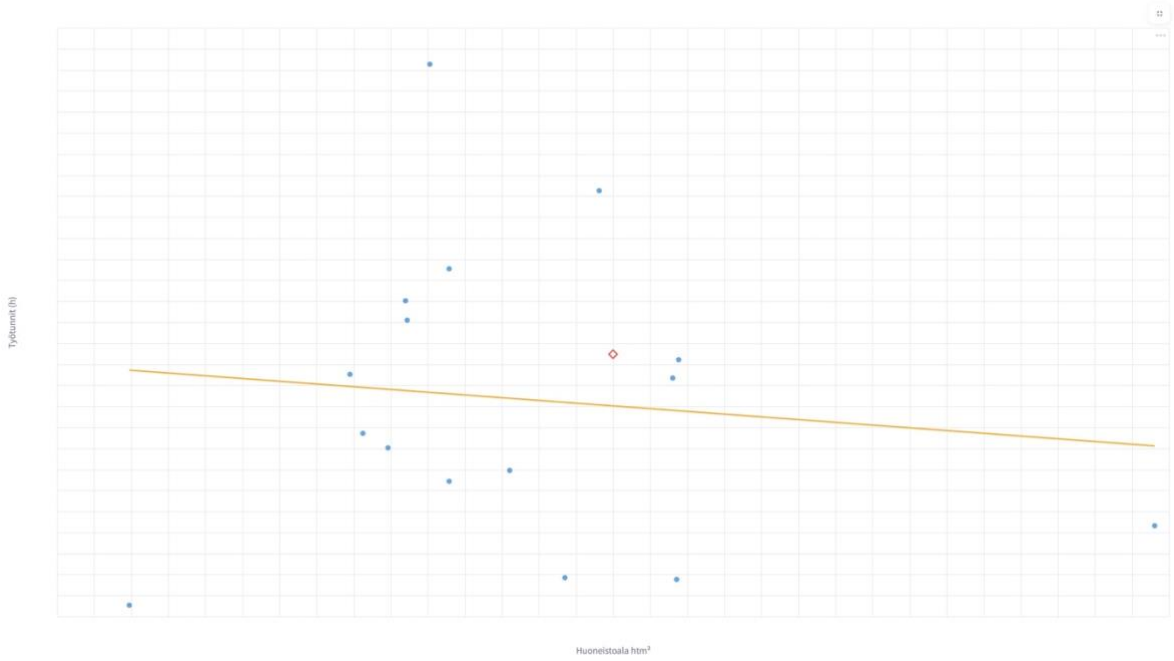

Kuva 23. Pistekaavio Turku, huomionarvoista suuri vaihtelu työmäärässä (x- ja y-akseleiden arvot piilotettu)

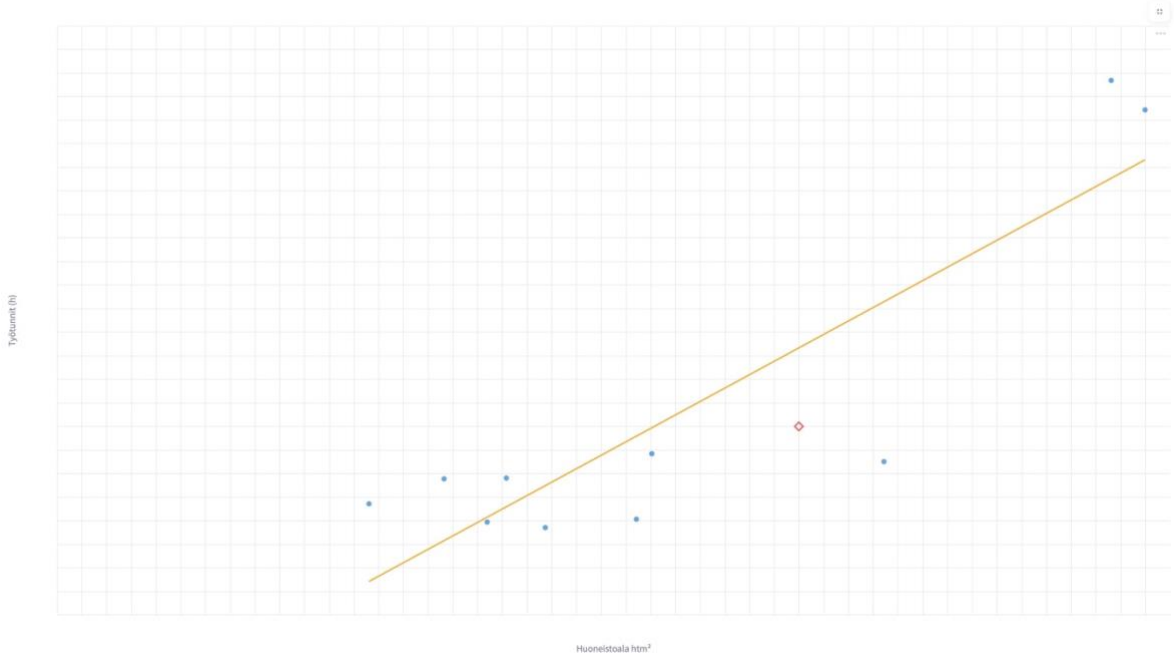

Kuva 24. Pistekaavio Tampere (x- ja y-akseleiden arvot piilotettu)

5.3.2 Lineaarinen regressio

Päätin tutkia, voisiko yksinkertaisempi lineaarinen regressio korvata satunnaismetsän. Toteutuksessa vaihdoin molempien RF-mallien tilalle kaksi ridge-regressoria. Kaikki muut

vaiheet mallissa (esikäsittely, satunnaisjako, visualisointi) pidettiin samana. Testin tuloksena MAE kasvoi reilusti random forestiin verrattuna ja myös R^2 heikkeni huomattavasti etenkin paikkakunnilla, joilla havaintoja oli vähän.

Visuaalisesta kuvaajasta oli myös mahdollista nähdä, että regressiosuora ylitti tai alitti todellisen ”keskiarvon”. Tämä oli luultavasti seurausta lähtödatasta ja/tai siitä, että työtunnit eivät kasva täysin lineaarisesti huoneistoalaan nähden. Johtopäätöksenä lineaarisen regression kokeilusta oli, että satunnaismetsä tarjoaa paremman tasapainon ennustetarkkuuden ja käytännön hyödynnettävyyden välillä, jonka vuoksi se valittiin päämalliksi.

Excelin ennustamiseen tarkoitettu FORECAST.LINEAR-funktio hyödyntää lineaarista regressiota. Funktio sovittaa tunnetut x- ja y-arvot lineaariseen malliin ja laskee tältä pohjalta ennusteen syötetylle x-arvolle (Microsoft n.d.a). Tämä Excelin funktio ei siis anna riittävän luotettavaa ennustetietoa tässä työssä tutkittavaan ongelmaan.

5.3.1 Microsoft Power BI

Kehitystyön aikana kokeilin myös projektidatan Excel-tiedostojen muokkausta Power BI:n avulla. Muodostin Power Query linkityksiä ja muokkauksia taulukkoihin, jonka avulla pystyi luomaan projektikohtaisen SKOL-jakauman tuntien ja eurojen osalta hyödyntäen erillisissä taulukoissa olleita asuntosuunnittelun tuntikirjauksia ja suunnittelijoiden SKOL-luokkia. Python-skriptien ajaminen oli myös mahdollista Power BI:ssä, mutta tämä osoittautui kuitenkin hieman hankalaksi ja skriptien ajaminen suoraan tietokoneen komentorivillä osoittautui joustavammaksi ratkaisuksi. Tämän vuoksi päädyin Power BI kokeilun jälkeen palaamaan alkuperäiseen toteutustapaan. Power BI käsittelystä oli kuitenkin hyötyä, koska sitä kautta sain eri taulukoita linkittämällä mm. luotua listan projektien toteutuneista SKOL-jakaumista.

5.4 Luotettavuuden ja käytettävyyden arviointi

Pilotin tavoitteena oli osoittaa, että malli pystyy jo nyt tuottamaan käyttökelpoisen hinta- ja tuntiarvion. Täydellisen käyrän saavuttaminen edellyttää laadukkaampaa ja kattavampaa

lähtöaineistoa, jota jatkuvasti tuotetaan lisää toiminnanohjausjärjestelmän puolelle. Kohdeorganisaatiossa on myös otettu tavoitteeksi puuttuvien projektitietojen lisääminen.

Käytännössä mallia voi hyödyntää nopeana referenssi- tai tarkistustyökaluna tarjouslaskennassa. Kun huoneistoalan kokoluokka ja paikkakunta on syötetty, sovellus antaa melko luotettavan suuruusluokka-arvion ja kertoo samalla, että kuinka paljon historiallista dataa sen taustalla on. Testien tarkkuus osoittautui riittäväksi tarjousvaiheen tarpeisiin, ennuste on selvästi parempi kuin pelkkä keskiarvo. Datalaadun ja kattavuuden parantuessa sovellus tarkentuu automaattisesti ilman, että mallia tarvitsee rakentaa uudelleen.

Rakennettu malli perustuu koneoppimiseen ja oppiminen tapahtuu, kun toiminnanohjausjärjestelmästä ladataan uusi projektidata sen käyttöön. Tämä tekee siitä käytännössä dynaamisen työkalun työmäärän arvioinnin ja hinnoittelun tueksi.

5.4.1 Ennustevirhe ja vaihtoehtoiset malit

Satunnaismetsään perustuvassa ennustemallissa hyödynnettiin Pythonin scikit-learn-kirjaston train_test_split -funktiota, jonka avulla aineisto jaettiin 80/20 % osuuksiin, josta 80 % käytettiin mallin kouluttamiseen ja loput 20 % sen testaamiseen. Mallin luotettavuutta voidaan näin tarkastella 20 % osuudella, jotta malli ei ole oppimisvaiheessa ”nähnyt”.

Ennusteen suorituskykyä mittaamaan valitsin mittareiksi R^2 (prosenttiosuus vaihtelusta) sekä MAE (keskimääräinen virhe, Mean Absolute Error). Nämä laskettiin lähtödatasta paikkakuntakohtaisesti, riippuen siitä mille paikkakunnalle sijoittuvalle kohteelle ennustetta tehdään. Esimerkiksi Espoon osalta MAE oli 140 h ja R^2 0,99 ja Tampereen osalta MAE 726 h ja R2 0,83. Ennustevirheen suuruus riippuu lähtödatan kattavuudesta ja laadusta, josta hyvä esimerkki oli Helsingin heikko MAE 1730 h ja R^2 0,18, jonka syynä luultavasti oli se, että referenssipisteitä oli vähemmän. Paikkakunnittain on eri määrä havaintoja, joka vaikuttaa mallin luotettavuuteen.

Nykymuodossaan malli on melko luotettava lähes kaikissa suurissa kaupungeissa, mutta pienemmiltä paikkakunnilta datapisteitä on liian vähän. Jääkin pohdittavaksi, että pitäisikö aineistosta niputtaa yhteen tiettyjä paikkakuntia, esimerkiksi markkinahintatasoltaan ja

kooltaan samantyyppiset pääkaupunkiseudun kehyskunnat voisi olla mahdollista laittaa samaan koriin ilman, että ennustetarkkuus merkittävästi kärsii.

Yrityksessä nykyisin käytössä olevassa tarjouslaskentaprosessin prosentuaalista ennustevirhe oli mahdollista tarkastella vertailemalla alkuperäisiä myyntiarvioita ja liikevaihtoa. Toteutunut projektien liikevaihto oli jonkin verran suurempi kuin alkuperäinen myyntiarvio projekteista, joista oli ERP:ssä tarjousvaiheen myyntiarvio merkittynä. Kiinteähintaisissa projekteissa ei liikevaihto periaatteessa voi ylittää tarjottua hintaa, joten ero selittyy luultavasti lisätöillä tai muilla projektikohtaisilla tekijöillä. Liikevaihtona datassa näkyy vain asiakkaalta laskutetut tunnit, joten kate-% on parempi tunnusluku tunnistamaan huonosti kannattaneet kiinteähintaiset projektit, joiden tehdystä työmäärästä osa on mennyt ”omaan takkiin”, koska se ottaa huomioon toteutuneiden työkulujen ja liikevaihdon erotuksen. Tässä tunnusluvussa olikin paljon vaihtelua projektien kesken.

Jatkotutkimuksessa olisi hyvä vertailla ennustevirheen vaihtelua hyödynnettäessä vaihtoehtoisia malleja, kuten gradientintehostukseen perustuvia XGBoost tai LightGBM -menetelmiä (Rankovic et al. 2024, s. 249). Tältä pohjalta voitaisiin arvioida millä malleista on mahdollista saavuttaa pienin ennustevirhe. Ennustevirhettä voitaisiin arvioida myös tarkastelemalla sitä paikkakunta- tai yksikkökohtaisesti. Lisäksi mallin herkkyyttä voitaisiin simuloida tekemällä systemaattinen kokeilu säätämällä syötettyä htm^2 -lukua esimerkiksi 500 m^2 välein ja katsomalla mikä on tuloksen vaihtelu.

5.4.2 Pilottimallin ennustetarkkuuden testaaminen

Käytännön mallin toimivuuden kokeiluna valikoin viisi vuosien 2024–2025 aikana organisaatiossa valmistunutta tarjousta ja vertasin manuaalisesti laskettua hintaa ja työmäärää sekä ennustemallin laskemaa arviota keskenään. Aineistoksi valikoitui seuraavat tarjoukset:

- Helsinki, keskikokoinen asuinkerrostalokohde
- Espoo, keskikokoinen asuinkerrostalokohde
- Tampere, suuri asuinkerrostalokohde
- Turku, keskikokokoinen asuinkerrostalokohde

- Keskikokoinen kaupunki, pienehkö asuinkerrostalokohde

Helsingin kohteen hinta oli ennustemallin arviossa -1 % pienempi kuin tarjouksessa. Espoon kohteen hinta oli ennustemallin arviossa -18 % pienempi kuin tarjouksessa. Tampereen kohteen hinta oli ennustemallin arviossa -14 % pienempi kuin tarjouksessa. Turun kohteen hinta oli ennustemallin arviossa -22 % pienempi kuin tarjouksessa. Keskikokoisen kaupungin kohteen hinta oli ennustemallin arviossa -3 % pienempi kuin tarjouksessa.

Kokeilun avulla voidaan todeta, että ennustemallin €/m^2 -tarkkuus on jo kohtuullinen, mutta riittävän luotettava tarkkuustaso saavutetaan vasta lähtödatan määrää ja laatua vielä edelleen laajentamalla. Jostain syystä testiaineistossa kaikkien kohteiden osalta ennustemalli antoi hieman pienemmän arvion, kuin mitä todellisuudessa oli tarjottu.

5.4.1 Vertailu nykytilan ja koneoppivan ratkaisun välillä

Osa-alue	**Nykyinen Excel-pohjainen käytäntö**	**Koneoppimista hyödyntävä satunnaismetsä-malli**
Tavoite	Työtunnit ja hinta lasketaan manuaalisesti taulukkoon	Automaattinen tunti- ja hintaennuste, joka perustuu historiadataan ja tarkentuu ERP:n tietojen karttuessa
Käyttäjä syöttää	Tunnit SKOL-luokittain ja työvaiheittain	Huoneistoala ja paikkakunta, ERP:sta ladattu historiadata liitetään Excel-tiedostona
Hyödynnettävä data	Käyttäjän käsin antamat tunnit, valmiit hinnastot ja kaavat	Projektidatasta automaattisesti poimitut piirteet: htm^2, log-htm^2, €/htm^2, h/htm^2, projektin kesto, paikkakunta
Laskentaperiaatteet	Perustuu tarjouslaskijan kokemukseen: referenssitunnit, vaihe- ja rooliprosentit, keskituntihinta, tavoitekate	Satoja päätöspuita, satunnaismetsä ennustaa ensin työtunnit ja toisessa metsässä €/htm2 kertoimen. Puut hyödyntävät datasta opittuja raja-arvoja. Lopullinen tulos on metsän keskiarvo.
Tuloste	Työtuntien (h) jakautuminen vaiheittain ja SKOL-	Työtunnit (h), h/htm2, €/htm2 ja hinta (€). Lisäksi pistekaavio, tärkeimmät satunnaismetsään

	luokittain, kate-%, keskituntihinta	vaikuttaneet piirteet, 10 lähintä referenssihanketta
Data	Ei yhteyttä toteumatietoihin, vertailu ERP:stä käsin ja kokemukseen perustuen	Suoraan ERP:stä. Malli oppii historiasta ja päivittyy, kun dataa lisätään.
Helppokäyttöisyys	Manuaalista taulukon täyttöä ja kokemusperäistä arviointia	Käyttäjä syöttää vain htm2 ja paikkakunnan, loppu hoituu automaattisesti
Skaalautuvuus	Skaalautuu huonosti suurille datamäärille, tuloksen laatu riippuu laskijan kokemuksesta	Skaalautuu hyvin datamäärän kasvaessa, malli perustuu koko historiadataan ja raportoi ennusteen tarkkuusmittarit (MAE, R^2)

Taulukko 1. Vertailu: nykytila vs. koneoppiva ratkaisu

Nykyiset Excel-pohjat ovat tehokkaita, kun tarjouslaskijalla on riittävä kokemus ja aikaa täyttää taulukko, mutta ne eivät hyödynnä toiminnanohjausjärjestelmän projektihistoriaa. Satunnaismetsä-algoritmia hyödyntävä malli sen sijaan tekee arvioinnista automaattisempaa. Malli hyödyntää samoja ajantasaisia historiatietoja jokaisessa laskennassa, huomioi eri paikkakuntien hinta- ja työmäärätason ja antaa käyttäjälle dataan pohjautuvan hinta- ja tuntiarvion.

5.4.2 Satunnaismetsän rajoitteet

Koneoppimista hyödyntävän mallin luotettavuuteen eniten vaikuttava tekijä on käytössä olevan lähtödatan laatu ja määrä. Diplomityön aikana rakennettu satunnaismetsään perustuva ennustemalli on yksinkertaistus, eikä se ota huomioon kaikkia arkkitehtisuunnittelun työmääräarviointiin liittyviä nyansseja. Tästä esimerkkinä ovat arkkitehtisuunnittelun tehtäväluettelon ARK18 (Rakennustieto 2020, RT 103253) mukaiset hankkeen tehtäväkokonaisuudet. Lähtödata pyrittiin rakentamaan siten, että se sisältäisi pääasiassa suurempia asuntosuunnitteluhankkeita, joissa lähtökohtaisesti on mukana suurempi osa näistä eri vaiheista. Nykymuodossaan datasta ei kuitenkaan ilmene mitä työvaiheita projektiin on sisältynyt ja onko hanke poikkeuksellisesti esimerkiksi päättynyt jo ennen rakentamista.

Toiminnanohjausjärjestelmässä on jo olemassa projektikohtainen lisätietokenttä ”(Tarjous) Suunnitteluvaiheet”, johon tieto tarjouksen mukaisista suunnitteluvaiheista voidaan kirjata.

Tämän kentän käyttö on vielä kuitenkin melko puutteellista ja kyseinen tieto oli saatavilla vain muutamasta projektista. Näiden tietojen kerääminen olisi edellyttänyt vanhojen tarjousdokumenttien läpikäyntiä, joka ei työmäärällisesti ollut mahdollista tämän tutkimuksen puitteissa.

Kehitetty ennustemalli ei myöskään nykymuodossaan ota huomioon arkkitehtisuunnittelun laadullisia tekijöitä, jotka nousivat aiheena esiin myös haastatteluissa. Esimerkiksi asemakaava, haastava tontti tai asiakaskohtaiset erityistoiveet voivat vaikuttaa suunnittelun työmäärään. RT-kortissa arkkitehdin työmäärän arviointi rakennushankkeessa (Rakennustieto 2013. RT 13-11117) muodostaa suunnittelun vaativuusluokka I-VII työpanoskertoimen, jolla h/brm^2 tunnuslukua hyödyntäen kerrotaan rakennuksen bruttoala lopullisen työmäärän laskemiseksi. Tähän RT-korttiin on kerätty sanalliset kuvaukset kustakin seitsemää eri vaativuusluokkaa olevasta kohteesta.

Kvalitatiivisen tiedon tuominen kvantitatiiviseen laskentamalliin on hieman haastavaa, mutta ei mahdotonta. Jatkokehityksessä tämä voitaisiin toteuttaa esimerkiksi siten, että ERP:iin lisättäisiin projekteille lisätietokenttä, johon projektin vaativuusluokka voitaisiin kirjata perustuen RT-kortin mukaiseen luokitteluun. Vaativuusluokan arviointi tapahtuisi aina jossain määrin subjektiivisesti, mutta luultavasti kuitenkin riittävän tarkasti. Vaihtoehtoisena ratkaisuna voisi olla projektitietoihin liitetty luettelo haastavuutta lisäävistä tekijöistä, joista käyttäjä voisi valita kunkin projektin tapauksessa soveltuvat.

5.5 Kehityskelpoisuus ja hyödynnettävyys

Pilottimalli perustuu tilastolliseen koneoppimiseen ja on itsessään kehityskelpoinen, kunhan lähtödata kertyy ajan myötä kattavammaksi. Jää kuitenkin kiinnostavaksi kysymykseksi, että miten neuroverkkoa, syväoppimista tai generatiivista tekoälyä voitaisiin soveltaa saman ongelman ratkaisemiseksi. Hybridi- ja syväoppimismalleilla pitäisi olla mahdollista saavuttaa korkeampi ennustetarkkuus (mm. Shamim et. al 2025)

Teknisenä toteutuksena syväoppimisen hyödyntämiselle, Microsoft mahdollistaa alustansa kautta esimerkiksi Microsoft Fabric ja Azure Machine Learning tekoälyintegraatioiden hyödyntämisen (Microsoft n.d.f). Nämä jäävät kuitenkin tämän tutkimuksen rajauksen ja oman teknisen osaamiseni ulkopuolelle. Azure Machine Learningin avulla on mahdollista

soveltaa myös GPT-kielimalleja. Yksi tulevaisuuden vaihtoehto voisi olla spesifisti työmäärän ennustamiseen räätälöity kielimali, jonka kanssa käyttäjä voi keskustella ja kysyä kysymyksiä lähtödatasta luonnollisella kielellä.

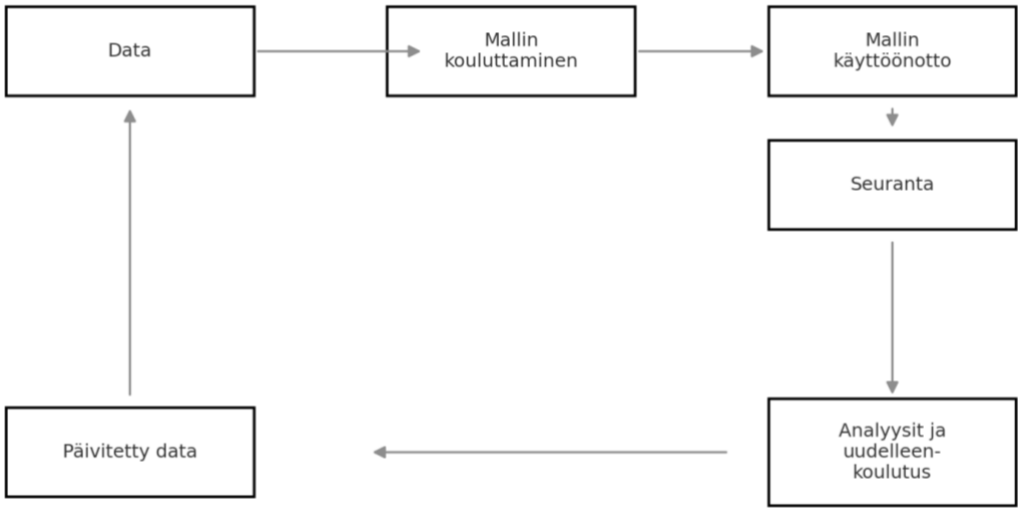

Kuva 25. koneoppimismallin kouluttamisen periaate (mukaillen Microsoft n.d.f)

Toiminnanohjausjärjestelmästä manuaalisesti ladattavan lähtödatan sijasta olisi mahdollista hyödyntää Severa REST API -rajapintaa, joka mahdollistaisi datan haun suoraan toiminnanohjausjärjestelmästä. Tämä mahdollistaisi säännöllisin väliajoin automaattisesti tehtävän tietojen hakemisen ja voisi avata myös muita kiinnostavia vaihtoehtoja. Kohdeyrityksessä on hyödynnetty Severa-lisäosia, joten REST API -rajapinnan avaamisesta on jo kokemuksia.

Mallia voitaisiin myös jatkokehittää ottamaan huomioon projektien työmäärän ja kustannusten SKOL-jakauman ja projektitiimin roolitukset. Tämän tiedon yhdistäminen yksikkökohtaiseen hinnastoon ja kate-%:n mahdollistaisi arvioidun kokonaistyömäärän tarkemman jaottelun suunnittelijoiden kesken. Lisäksi mahdolliset erot suunnittelutehtävän vaiheissa voitaisiin ottaa paremmin huomioon. Toiminnanohjausjärjestelmästä voitaisiin historiallisista projekteista taulukoida arkkitehtisuunnittelun ARK18 tehtäväluettelon mukaiset suunnitteluvaiheet ja niihin menneet tunnit esimerkiksi tuntikirjausten kautta. Myös tarjousvaiheessa oleva aikataulu ja projektin kesto voitaisiin ottaa mukaan selittävinä tekijöinä jatkokehityksessä.

5.5.1 Organisaatiotason vaikutukset

Kehitettyä työmääräarviointimallia voidaan tarkastella teknisenä työkaluna, mutta myös organisaation näkökulmasta. Mallin rakentaminen on rajattu diplomityössä suppeaksi pilotiksi, ja sen käyttöönotto vaatisi arvioimaan organisaation nykyistä toimintaa ja päätöksenteosta laajemminkin. Mallin systemaattinen käyttöönotto tarjouslaskennassa edellyttää muutoksia toimintatavoissa. Tarjousvastaavien tulee luottaa mallin tuottamiin arvioihin, jotta niitä voidaan hyödyntää päätöksenteossa.

Dataan perustuva malli myös jossain määrin haastaa nykyisiä käytäntöjä, joissa hinnoittelussa hyödynnetään edelleen asiantuntija-arvioita. Ennustemallin käyttöönotto voisi toimia tässä tapauksessa myös oppimisvälineenä, verrattaessa mallin antamaa arvoa ja kokemukseen perustuvaa arvioita, voisi olla mahdollista lisätä yhteistä ymmärrystä projektien työmäärän ja kannattavuuden muodostumisesta. Lisäksi malli voi tarjota työkalun johdon ohjaustoimintojen vahvistamiseksi, esimerkiksi, jos mallin tarjoama perustaso otettaisiin osaksi tarjouksen hyväksymisen prosessia.

Ennustemallin potentiaali on korkeimmillaan, jos sen hyödyt saadaan osaksi organisaation arkea. Tämä edellyttää johdon tukea, mutta myös sitä, että malli koetaan tarjoustyötä tekevien näkökulmasta hyödylliseksi, helppokäyttöiseksi sekä aikaa ja vaivaa säästäväksi työkaluksi. Tarjoustyötä tekeviltä henkilöiltä pilottimallista saatu palaute on ollut kiinnostunutta, joten avoimuutta uusille työkaluille on olemassa. Tämä edellyttää käyttäjälähtöistä kehittämistä, käyttökokemuksia tulee systemaattisesti kerätä ja mallia kehittää myös käytettävyyden näkökulmasta.

6 Johtopäätökset ja suositukset

6.1 Vastaukset tutkimuskysymyksiin

Diplomityön päätutkimuskysymys oli, kuinka tekoäly ja projektidata voivat kehittää arkkitehtisuunnitteluprojektien työmääräarviointia ja tukea kannattavampaa tarjouslaskentaa? Tutkimuksen perusteella voidaan todeta, että tekoälyn ja projektidatan avulla on mahdollista kehittää työmääräarviointia erityisesti kiinteähintaisten projektien tarjouslaskennan tukena. Rakennettu yksinkertainen koneoppimismalli kykenee tuottamaan asuntosuunnitteluprojekteista riittävän luotettavan arvion tarvittavasta työmäärästä (h) ja siihen perustuvasta tarjoushinnasta (€/htm^2) hyödyntäen toiminnanohjausjärjestelmästä saatavaa projektihistoriaa.

Datapohjainen ennustemalli voi parantaa tarjouslaskennan ennustettavuutta ja yhdenmukaisuutta sekä mahdollistaa tarjottujen katteiden realistisemman arvioinnin jo tarjousvaiheessa. Tekoälyn hyödyntäminen vähentää arvion subjektiivisuutta tai vähintään antaa tukea hinnoittelupäätöksiin. Paremmat hinnoittelupäätökset voivat tukea projektikatteiden toteutumista ja koko liiketoiminnan kannattavuutta, sillä kirjallisuuden perusteella projektin alkuvaiheessa tehtävillä päätöksillä on suurin vaikutus projektin aikana muodostuviin kustannuksiin.

Tutkimuskysymys oli jaettu kolmeen alakysymykseen. Ensimmäisessä alatutkimuskysymyksessä kysyttiin, mitkä tekijät vaikuttavat työmäärän ennustamiseen arkkitehtisuunnitteluprojektissa?

Tärkeimpiä vaikuttavia tekijöitä ovat suunnittelukohteen huoneistoala ja kohteen sijainti. Käytännössä myös SKOL-jakaumalla (suunnittelijoiden henkilöryhmien työmäärän jakautuminen) vaikuttaa. Toisaalta SKOL-luokkien painotuksia säätämällä voidaan mahdollistaa paremman katteen toteutuminen esimerkiksi tiukan hintakilpailun toimeksiannoissa. Myös yksiköiden ja paikkakuntien välillä vaikuttaa olevan merkittäviäkin eroja työmäärän ja hinnoittelutason vaihteluissa. Lisäksi projektikohtainen haastavuus ja esimerkiksi asemakaavalliset reunaehdot voivat vaikuttaa merkittävästikin toimeksiannon

työmäärään, mutta näitä ei koneoppimismallilla kyetä arvioimaan, vaan siihen tarvitaan kokemusperäistä asiantuntemusta.

Toisena alatutkimuskysymyksenä oli, miten kohdeyrityksen historiallisen projektidatan analytiikkaa voidaan hyödyntää ennustemallin rakentamisessa?

Visma Severa -toiminnanohjausjärjestelmä tarjoaa hyvän lähtökohdan projektihistorian hyödyntämiselle. Projektidataa voidaan hyödyntää suodattamalla ja yhdistämällä olennaiset muuttujat raportille ja kouluttamalla koneoppimismallia näiden pohjalta. Diplomityön teon aikana projektidataa kartutettiin yhteistyössä organisaation projektipäälliköiden ja tarjousvastaavien kanssa, jonka ansiosta saatiin rakennettua 71 projektin kattava aineisto. Tämä toiminnanohjausjärjestelmään koostettu data hyödyttää kaikkia tulevaisuudessa, ja yrityksessä on pyrkimyksenä saada projektidatasta muutenkin kattavampaa. Mitä enemmän projektidataa ja eri muuttujia saadaan kerättyä, sitä paremmin tietoa voidaan hyödyntää tässä koneoppimismallissa ja myös uusien analyysimallien kehittämisessä.

Kolmantena alatutkimuskysymyksenä oli, millaisia mahdollisuuksia ja rajoitteita tekoälypohjaiset työkalut tarjoavat tarjouslaskennan kehittämisessä ja liiketoiminnan kannattavuuden tukemisessa?

Tekoälypohjaiset työkalut, kuten satunnaismetsäalgoritmi, tarjoavat mahdollisuuden tehdä riittävän tarkkoja ja nopeita työmääräarvioita. Vakioitu malli vähentää riippuvuutta yksittäisten asiantuntijoiden kokemuksesta ja tuovat käyttöön dataan perustuvan lähtökohdan. Tämänkaltaiset mallit voivat toimia joko ns. ”tarkistuslaskurina” tai jopa ensisijaisena hinnoittelutyökaluna.

Rajoitteena korostuvat lähtödatan laatu ja kattavuus, erityisesti puuttuvat tai virheelliset projektitiedot. Myös käyttäjien tekninen osaaminen asettaa omat rajoitteensa. Kohdeyrityksessä suurin osa tarjoushinnoittelua tekevistä henkilöistä ei luultavasti nykyisin osaa esimerkiksi hyödyntää Python-koodausta. Excelin osalta osaaminen on vahvaa ja Power BI:tä on muutama henkilö jo hyödyntänyt. Mallin tulee siis olla käyttöliittymältään riittävän helppokäyttöinen ja tähän hyvänä ratkaisuna on mallien ajaminen ”nettisivuna” esimerkiksi Sharepointissa.

Mallin soveltaminen ei myöskään vielä kata laadullisia tekijöitä tai ota huomioon suunnittelutehtävien erityispiirteitä, mikä rajoittaa sen tarkkuutta monimutkaisemmissa tai monivaiheisissa hankkeissa ja tarjouspyynnöissä. Toisaalta Severaan on jo nykyisin

mahdollista kirjata kunkin projektin suunnitteluvaiheet, jolloin myös tätä tietoa olisi mahdollista hyödyntää ja tehdä työmääräarviomallista entistäkin parempaa.

6.2 Kehittämisehdotukset kohdeorganisaatiolle

Diplomityön pohjalta oli mahdollista tunnistaa useita mahdollisia kehittämisaihioita. Lähtödatan kehittäminen on yksi tärkeä aihe. Ennustemallin hyödyntää ERP:ssä olevaa projektihistoriaa ja sen tarkkuus kasvaa, kun datan laatua ja määrää saadaan kasvatettua. Tutkimuksessa käytetty lähtödata-aineisto oli hyvin tarkkaan rajattu, jotta siitä saatiin riittävän laadukasta. Päättyneiden projektien puuttuvia tietoja täydentämällä olisi aineiston kattavuutta mahdollista laajentaa edelleen.

ERP:n projektikohtaisten lisätietokenttien täyttämisen prosessia on suositeltavaa kehittää. Datan laatukäytäntöjen kehittämisen tarve nousi esiin konkreettisesti, kun päättyneiden projektien datassa oli aukkoja. Tämän osalta selkeä roolivastuu olisi tärkeää, jotta on yksiselitteistä, onko projektipäällikön vai tarjousvastaavan vastuulla huolehtia tarjouksen mukaiset laajuus-, hinta- ja työmääräarviotiedot ERP:n projektitietoihin. Selkeintä voisi olla, jos tämä olisi projektipäällikön vastuulla ja tietojen kirjaaminen voitaisiin ottaa osaksi projektin aloituspalaverin sisältöä.

Ennustemallin tekninen toteutus mahdollistaa sen ajamisen selainympäristössä, joka käytännössä tarkoittaa sitä, että sen käyttö on mahdollista sisällyttää oleviin työprosesseihin ilman merkittävää teknistä integraatiota. Tästä huolimatta Severan REST API -integraatiota voitaisiin tutkia lisää, jolloin manuaalisia työvaiheita saataisiin vähennettyä. Rakennettu ennustemalli on konseptiluonteinen ja sen hyödyllisyyttä tulee tutkia vielä lisää käytännössä organisaation tarjoustoiminnassa.

Projektidatan merkitys tulee korostumaan tulevaisuudessa ja yrityksen tulee nähdä se arvokkaana omaisuuseränä, joka mahdollistaa monenlaista analytiikkaa ja tukee tietoon perustuvaa päätöksentekoa. Kone- ja syväoppimista olisi mahdollista hyödyntää yrityksessä laajemminkin kehittämällä yrityksen dataa hyödyntäviä sovelluksia eri käyttötarkoituksiin. Diplomityöprojektin aikana kävin esimerkiksi keskustelun yhden liiketoimintayksikön johtajan kanssa siitä, että samaa mallia voitaisiin hyödyntää asuntosuunnittelun lisäksi myös eräässä toisessa rakennustyypissä. Kyseiset rakennukset ovat luonteeltaan myös hyvin

vakioituja ja niiden suunnittelu hinnoitellaan yleensä laajuusperusteisesti. Keräämällä toiminnanohjausjärjestelmästä h/m^2 €/m^2 -tietoja kyseiseistä kohteista, voitaisiin rakentaa vastaavan tyyppinen ennustemalli kuin mikä tässä diplomityössä rakennettiin asuntosuunnittelun osalta.

Yleisesti ottaen rakennettu malli osoittaa, että tekoälypohjaisia menetelmiä voidaan hyödyntää arkkitehtisuunnittelun tarjouslaskennassa ilman merkittäviä investointeja. Kehittyneempien tekoälymallien rakentaminen vaatisi toki jonkinlaisia investointeja teknologiaan ja henkilöstön koulutukseen. Perustason tekoälyn ja data-analytiikan osaamisen kehittäminen voisi olla kannattava panostus, etenkin paljon numeroiden ja datan kanssa toimiville henkilöille.

Tekoälyn hyödyntämisessä on järkevää priorisoida käyttötapaukset sellaisiin kohteisiin, joissa siihen käytettävillä panoksilla saadaan aikaan suurin mahdollinen hyöty alla kuvatun nelikentän mukaisesti (Savolainen 2024, s. 174). Tämän diplomityön teon aikana kehitetty työkalu osuu mielestäni parhaiten ”Pikavoitot” -laatikkoon. Mallin toteutus oli melko suoraviivaista suhteessa sillä saavutettuun hyötyyn.

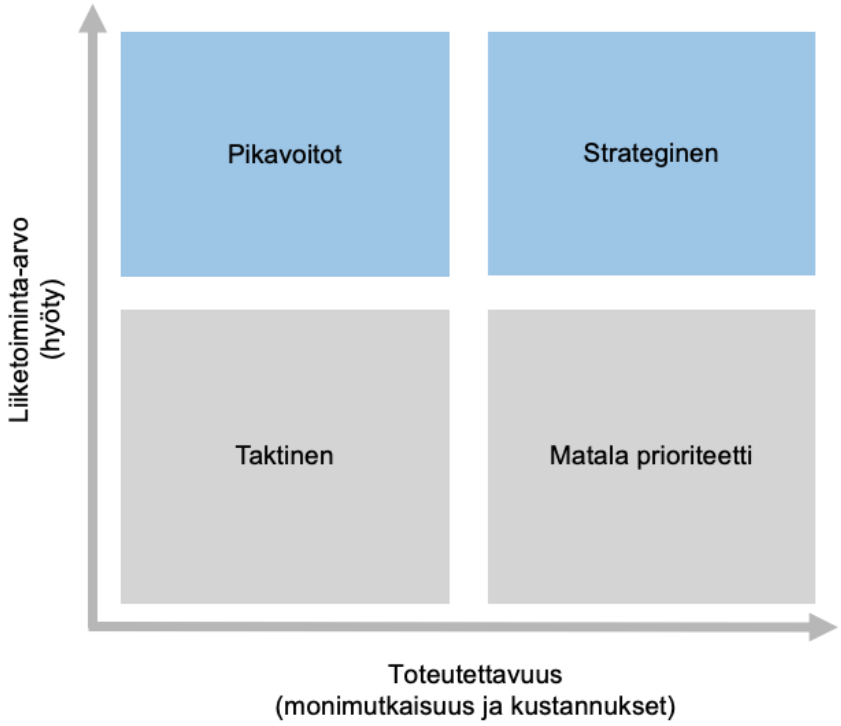

Kuva 26. Tekoälyn käyttötapausten priorisointimatriisi (mukaillen Savolainen 2024, s. 175)

Kohdeyrityksen kontekstiin voisi tekoälyn hyödyntämisen neljästä lähestymistavasta (Ruokonen, Mero, Ritala 2024) sopia erityisesti parantelu- ja laajentumisstrategiat.

Arkkitehtisuunnittelu on todennäköisesti tulevaisuudessakin yrityksen ydinliiketoimintaa. Olevia liiketoimintaprosesseja voitaisiin kuitenkin tehostaa ottamalla käyttöön erilaisia tekoälysovelluksia esimerkiksi projektianalytiikan, tarjouslaskennan ja taloushallinnon puolella.

Laajentumisstrategialla voitaisiin etsiä potentiaalisia uusia liiketoimintamalleja tunnistamalla erityisesti suunnittelun ja projektinhallinnan puolelta mahdollisuuksia, joissa tekoälyä voitaisiin soveltaa. Tähän lukeutuvat muun muassa erilaiset generatiivisen tekoälyn mahdollisuudet, esimerkiksi visualisointikuvien tai pohjapiirrosten generoimisen puolella, jotka eivät aiheena sisältyneet tämän diplomityön rajaukseen.

Työmäärälaskentamallin implementaation mahdollinen tiekartta:

Q3/2025 Projektidatan täydentäminen, työmäärälaskentamallin pilotointi käytännön tarjouslaskennassa

Q4/2025 Sharepoint ja Visma Severa REST API -integraatio, mallin ja sen käyttöliittymän jatkokehittäminen

Q1/2026 Ennustemallin laajentaminen muihin suunnittelulajeihin (hoiva- ja päiväkotisuunnittelu ym.)

Q2–Q4/2026 Uudet toiminnallisuudet: projektisuunnittelu (työmäärän automaattinen jako työvaiheisiin), riskiennusteet

6.3 Johtopäätökset ja jatkotutkimus

Tekoälyyn ja projektidataan perustuvaa työmäärälaskentaa voidaan tutkimuksen perusteella hyvin soveltaa arkkitehtisuunnitteluprojekteissa. Työmääräarviointimallin kehittäminen avaa samalla mahdollisuuksia laajempaan datan hyödyntämisen ja tiedolla johtamisen kulttuuriin. Nykyisen toiminnanohjausjärjestelmän täysimääräinen hyödyntäminen ja datan kertyminen ovat vieneet kohdeyrityksen kulttuuria jo vahvemmin tähän suuntaan. Jatkokehityksen kannalta voisi olla hyödyllistä arvioida, miten ennusteet voisivat toimia osana koko projektin elinkaaren hallintaa, ei ainoastaan tarjousvaiheessa.

Projektidatan jatkojalostamiseen ja visualisointiin osoittautui Python-kieli hyväksi työkaluksi sen joustavuuden ja kattavien laajennuskirjastojen ansiosta. Rakennettu

työmääräennustemalli perustuu satunnaismetsäalgoritmiin, joka soveltuu hyvin yksinkertaiseen työmäärän ennustamiseen. Jatkotutkimuksena voitaisiin tutkia, miten syväoppimismallit, kuten neuroverkot voisivat parantaa ennusteita laajemmasta datamäärästä, vaikkakin esimerkiksi neuroverkon kouluttaminen on teknisesti monimutkaisempaa. GPT-mallit voisivat lisäksi toimia käyttäjän tukena keskustelupohjaisessa analytiikassa ja päätöksenteon tukena.

Rakennetun ennustemallin käyttö edellyttää tällä hetkellä manuaalista Excel-datan lataamista toiminnanohjausjärjestelmästä, joka asettaa rajoitteita tehokkuuden ja tietojen ajantasaisuuden näkökulmasta. REST API -rajapinta tarjoaa mahdollisuuden automatisoida datan keruu ja jatkokehitysvaiheessa voitaisiin luoda skripti, joka päivittää mallin lähtödatan automaattisesti. Lähtödatan aukottomuus ja laatu osoittautuivat käytännössä tärkeiksi tekijöiksi, kuten kirjallisuudessakin mainitaan. Mallin käyttöliittymän tulisi olla mahdollisimman intuitiivinen ja helppokäyttöinen, jotta sen käyttö saataisiin omaksuttua osaksi yrityksen arkea. Sharepoint-pohjainen toteutus on tälle hyvä alku, ja jatkossa voitaisiin kokeilla mahdollista Teams-integraatiota.

Arkkitehtisuunnitteluprojektien analytiikan osalta työssä keskityttiin numeerisiin muuttujiin, kuten pinta-alaan ja erinäisiin euro- ja tuntimääräisiin tunnuslukuihin. Rakennussuunnittelussa kuitenkin myös laadulliset tekijät, kuten esimerkiksi suunnittelutehtävän vaativuus tai asemakaavalliset reunaehdot ovat todella tärkeitä. Tulevaisuudessa voisi olla mahdollista kehittää järjestelmä, jossa näitä laadullisia piirteitä kirjattaisiin toiminnanohjausjärjestelmään, jolloin niitä voitaisiin hyödyntää ennustemalleissa.

Nykyisessä muodossaan ennustemalli on rajattu kiinteähintaisiin suunnittelutoimeksiantoihin ja koskemaan ainoastaan asuntosuunnitteluhankkeita. Jatkotutkimusaiheena voitaisiin tutkia, miten sama malli soveltuu työmääräarvioon perustuviin suunnittelutarjouksiin tai eri rakennustyypeille. Toinen mielenkiintoinen jatkotutkimusaihe olisi verrata työmääräennusteiden osumatarkkuutta tai projektien kannattavuutta asiakkaiden välillä. Onko esimerkiksi tunnistettavissa asiakkaita, joiden kanssa projektit menevät useammin ”pitkäksi” tai projektikate on heikompi, ja tehdä analyysi tähän johtaneista syistä.

Ennustemalli ei myöskään ota kantaa suunnittelijoiden tai yksiköiden välisiin tehokkuuseroihin, ja jatkokehityksessä voitaisiin huomioida myös näitä tekijöitä. Toiminnanohjausjärjestelmästä on mahdollista koostaa mukaan taulukkoon myös projektin työryhmä. Tällä hetkellä lähtödataraportilla on otettu mukaan vain tieto projektipäälliköistä. Digitaalisten menetelmien osalta yrityksessä on käytössä kaksi alan johtavaa suunnitteluohjelmistoa Archicad ja Autodesk Revit. Voisi olla kiinnostavaa vertailla keskenään projekteja, jotka on tehty eri suunnitteluohjelmistoilla ja onko tältä pohjalta tunnistettavissa tehokkuus- tai kate-eroja.

Organisaation tasolla, tekoälytransformaation edistämiseksi, pystytään tekoälytyökaluihin liittyvää osaamista luultavasti kehittämään parhaiten käytännön tekemisen kautta. Olisikin hyvä pyrkiä rakentamaan kulttuuria, jossa kannustetaan henkilöstöä tekoälyn käyttämiseen ja soveltamiseen eri käyttötarkoituksissa. Painopiste olisi tämän osalta hyvä olla ihmisissä sekä heidän osaamisessaan. Teknologia ja prosessit ovat myös tärkeitä, mutta kuitenkin pienemmässä roolissa muutoksen kannalta. Aiheeseen on järkevää panostaa, sillä tekoälytransformaatiossa onnistuminen voi olla ratkaisevaa yrityksen tulevaisuuden kilpailukyvyn näkökulmasta (mm. Savolainen 2024, s. 220).

Mallin kehittäminen osoitti käytännössä, että tekoälyn soveltaminen ei välttämättä vaadi yritykseltä suuria investointeja teknologiaan, vaan on toteutettavissa suhteellisen kevyin ratkaisuin. Tämä voi madaltaa kynnystä tekoälyratkaisujen käyttöönotolle laajemminkin yrityksessä. Organisaation datakypsyys, kulttuuri ja toimiala vaikuttavat tekoälyn omaksumiseen yllättävän paljon. Pelkkä tekninen toteutus ei kuitenkaan riitä, vaan tarvitaan myös muutoksia ajattelutavassa ja prosesseissa. Ennustemallille olisi hyvä määrittää selkeä omistajuus ja ylläpitovastuu sen jatkokehittämisestä.

Diplomityö tarjosi kiinnostavan mahdollisuuden yhdistää teoria ja konkreettinen kohdeyritystä hyödyntävä kehittämistyö. Tutkimuksen teon aikana syvensin omaa osaamistani erityisesti tekoälyn ja koneoppimisen perusteista. Python ja Power BI eivät olleet minulle entuudestaan tuttuja työkaluja, mutta opettelin niitä prosessin aikana, joka oli mielenkiintoista ja palkitsevaa. Työ auttoi hahmottamaan datan merkitystä ja sen hyödyntämisen mahdollisuuksia asiantuntijaorganisaatiossa. Tästä näkökulmasta diplomityö vahvisti omaa kiinnostustani datalähtöiseen analytiikkaan ja liiketoiminnan kehittämiseen.

Lähteet

AACE International (2021) 104R-19: Communicating Expected Estimate Accuracy.

Alpaydin, E., 2014. Introduction to machine learning. MIT press.

Amazon Web Services (n.d.a) What is reinforcement learning? Viitattu 12.5.2025. Saatavissa https://aws.amazon.com/what-is/reinforcement-learning

Amazon Web Serivces (n.d.b) What is generative AI? Viitattu 12.5.2025. Saatavissa https://aws.amazon.com/what-is/generative-ai/

Amazon Web Services (n.d.c). What is a neural network? Viitatttu 22.5.2025. Saatavissa https://aws.amazon.com/what-is/neural-network/

American Institute of Architects. & Hayes, R. L. (2014) The architect's handbook of professional practice. 15th ed. Hoboken: Wiley.

Artto, K. A. et al. (2006) Projektiliiketoiminta. Helsinki: WSOY.

Bhansali, R., 2013. Data Governance: Creating Value from Information Assets. Boca Raton, FL: CRC Press.

Carenholm, S. 2007. Arkkitehtitoimisto bisneksenä. Miten kehittää arkkitehtiyrityksen liiketoimintaa. Suom. T. Sirkiä. Helsinki: Rakennustieto Oy.

Cheng, M.-Y. et al. (2025) Hybrid deep learning model for accurate cost and schedule estimation in construction projects using sequential and non-sequential data. Automation in construction. 170105904-.

Chowdhary, K. R. (2020) Fundamentals of Artificial Intelligence. 1st ed. 2020. New Delhi: Springer India.

Downey, A.B. 2015. Think Python: How to Think Like a Computer Scientist. 2. painos. Viitattu 17.5.2025. Saatavissa https://greenteapress.com/thinkpython/html/index.html

Eloundou, T., Manning, S., Mishkin, P. and Rock, D., 2024. GPTs are GPTs: Labor market impact potential of LLMs. Science, 384(6702)

Engwall, M. & Jerbrant, A. (2003) The resource allocation syndrome: the prime challenge of multi-project management? International journal of project management. 21 (6), 403–409.

Euroopan parlamentti. (2020). Mitä tekoäly on ja mihin sitä käytetään? Viitattu 15.6.2025. Saatavissa https://www.europarl.europa.eu/topics/fi/article/20200827STO85804/mita-tekoaly-on-ja-mihin-sita-kaytetaan

Google Cloud. (n.d.a). Artificial intelligence vs. machine learning: What's the difference? Viitattu 10.5.2025. Saatavissa https://cloud.google.com/learn/artificial-intelligence-vs-machine-learning

Google Cloud. (n.d.b) What is supervised learning? Viitattu 12.5.2025. Saatavissa https://cloud.google.com/discover/what-is-supervised-learning

Habib, O. et al. (2025) Ensemble learning framework for forecasting construction costs. Automation in construction. 170105903-.

Hans, E. W., Herroelen, W., Leus, R. & Wullink, G. (2007). A hierarchical approach to multi-project planning under uncertainty. Omega. Vol. 35(5), pp.563–577.

Helsingin yliopisto. 2024. Data Analysis with Python 2024–2025. Viitattu 17.5.2025. Saatavissa https://courses.mooc.fi/org/uh-cs/courses/data-analysis-with-python-2024-2025

Hinterhuber, A. (2008) Customer value-based pricing strategies: why companies resist. The Journal of business strategy. 29 (4), 41–50.

Hinterhuber, A. & Liozu, S. (2012) Is It Time to Rethink Your Pricing Strategy? MIT Sloan management review. 53 (4), 69-.

ISO (2022). ISO 8000-1:2022 Data quality — Part 1: Overview. Viitattu 26.5.2025. Saatavissa https://www.iso.org/standard/81745.html

Kananen, H. & Puolitaival, H. (2019) Tekoäly: bisneksen uudet työkalut. Helsinki: Alma Talent Oy.

Kananen, J. & Jyväskylän ammattikorkeakoulu. (2012) Kehittämistutkimus opinnäytetyönä: kehittämistutkimuksen kirjoittamisen käytännön opas. Jyväskylä: Jyväskylän ammattikorkeakoulu.

Kontio, J. & Puttonen, M. (2024). Tekoäly yskii ilman kunnon dataa. EY Suomi. Viitattu 26.5.2025. Saatavissa https://www.ey.com/fi_fi/insights/ai/tekoaly-yskii-ilman-kunnon-dataa

Koskenvesa, A. et al. (2018) Rakennushankkeen kustannushallinta. Helsinki: Rakennustieto Oy.

Kämäräinen, J. & Otatieto, kustantaja (2023) Koneoppimisen perusteet. Helsinki: Otatieto.

Lewis, J. P. (2007) Fundamentals of project management. 3rd ed. Saranac Lake: American Management Association.

Merilehto, A. (2018) Tekoäly: matkaopas johtajalle. Helsinki: Alma Talent.

Microsoft. (n.d.a). Forecast and FORECAST.LINEAR functions. Microsoft. Viitattu 17.5.2025. Saatavissa https://support.microsoft.com/en-us/office/forecast-and-forecast-linear-functions-50ca49c9-7b40-4892-94e4-7ad38bbeda9

Microsoft. (n.d.b). About Power Query in Excel. Viitattu 18.5.2025. Saatavissa https://support.microsoft.com/en-us/office/about-power-query-in-excel-7104fbee-9e62-4cb9-a02e-5bfb1a6c536a

Microsoft. (n.d.c). What is Power Query? Viitattu 18.5.2025. Saatavissa https://learn.microsoft.com/en-us/power-query/power-query-what-is-power-query

Microsoft. (n.d.d). Use Python in Power BI Desktop. Viitattu 18.5.2025. Saatavissa https://learn.microsoft.com/en-us/power-bi/connect-data/desktop-python-in-query-editor

Microsoft (n.d.e). What is Power BI? Viitattu 18.5.2025. Saatavissa https://learn.microsoft.com/en-us/power-bi/fundamentals/power-bi-overview

Microsoft. (n.d.f) What is Azure Machine Learning? Viitattu 20.5.2025 Saatavissa https://learn.microsoft.com/en-us/azure/machine-learning/overview-what-is-azure-machine-learning

Momeni, K. & Martinsuo, M. M. (2018) Allocating human resources to projects and services in dynamic project environments. International journal of managing projects in business. 11 (2), 486–506.

Neilimo, K. & Uusi-Rauva, E. (2005) Johdon laskentatoimi. 6. uud. p. Helsinki: Edita.

Niazi, A., Dai, J. S., Balabani, S. & Seneviratne L. 2006. Product Cost Estimation: Technique Classification and Methodology Review. Journal of Manufacturing Science and Engineering. Vol. 128, Nro. 2, s. 563-575.

Peffers, K. et al. (2020) Design Science Research Process: A Model for Producing and Presenting Information Systems Research. arXiv.org.

Pelin, R. (2009) Projektihallinnan käsikirja. 6. uudistettu painos. Helsinki: Projektijohtaminen Oy Risto Pelin.

Project Management Institute (2013) A Guide to the Project Management Body of Knowledge (PMBOK ® Guide). 5th edition. Newtown Square, PA: Project Management Institute, Inc. (PMI).

Porter, M. E. 1985. The Competitive Advantage: Creating and Sustaining Superior Performance. NY: Free Press.

Rankovic, N. et al. (2024) Recent Advances in Artificial Intelligence in Cost Estimation in Project Management. 1st edition. Vol. 6. Cham: Springer.

Redman, T. C. (2018). If Your Data Is Bad, Your Machine Learning Tools Are Useless. Harvard Business Review. Viitattu 26.5.2025. Saatavissa https://hbr.org/2018/04/if-your-data-is-bad-your-machine-learning-tools-are-useless

Redman, T. C. (1995). Improve data quality for competitive advantage. MIT Sloan Management Review.

Rowley, J. (2007) The wisdom hierarchy: representations of the DIKW hierarchy. Journal of information science. 33 (2), 163–180.

RT 10-11226. 2016. Talonrakennushankkeen kulku. Kustannusten muodostuminen ja ohjaus. RT-ohjekortti. Rakennustieto.

RT 103253. 2020. Arkkitehtisuunnittelun tehtäväluettelo ARK18. RT-ohjekortti. Rakennustieto.

RT 103254. 2020. Pääsuunnittelun tehtäväluettelo PS18. RT-ohjekortti. Rakennustieto.

RT 13-10860. 2005. Suunnittelun johtaminen rakennushankkeessa. RT-ohjekortti. Rakennustieto.

RT 13-11117. 2013. Arkkitehdin työmäärän arviointi rakennushankkeessa. RT-ohjekortti. Rakennustieto.

RT 13-11182. 2015. Konsulttisopimuksen laatiminen. RT-ohjekortti. Rakennustieto.

Ruokonen, M, Mero, J, Ritala, P. 2024. LJT-tutkijablogi: Miten hyödyntää generatiivista tekoälyä strategisesti? 22.2.2024. LTJ-tutkijablogi. Viitattu 25.5.2025 Saatavissa https://www.boardman.fi/ljt-blogi/ljt-tutkijablogi-miten-hyodyntaa-generatiivista-tekoalya-strategisesti/

Salo, I. (2014) Big data & pilvipalvelut. Jyväskylä: Docendo.

Salesforce. (2024). What is agentic AI? Viitattu 22.5.2025. Saatavissa https://www.salesforce.com/agentforce/what-is-agentic-ai/

SAP. (n.d.). Mitä tekoäly on? Viitattu 15.6.2025. Saatavissa https://www.sap.com/finland/products/artificial-intelligence/what-is-artificial-intelligence.html

Savolainen, T. (2024) Tekoälyllä kilpailuetua: opas johtoryhmille ja hallituksille. Helsinki: Alma Insights.

Schwalbe, K. (2015) Introduction to project management. 5th ed. Minneapolis, Schwalbe Publishing.

Shamim, Md. M. I. et al. (2025) Advancement of Artificial Intelligence in Cost Estimation for Project Management Success: A Systematic Review of Machine Learning, Deep Learning, Regression, and Hybrid Models. Modelling. 6 (2), 35-.

Sweigart, A. 2015. Automate the Boring Stuff with Python. Viitattu 17.5.2025. Saatavissa https://automatetheboringstuff.com/

Telivuo, S. (2018) Satunnaismetsä-koneoppimismenetelmä: teoria ja soveltaminen. Helsingin yliopisto.

Tonchia, Stefano. (2008) Industrial Project Management: Planning, Design, and Construction. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg.

IBM. (2024a). Generative AI. IBM Think. Viitattu 10.5.2025. Saatavissa https://www.ibm.com/think/topics/generative-ai

IBM. (2024b). What is artificial intelligence (AI)? IBM Think. Viitattu 10.5.2025. Saatavissa https://www.ibm.com/think/topics/artificial-intelligence

IBM. (2021). What is strong AI? Viitattu 11.5.2025. Saatavissa https://www.ibm.com/think/topics/strong-ai

IBM. (2023a). Types of Artificial Intelligence. Viitattu 11.5.2025. Saatavissa https://www.ibm.com/think/topics/artificial-intelligence-types

IBM. (2023b). Five machine learning types to know. Viitattu 12.5.2025. Saatavissa https://www.ibm.com/think/topics/machine-learning-types

IBM (n.d.a) What is random forest? Viitattu 18.5.2025. Saatavissa https://www.ibm.com/think/topics/random-forest

IBM. (n.d.b). What is a neural network? Viitattu 22.5.2025. Saatavissa https://www.ibm.com/think/topics/neural-networks

Vartiainen, M., Ruuska, I. ja Kasvi, J. J. J. (2003) Projektiosaaminen – dynaamisen organisaation voimavara. Tampere: Teknologiainfo Teknova Oy.

van Aken, J. E. et al. (2007) Problem Solving in Organizations: A Methodological Handbook for Business Students. 1st edition. Cambridge: Cambridge University Press.

VanderPlas, J. (2016a). Python Data Science Handbook. Sebastopol, CA: O'Reilly Media. Saatavissa https://jakevdp.github.io/PythonDataScienceHandbook/

VanderPlas, J. (2016b). A Whirlwind Tour of Python. O'Reilly Media. Saatavissa https://github.com/jakevdp/WhirlwindTourOfPython

Visma Severa, 2025. Ominaisuudet. Viitattu 28.4.2025. Saatavissa https://severa.fi/ominaisuudet/

Visma Severa, 2025a. Tarjouksen luonti. Viitattu 28.4.2025. Saatavissa https://support.severa.com/fi/support/solutions/articles/77000545955-tarjouksen-luonti

Walker, A. (2015) Project management in construction. Sixth edition. West Sussex, England: Wiley Blackwell

Liitteet

Liite 1. Haastattelupohja

Haastattelupohja - Kiinteähintaisten toimitusprojektien kannattavuudenhallinnan nykytilan kartoitus

1. Kuvailisitko kiinteähintaisten projektien tarjouslaskentaprosessin.
2. Mitä tietoja tarjouslaskennassa hyödynnetään? Ovatko luvut tarkkoja vai suuntaa antavia?
3. Onko tarjouslaskentaprosessi joka kerta samanlainen, vai vaihteleeko se riippuen projektista tai henkilöstä?
4. Käytetäänkö tarjouslaskentaan riittävästi aikaa ja huomioidaanko hinnoittelumallissa riskit sekä projektikate riittävän hyvin?
5. Hyödynnetäänkö jo toteutuneiden projektien tietoja tarjouslaskennassa? Millä tavoin?
6. Miten projektin toteutuksessa seurataan, että alkuperäinen kustannusarvio pitää paikkansa?
7. Miten hankkeen riskit arvioidaan ja miten niitä ennaltaehkäistään?
8. Kuinka usein arvioidaan projektin kustannustavoitteet ja aikarajat? Millä tavoin ennakoidaan mahdollisia ylittymiä?
9. Miten mahdollistetaan lisätöiden neuvottelu kiinteähintaisissa hankkeissa?
10. Miten projektin onnistumista arvioidaan sen päätyttyä ja miten onnistumisen tai epäonnistumisen syistä saatu oppi siirretään tuleviin projekteihin?
11. Miten projektinhallinnan prosesseja voitaisiin kehittää niin, että kiinteähintaiset projektit olisivat taloudellisesti kannattavampia?
12. Mitkä ovat suurimmat haasteet projektin tuloksen hallinnassa ja mitä parannuksia siihen voitaisiin tehdä?