

Olli Laiho

**ÄLYKÄSTÄ TUOTTAVUUDEN NOSTOA  
RAKENNUSTEOLLISUUTEEN**



JYVÄSKYLÄN YLIOPISTO  
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA  
2024

# TIIVISTELMÄ

Laiho, Olli

Älykästä tuottavuuden nostoa rakennusteollisuuteen

Jyväskylä: Jyväskylän yliopisto, 2024, 31 s.

Tietojärjestelmätiede, kandidaatintutkielma

Ohjaaja(t): Halttunen, Veikko

Rakennusteollisuuden tuottavuuskasvu ei ole pysynyt kokonaistalouden tuottavuuskasvun tahdissa. Viivästyksset ja budjettien ylitykset ovat yleisiä ongelmia alalla ja suurimmiksi aiheuttajiksi on havaittu tehoton projektisuunnittelu ja suunnitteluvirheistä johtuvat viivästyksset. Rakennusteollisuus on myös toiseksi vähiten digitalisoitunut ala, sijoittuen ainoastaan yhdeksi alaksi lasketun maatalouden ja metsästyksen edelle. Tekoälyn kehitys on ottanut suuria harppauksia eteenpäin sen jälkeen, kun IBM:n Deep Blue voitti Garry Kasparovin shakissa vuonna 1997. Vuonna 2016 AlphaGo voitti gon 18-kertaisen maailmanmestari Lee Sedolin ja näin osoitti tekoälyn tehokkuuden datan läpikäynnissä ja arvioiden tarkkuudessa. Tekoälyä hyödynnetään jo monilla aloilla, mutta rakennusteollisuudessa kehitys- ja tutkimustyö on jäänyt toissijaiseen asemaan - rakennusteollisuuden tuottamista voitoista käytetään ainoastaan yksi prosentti tutkimustyöhön. On havaittu, että yritysten kasvattaessa tekoälypatenttien määrää kymmenellä prosentilla, myös yrityksen tuottavuus nousee viidellä prosentilla. Vaikutus on tällä hetkellä nähtävissä lähinnä pienillä ja keskisuurilla yrityksillä, mikä voi johtua suurien yritysten kankeudesta sopeutua muuttuviin tilanteisiin tai haluttomuudesta ylipäätään lisätä tekoälypatenttien määrää. Tämän kirjallisuuskatsauksen tavoitteena on selvittää, kuinka tekoälyllä voidaan parantaa rakennusteollisuuden tuottavuutta. Tutkielmassa käydään läpi neljä tutkimusta, joissa käsitellään budjettien arviointia, tuottavuuteen vaikuttavien tekijöiden kartoittamista, työntekijöiden tuottavuuden seuraamista ja riskienhallintaa. Jokaisessa edellämainitussa tutkimuksessa on hyödynnetty tekoälyä ja tutkimusten tulokset vaikuttavat lupaavilta. Tekoälyllä on havaittavissa potentiaalia erityisesti projektisuunnittelun tehostamisessa.

Asiasanat: tekoäly, rakennusala, tuottavuus, projektisuunnittelu

## ABSTRACT

Laiho, Olli

Intelligent productivity increase for the construction industry

Jyväskylä: University of Jyväskylä, 2024, 31 pp.

Information Systems Science, Bachelor's Thesis

Supervisor(s): Halttunen, Veikko

The productivity growth in the construction industry has not kept pace with the overall economy's productivity growth. Delays and budget overruns are common problems in the industry, and inefficient project planning and delays due to design errors have been identified as the major causes. Additionally, the construction industry ranks as the second least digitized sector, trailing only agriculture and hunting. The development of artificial intelligence has taken significant leaps forward since IBM's Deep Blue defeated Garry Kasparov in chess in 1997. In 2016, AlphaGo defeated the 18-time world champion Lee Sedol in Go, demonstrating the efficiency of artificial intelligence in processing data and making evaluations. Artificial intelligence is already being utilized in many fields, but in the construction industry, research and development have taken a secondary position - only one percent of the profits generated by the construction industry are used for research. It has been observed that as companies increase the number of AI patents by ten percent, their productivity also increases by five percent. The impact is currently most visible in small and medium-sized enterprises, which may be due to the inability of large companies to adapt to changing situations or reluctance to increase the number of AI patents. The aim of this literature review is to explore how artificial intelligence can improve productivity in the construction industry. The thesis reviews four studies that address budget estimation, identifying factors affecting productivity, monitoring employee productivity, and risk management. Artificial intelligence has been utilized in each of the studies, and the results appear promising. There is potential for artificial intelligence, particularly in streamlining project planning.

Keywords: artificial intelligence, construction industry, productivity, project planning

## KUVIOT

KUVIO 1 Ohjatun oppimisen opetus ja testaus .....	13
KUVIO 2 Neuroverkon kerrokset .....	14

## TAULUKOT

TAULUKKO 1 Henkilöt-, ikä-, sukupuoli- ja palkkasarakkeissa datayksiköitä. palkkasarakkeessa alimmaisena henkilöiden keskipalkka, eli informaatiota. ....12

TAULUKKO 2 Satunnainen 20 tapauksen otanta putkitöiden todellisista hinnoista sekä tekoälymallin arviot. hinnat on ilmoitettu puntina ja tulee kertoa tuhannella. ....19

TAULUKKO 3 Kolme parasta ja huonoiten suoriutunut algoritmi käyttäjästä riippuvaisessa skenaariossa, jossa suoritettiin kaikki toiminnot.....23

# SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT JA TAULUKOT

1	JOHDANTO.....	6
2	TUOTTAVUUS.....	8
	2.1 Tuottavuuden määrittely.....	8
	2.2 Digitalisaation vaikutus tuottavuuteen.....	9
3	TEKOÄLY.....	11
	3.1 Tekoälyn kehittyminen.....	11
	3.2 Data ja informaatio.....	12
	3.3 Tiedonlouhinta ja koneoppiminen.....	12
	3.4 Tekoälyn vaikutus tuottavuuteen.....	15
	3.5 Tekoälyn luomat haasteet.....	16
	3.5.1 Automaation tyytyväisyys.....	16
	3.5.2 Roskaa sisään, roskaa ulos.....	16
4	TEKOÄLYN HYÖDYNTÄMINEN RAKENNUSALLA.....	18
	4.1 Tekoäly budjetin arvioinnissa.....	18
	4.2 Tuottavuuteen vaikuttavien tekijöiden kartoittaminen.....	20
	4.3 Työntekijän tuottavuuden seuraaminen.....	21
	4.4 Riskienhallinta.....	23
5	YHTEENVETO.....	26
6	LÄHTEET.....	28

# 1 JOHDANTO

Rakennusala kärsii suurista tuottavuusongelmista ja kaksi suurinta tuottavuuteen negatiivisesti vaikuttavaa tekijää ovat tehoton projektisuunnittelu ja suunnitteluvirheiden aiheuttamat viivästyksset (Naoum, 2016). Suurimmat virheet tuottavuuden kannalta tehdään siis jo ennen kuin varsinaiset rakennustyöt edes aloitetaan. Changalin, Mohammadin ja van Nieuwlandin 2015 julkaiseman tutkimuksen mukaan myös päätöksenteossa ja hankintaprosesseissa ei saavuteta vaadittua nopeutta ja lyhyen aikavälin tavoitteiden hahmottaminen aiheuttaa haasteita. Samaisessa tutkimuksessa mainitaan myös, että pääurakoitsijat hyödyntävät mieluummin jo aiemmin käyttämiään aliurakoitsijoita ja henkilöitä, kuin etsisivät oikeasti parhaat vaihtoehdot kuhunkin työhön. Myös Naoum (2016) mainitsee tutkimuksessaan huonosti hoidetun roolituksen, erityisesti kokemattomien rakennuttajien sekä työnjohtajien osalta, vaikuttavan huomattavasti työn tuottavuuteen.

Rakennusala piinaavat myös vaikeudet pysyä aikatauluissa sekä jatkuvat budjettien ylitykset. 98 prosenttia hankkeista budjetti ylittyi yli 30 prosentilla ja 77 prosenttia hankkeista oli vähintään 40 prosenttia myöhässä (Changali ym., 2015). Pelkästään suuria rakennusprojekteja tarkastellessa budjetit ylittyivät 80 prosentilla ja ne valmistuivat vähintään 20 prosenttia aikataulusta jäljessä (Agarwal ym., 2016). Kiristyviin aikatauluihin on pyritty perinteisesti vastaamaan palkkaamalla työmaille enemmän työvoimaa sen sijaan, että kehitettäisiin parempia ja tehokkaampia menetelmiä tuottavuuden parantamiseksi (Hanna, 2010). Piittaamattomuus uuden teknologian käyttöönotosta ja kehityksestä laskee tasaisesti urakoitsijoiden voittoja. Jos tuottavuuden kasvu onnistuttaisiin nostamaan nykyisestä yhdestä prosentista vastaamaan kokonaistalouden 2,8 prosentin kasvua, rakennusalan globaalin arvon arvioidaan nousevan 1 410 miljardia euroa vuodessa. Tämä voisi tehostaa globaalia bruttokansantuotetta kahdella prosentilla. (Barbosa ym., 2017).

Iso-Britannian rakennusala koskeva tutkimus paljasti, että suurin osa urakoitsijoista ei seuraa tuottavuutta projektitasolla (Chan & Kaka, 2003) vaikka tähän on kehitetty monia tekniikoita, joista urakoitsijat voisivat valita omiin

tarpeisiinsa parhaiten sopivat työkalut (Lin & Huang, 2009; Zhao & Dungan, 2014). Rakennusala vaivaa selvästi jonkin asteinen muutosvastarinta. Rakennusala on toiseksi vähiten digitalisoitunut ala, jättäen taakseen ainoastaan yhdeksi alaksi lasketun maatalouden ja metsästyksen (Khanna ym., 2016). Rakennusalan tuottamista voitoista käytetään ainoastaan noin prosentin verran tutkimukseen ja kehitystyöhön (Changali ym., 2015). Tuottavuuden kasvulukuja tarkastellessa suuremmalle rahoitukselle olisi todellakin tarvetta.

Rakennusalan tuottavuuteen liittyvät ongelmat yhdistettynä uuden teknologian vähäiseen hyödyntämiseen onkin syytä miettiä, voisiko tekoälystä löytyä mahdollisia ratkaisuja tuottavuusongelman ratkaisemiseksi. Tämä kandidaatintutkielma on toteutettu kirjallisuuskatsauksena ja sen tavoitteena on kartoittaa jo olemassa olevia tai kehitteillä olevia tekoälyratkaisuja rakennusalan tuottavuusongelmiin. Tutkielman tutkimuskysymys on:

1. Kuinka tekoälyllä voidaan parantaa rakennusteollisuuden tuottavuutta?

Tutkielman lähdekirjallisuutena on käytetty vertaisarvioituja tieteellisiä artikkeleita, konferenssijulkaisuja, raportteja ja verkkosivuja. Suurin osa tutkielmassa käytetyistä artikkeleista ja konferenssijulkaisuista on JUFO-luokitukseltaan tasoa yksi, mikä oli myös vähimmäisvaatimus lähdeaineiston valinnassa. Verkkosivuilta haettua tietoa on käytetty tilastoihin ja termien määrittelyyn. Lähdekirjallisuutta hakiessa on käytetty yleisimmin hakusanoja "construction", "productivity", "ai", "artificial intelligence", "machine learning" ja "data mining". Pääosin lähteet on haettu JYKDOKin, Google Scholarin ja ScienceDirectin tietokannoista.

Tutkielma koostuu viidestä pääluvusta. Toisessa luvussa käsitellään tuottavuuden käsitettä ja digitalisaation on vaikutusta siihen. Kolmannessa luvussa tutustutaan tekoälyn historiaan, tiedonlouhintaan ja koneoppimiseen, tekoälyn vaikutuksesta tuottavuuteen sekä tarkastellaan joitakin tekoälyn haasteita. Neljännessä luvussa käydään läpi neljä erilaista tutkimusta, joissa on kehitetty keinoja tekoälyn hyödyntämiseksi rakennusteollisuudessa. Viidennessä luvussa pohditaan neljännessä luvussa esitettyjä tutkimuksia ja niiden menetelmien hyötyjä. Lisäksi tehdään yhteenveto ja esitellään jatkotutkimusaiheita.

## 2 TUOTTAVUUS

Tuottavuuden väitetään olevan ehkäpä jopa tärkein taloutta ohjaava perusmuuttuja (Tangen, 2002). Tuottavuuden käsite on ollut olemassa yli kahden vuosisadan ajan ja yleisesti se määritellään tuotoksen ja panoksen välisenä suhteena. Tuottavuutta on sovellettu monissa eri tilanteissa talousjärjestelmän eri tasoilla. Tutkijat väittävät, että tuottavuus sivuutetaan usein toissijaiseen asemaan, vaikka sitä pidetään yhtenä tärkeimmistä tekijöistä, jotka vaikuttavat valmistusyrityksen kilpailukykyyn. Suurin syy tähän uskotaan olevan siinä, että useat johtajat eivät välttämättä täysin ymmärrä, mitä tuottavuuden käsitteellä todellisuudessa tarkoitetaan ja se sekoitetaan usein samankaltaisiin termeihin. (Tangen, 2002.) Tässä osiossa tutustutaan tuottavuuden käsitteeseen ja tarkastellaan digitalisaation vaikutusta tuottavuuteen.

### 2.1 Tuottavuuden määrittely

Yleisenä virheenä pidetään esimerkiksi tuottavuuden käyttämistä synonyymina tuottavuuden mittareille, jotka viittaavat tuotetun palvelun tai tuotteen määrään (Tangen, 2002). Tästä syystä ihmiset usein taipuvat uskomaan, että lisääntynyt tuotanto tarkoittaa lisääntynyttä tuottavuutta. Tämä ei kuitenkaan aina pidä paikkaansa, vaan on syytä muistaa, että tuottavuus on suhteellinen käsite, jota ei voida sanoa lisääntyvän tai vähentyvän, ellei suoriteta vertailua joko kilpailijoiden tai muiden standardien kanssa tietyllä hetkellä tai ajan myötä tapahtuneista muutoksista. (Tangen, 2002.)

Teollisuustekniikassa tuottavuus yleisesti ottaen määritellään suhteena tuotetun tuotteen ja käytetyn resurssin välillä valmistuksen muunnosprosessissa (Tangen, 2002). Tuottavuuteen siis vaikuttaa erittäin voimakkaasti resurssien käyttö ja saatavuus - eli tuottavuus vähenee, jos yrityksen resursseja ei käytetä asianmukaisesti tai niitä on puutteellisesti. Tuottavuus liittyy vahvasti myös arvon luomiseen. Korkea tuottavuus saavutetaan, kun valmistusprosessissa



käytetyt toiminnot ja resurssit lisäävät arvoa tuotettaville tuotteille. (Tangen, 2002.)

Rakennusteollisuudessa tuottavuutta kuvaavat moninaiset käsitteet, kuten työsaavutus (engl. *performance factor*), työmenekki (engl. *production rate*) ja työntekijätunti (engl. *unit person-hour rate*), eli tth (Dozzi & AbouRizk, 1993). Rakennusteollisuudessakin tuottavuus määritellään perinteisesti panoksen ja tuotoksen suhteena, eli liittyvän resurssin panoksen suhteena todelliseen tuotokseen, joka ilmaistaan yleensä tth:ina. Esimerkiksi voitaisiin mitata tth:ta per juoksumetri asennettua vesijohtoa tai tth:ta per kuutiometri valettua betonia. (Dozzi & AbouRizk, 1993.)

Työvoiman tuottavuuden tärkeimmät mittarit ovat tehokkuus, jolla työvoimaa käytetään rakennusprosessissa, ja työvoiman suhteellinen tehokkuus suhteessa siihen, mitä sen odotetaan tekevän tietyssä aikataulussa ja paikassa (Dozzi & AbouRizk, 1993). Esimerkkejä ensimmäisestä mittarista ovat työvoimakustannukset neliometriä kohti asuinpinta-alaa tuottaessa tai kustannukset esimerkiksi yhden sairavuoteen tarjoamiseksi sairaalassa. Toisaalta voidaan tarkastella öljynjalostamon rakentamiseen vaaditun työvoiman tarvetta öljynjalostamon tuottamia tynnyreitä kohden. Rakennusteollisuudessa ollaan kuitenkin yleensä kiinnostuneempia työvoiman suhteellisesta tehokkuudesta, eli esimerkiksi aiemmin mainittu tth per metri asennettua vesijohtoa. (Dozzi & AbouRizk, 1993.)

## 2.2 Digitalisaation vaikutus tuottavuuteen

Monien maiden talous koki massiivisen teknologisen muutoksen 1980-luvun jälkeen. Nopean teknologisen kehityksen on väitetty hidastaneen tuottavuuskasvua, ja taloustieteilijät käyttävät tästä tilanteesta termiä "tuottavuusparadoksi". (Krutova ym., 2021). Esimerkiksi Brynjolfsson korostaa vuonna 1993 julkaisemassaan artikkelissa, että informaatioteknologian kehitys korreloi negatiivisesti informaatiotyöntekijöiden tuottavuuden kanssa monilla valmistus- ja palvelualoilla. Vaikka Brynjolfsson aiemmin väitti informaatioteknologian nopean kehityksen heikentävän tuottavuutta, vuonna 1996 julkaistussa tutkimuksessa Brynjolfsson ja Hitt kuitenkin havaitsivat IT-investointien merkittävän vaikutuksen sekä yritysten tuotantoon että kuluttajien kokonaisyötyyn.

IT-investoinnit eivät itsestään lisää tuottavuutta, mutta se on yksi olennainen osa laajempaa organisaatiomuutosten järjestelmää, jonka on todettu lisäävän tuottavuutta (Krutova ym., 2021). Teknologia on ainoastaan yksi osa ICT-investointeja ja näihin investointeihin sisältyy yleensä myös suuria kustannuksia koulutukseen, prosessien uudelleensuunnitteluun ja organisaatiomuutoksiin. Vaikka tuottavuusparadoksi on kestävä argumentti selitettäessä tuottavuuden kasvun heikkenemistä, niin monet tutkimukset

kuitenkin osoittavat teknologisen kehityksen edistävän tuottavuuskasvua.  
(Krutova ym., 2021).

## 3 TEKOÄLY

Tekoäly on edennyt merkittävin harppauksin viime vuosina, ja sen hyödyntäminen on yleistynyt sekä arjessa että työelämässä. Tässä luvussa käydään läpi tekoälyn kehityksen historiaa, datan ja informaation eroja, tiedonlounhintaa ja koneoppimista sekä tekoälyn ongelmakohtia.

### 3.1 Tekoälyn kehittyminen

Tekoäly hyödyntää tietokoneita jäljittelemään ihmismielen ongelmanratkaisua sekä päätöksentekokykyä (IBM, 2020). Alan Turing julkaisi vuonna 1950 artikkelin "Computing Machinery and Intelligence", missä hän kuvaili kuinka luoda älykkäitä koneita ja kuinka voidaan testata niiden älykkyyttä. Tekoälyn todellista alkua on kuitenkin pidetty vuonna 1956 Dartmouthissa pidettyä konferenssia, jossa termiä "tekoäly" käytettiin ensimmäisen kerran. Turing myös ennusti tietokoneiden olevan loistavia shakinpelaajia tulevaisuudessa (Haenlein & Kaplan, 2019).

Noin 50 vuotta myöhemmin, vuonna 1997, IBM:n kehittämä shakkitietokone Deep Blue voitti entisen maailmanmestarin Garry Kasparovin  $3\frac{1}{2}-2\frac{1}{2}$ . Tätä on pidetty yhtenä suurena virstanpylväänä tekoälykehityksessä, mutta myös umpikujana (Heßler, 2017). Heßlerin (2017) artikkelin mukaan Deep Bluen voitossa ei ollut kyse niinkään tekoälyn kehittymisestä, vaan raa'an laskentatehon kasvusta.

Seuraava ja todellisenä pidetty virstanpylväs oli, kun DeepMind Technologiesin AlphaGo -tekoäly voitti ensimmäistä kertaa täysikokoisella pelilaudalla ja ilman tasoitusta go-ammattilaisen vuonna 2015. Vain vuotta myöhemmin AlphaGo voitti 18-kertaisen maailmanmestari Lee Sedolin. Tämän teki merkittäväksi se, että gota on pidetty yhtenä haasteellisimmista kokonaisuuksista ihmismielen ymmärrykselle. Gon säännöt ovat erittäin yksinkertaiset, mutta se vaatii paljon taktiikkaa, strategiaa ja ennakointia. (Silver ym., 2017).

Vaikka shakkiin ja gohon erikoistuneet tekoälyt saattavat kuulostaa hyödylliseltä ainoastaan kyseisiä lautapelejä harrastaville tai ammatikseen pelaaville ihmisille, todistivat ne tekoälyn ylivertaisuuden oppimisessa, datan läpikäynnissä sekä arvioiden tarkkuudessa ihmiseen nähden. Tekoälyn hyödyntäminen tiedonlouhinnassa ei ole suinkaan uusi keksintö, vaan siitä on julkaistu artikkeleita jo 90-luvulla, kuten esimerkiksi Mitchellin vuonna 1999 julkaisema ”Machine Learning and Data Mining”.

### 3.2 Data ja informaatio

Datan ja informaation välillä on vain hiuksenhieno ero. Data on raakoja ja organisoimattomia faktoja, osia informaatiosta, mitkä vaativat käsittelyä (Australian Bureau of Statistic). Kun data tehdään hyödylliseksi järjestämällä, käsittelemällä tai esittelemällä se tietyssä kontekstissa, se muuttuu informaatioksi. Esimerkiksi yrityksen jokaisen työntekijän kuukausipalkka on dataa ja yrityksen työntekijöiden keskipalkka on informaatiota, jonka voi johtaa annetusta datasta (taulukko 1). (Australian Bureau of Statistic).

TAULUKKO 1 Henkilöt-, ikä-, sukupuoli- ja palkkasarakkeissa datayksiköitä.  
Palkkasarakkeessa alimmaisena henkilöiden keskipalkka, eli informaatiota (Australian Bureau of Statistic).

Henkilöt	Ikä	Sukupuoli	Palkka
Henkilö 1	30	m	3500
Henkilö 2	23	n	3200
Henkilö 3	18	m	2200
Henkilö 4	25	m	3000
			2975

### 3.3 Tiedonlouhinta ja koneoppiminen

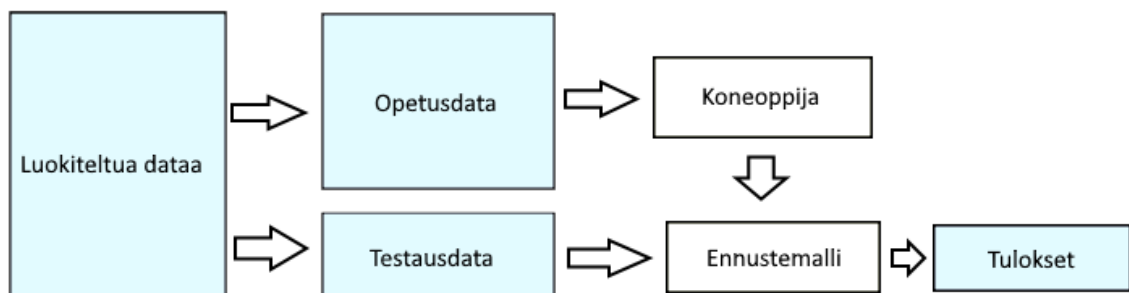
Tiedonlouhinta (engl. *data mining*) on joukko menetelmiä, jolla pyritään poimimaan dataa tai aiemmin tuntemattomia datakuvioita (engl. *data pattern*) suurista tietojoukoista (Javatpoint, 2011). Perinteisesti tiedonlouhinnan menetelmät voidaan karkeasti yleistettynä jaotella kolmeen eri joukkoon – klusterointiin (engl. *clustering*), assosiaatioon (engl. *association*) sekä luokitteluun (engl. *classification*). Alun perin tiedonlouhinnassa keskityttiin pääasiassa lähinnä taulukkotietoihin (engl. *tabular data*), mutta nykyään menetelmiä on jalostettu mahdollistamaan esimerkiksi tekstin, kuvien sekä graafien louhinnan. (Maggioni, 2012).

Koneoppiminen (engl. *machine learning*) puolestaan on yksinkertaisesti ilmaistuna tekoälyn alahaara, mikä pyrkii datan sekä algoritmien käytöllä

jäljittelemään ihmisten tapaa oppia parantaen vähitellen tarkkuuttaan ja lopulta tuottamaan ihmiselle ymmärrettävää tietoa sekä malleja (IBM, 2020; Javatpoint, 2011). Yleisesti koneoppimisalgoritmeja käytetään ennusteiden tekemiseen tai luokitteluun. Koneoppimisalgoritmin oppimissysteemi voidaan jakaa kolmeen pääosaan.

Päätösprosessissa (engl. *decision process*) algoritmi tuottaa ennusteen datan mallista syötetiejoen perusteella (Salian, 2018). Virhefunktio (engl. *error function*) arvioi päätösprosessin tuottaman ennusteen verraten sitä ennalta annettuihin esimerkkimalleihin, jos niitä vain on saatavilla. Jos saatu arvio ja esimerkkimalli ei täsmää, siirtyy algoritmi optimointiprosessiin. Tässä kohtaa algoritmi tarkastelee virhettä ja päivittyy, jotta seuraavalla kerralla päätösprosessin antaman arvion virheen suuruus ei olisi niin iso. (Salian, 2018).

Komponenttivalmistaja Nvidia jaottelee koneoppimisen neljään eri tyyppiin riippuen pääsääntöisesti siitä, että onko ihminen vaikuttanut käsiteltävään raakadataan (Salian, 2018). Ohjatussa oppimisessa (engl. *supervised learning*) opetusdata on valmiiksi luokiteltua ja on jo ennalta tiedossa haluttu lopputulos. Opetusdata on osa isompaa datakokonaisuutta, josta otetaan myös algoritmin testaukseen käytettävä testidata. Harjoitusdatasta koneoppimismalli oppii tunnistamaan merkitykselliset mallit ja testidatalla, jota malli ei ole vielä nähnyt, testataan mallin lopullista tarkkuutta (kuvio 1). (Salian, 2018).



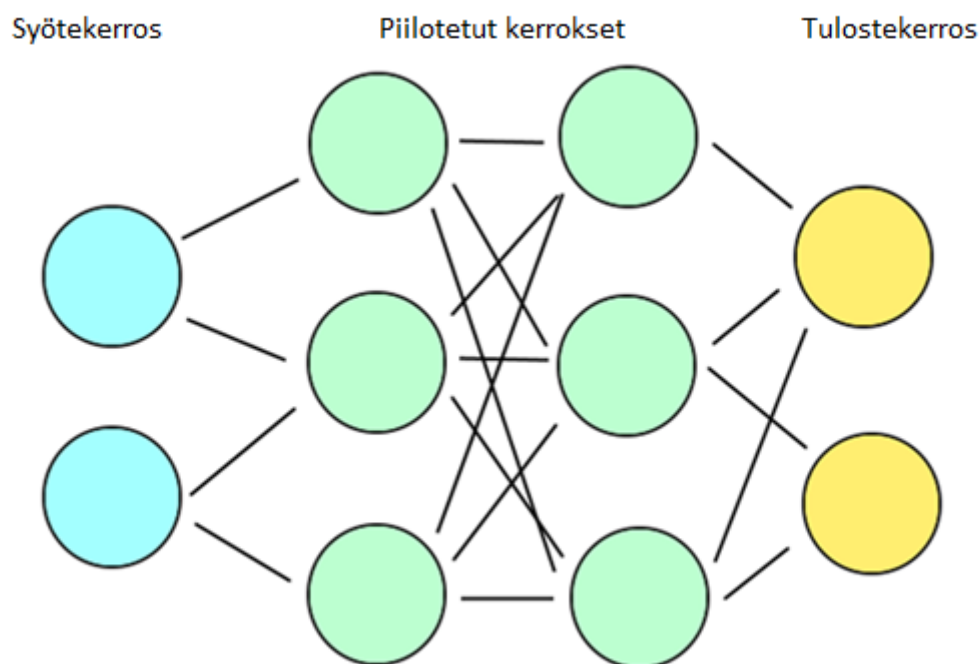
KUVIO 1 Ohjatun oppimisen opetus ja testaus (Salian, 2018)

Ohjaamattomassa oppimisessä (engl. *unsupervised learning*) opetusdata on täysin raakaa ja siitä ei tiedetä mitään ennalta (Salian, 2018). Algoritmi tunnistaa itse malleja ja yhteyksiä datasta, ilman käyttäjältä saatavaa apua. Osittain ohjattu oppiminen (engl. *semisupervised learning*) on nimensä mukaisesti näiden kahden edellä mainitun tyyppien yhdistelmä. Osa harjoitusdatasta on valmiiksi luokiteltua ja osa ei. Tämä ohjaa algoritmia tekemään itsenäisiä johtopäätöksiä ja se oppii samalla luokittelemaan luokittelematonta dataa. (Salian, 2018.)

Vahvistusoppimisessa (engl. *reinforcement learning*) tekoäly oppii yrityksen ja erehdyksen kautta (Salian, 2018). Vahvistusoppiminen muistuttaa ohjattua oppimista, mutta algoritmia ei opeteta ennalta harjoitusdatan avulla. Tämänkaltaisessa koneoppimisessä tekoäly pyrkii löytämään optimaalisen tavan saavuttaa haluttu tavoite, tai kehittää itseään tietystä tehtävästä, saaden

palkinnon jokaisesta suorittamasta askeleesta, mikä vie sitä lähemmäs tavoitetta. Kaksi tällaista tekoälyä voivat oppia pelaamaan esimerkiksi shakkia pelaamalla ainoastaan toisiaan vastaan. (Salian, 2018.)

Syväoppiminen (engl. *deep learning*) on koneoppimisen haara, jonka selkärangana toimivat neuroverkot ja syväoppiminen pyrkii imitoimaan ihmisen aivoja (Javatpoint, 2011). Neuroverkko koostuu vähintään kolmesta kerroksesta. Ensimmäisenä on syötekerros (engl. *input layer*), jonka jälkeen voi olla yksi tai useampi piilokerros (engl. *hidden layer*) ja viimeisenä tulee tulostekerros (engl. *output layer*) (kuvio 2) (LeCun ym., 2015). Kerrokset koostuvat neuroneista, jotka sisältävät parametreja, kutsutaan usein painotukseksi (engl. *weight*), joita muutetaan verkon opetuksen yhteydessä. Neuronien lukumäärä kerroksissa voi vaihdella tehtävän haastavuuden mukaan. Esimerkiksi syötekerroksen neuronien lukumäärään voi vaikuttaa se, montaako ominaisuutta syötteestä halutaan tutkia. Laskutehtävät suoritetaan piilokerroksissa ja funktion arvo saadaan ulostuskerroksesta. Tyypillisin syväoppimisen harjoitustapa on ohjattu oppiminen. (LeCun ym., 2015).



KUVIO 2 Neuroverkon kerrokset

Tiedonlouhinnalla ja koneoppimisella on paljon yhteistä ja ne hyödyntävät toisiaan, mutta niiden päämäärät ovat erilaiset. Koneoppimisalgoritmit pyrkivät löytämään isoista aineistojoukoista säännönmukaisuuksia ja luomaan niistä malleja tulevien tulosten ennustamiseksi. Tiedonlouhinnalla taas pyritään ainoastaan löytämään oleellisenä pidettävää tietoa suurista aineistojoukoista. (Javatpoint, 2011.)

### 3.4 Tekoälyn vaikutus tuottavuuteen

Corrado, Haskel ja Jona-Lasinio tutkivat vuonna 2021 julkaisemassaan artikkelissa miten tekoälyn tehdyt investoinnit vaikuttavat tuottavuuteen. Vaikka näyttöä suurista ja jatkuvista investoinneista on paljon, tuottavuus näytti enemmin hidastuvan kiihtymisen sijaan. Tätä on heidän mukaansa selitetty yleisesti "J-käyrä" -ilmiöllä, eli tuottavuuden kehitys laskee aluksi, mutta kääntyy sitten jyrkästi nousuun. Sen mukaan tekoälyn tehdyt investoinnit ovat väärin laskettuja, mikä vääristää mitattua tuotantoa alhaiseksi ja saa kokonaistekijätuottavuuden (engl. *Total Factor Productivity*) näyttämään laskevalta. Ajan kuluessa, kun investoinnit palaavat vakaalle tasolle, vääristymä mitatussa tuottavuudessa katoaa, mutta siihen mennessä tekoälyn aineettomaan tietoon liittyvä pääoma on kasvanut, ja vääristymä mitatussa tuottavuuden kehityksessä aiheutuu siitä, että jo tehtyjä investointeja aineettomaan tietoon ei huomioida, jolloin kokonaistuottavuuden kasvu näyttää liian korkealta. (Corrado ym., 2021).

Tutkijat loivat viitekehyksen edellä mainitun vaikutuksen havainnollistamiseksi ja tutkivat asiaa monien maiden ja alojen useiden vuosien tietoaineistoilla Yhdysvalloissa sekä Euroopassa. Tutkiakseen mittaamattomia investointeja he käyttivät CHS-menettelytapaa. Tutkijoiden käytössä olleen datan perusteella he eivät löytäneet tukea J-käyrä -selitykselle, vaan heidän mukaansa käyrän olisi jo pitänyt kääntyä ylöspäin. Tutkijat kuitenkin painottivat heidän datansa rajallisuutta ja samankaltaisten tutkimuksien vähyyttä, jotta tekoälyn vaikutuksesta tuottavuuteen voitaisiin tehdä varmoja johtopäätöksiä. (Corrado ym., 2021).

Kahdessa muussa tutkimuksessa on havaittu, että tekoälyllä on mahdollisesti hyvinkin positiivinen vaikutus yritysten tuottavuuteen. Yangin vuonna 2022 julkaisemassa artikkelissa tutkittiin taiwanilaisia yrityksiä, joissa osa hyödynsi tekoälyä ja osa ei. Hän havaitsi, että kun yritys kasvatti tekoälypatenttien määrää 10 prosentilla, yrityksen tuottavuus kasvoi myös 5 prosenttia. Hänen mukaansa tekoälyteknologialla oli myös positiivinen vaikutus työllisyyteen. Tekoälyä käyttävät yritykset työllistivät 3,5 prosenttia enemmän työvoimaa. (Yang, 2022).

Vuonna 2021 julkaistussa tutkimuksessa Damioli, Van Roy ja Vertesy myös korostavat tekoälyn hyötyjä yritysten tuottavuuteen. Heidän otoksensa oli 5257 yritystä ympäri maailman, jotka olivat jättäneet vähintään yhden tekoälyteknologian patenttihakemuksen vuosien 2000 ja 2016 välillä. Positiivinen vaikutus näkyi erityisesti palvelualoilla ja pienissä ja keskisuurissa yrityksissä. Heidän mukaansa tämä viittaa siihen, että tekoälyn vaikutus yritysten tuottavuuteen riippuu suuresti yrityksen kyvystä sopeutua nopeasti muuttuviin olosuhteisiin. Tutkimuksen perusteella suurten ja monimutkaisten yritysten tuottavuutta edelleenkin hallitsevat monipuoliset patenttisalkut, joissa tekoälypatentteja on vähän tai ei lainkaan. (Damioli ym., 2021).

### 3.5 Tekoälyn luomat haasteet

Tarjotessaan monia mahdollisuuksia, tekoälyyn liittyy myös monia merkittäviä huolenaiheita sekä riskejä. Ehkä suurimpana, tai ainakin näkyvimpänä, huolenaiheena on ollut työpaikkojen katoaminen. McKinsey Global Instituten (2017) arvion mukaan pahimmassa tapauksessa vuoteen 2030 mennessä jopa 800 miljoonaa työpaikkaa on vaarassa kadota automaation takia. Tekoälyä voidaan myös käyttää väärän tiedon ja propagandan levittämiseen. Erityisesti syväväärennösteknologia (engl. *deepfake*), jolla voidaan luoda ihmisistä realistisia mutta väärennetyjä videoita, on noussut suureksi huolenaiheeksi. Myös tekoälyn kyky käsitellä suuria tietomääriä ja ennennäkemätön tarkkuus analyysien luomisessa voi olla uhka ihmisten tietoturvalle ja yksityisyydelle.

Tämän tutkielman kannalta oleelliset ongelmat ovat kuitenkin sokea luottamus automaatioon sekä huono koulutusaineisto. Seuraavaksi käydään läpi kaksi todellisen maailman esimerkkitapausta, jotka Kaminski esitteli vuonna 2023 julkaisemassaan artikkelissa "Regulating the Risks of Ai".

#### 3.5.1 Automaation tyytyväisyys

Vuonna 2015 Uber aloitti kokeilun itseohjautuvien autojen kanssa tavoitteenaan vähentää ihmistyövoiman tarvetta. Aluksi jokaisessa autossa oli kaksi ihmistä turvaoperaattoreina. Toinen henkilö ilmoitti esteitä ja toinen henkilö vahvisti kannettavalla tietokoneella, olivatko tekoälyjärjestelmän tekemät havainnot samat. Vuonna 2017 Uber muutti käytäntöään ja vähensi operaattoreiden määrän yhteen. Yksin autossa ollessaan yksittäiset operaattorit alkoivat tuntea tylsistymistä ja samanaikaisesti tarkkailivat puhelimiaan auton ollessa liikkeellä. (Kaminski, 2023).

Samaan aikaan kun operaattorit kokivat "automaation tyytyväisyyttä" (engl. *automation complacency*), eli luottivat liikaa automaatioon, eivätkä tarkkailleet tai osallistuneet ajamiseen vaadittavalla tavalla, Uber teki päätöksen ohittaa autojen automaattisen jarrutusjärjestelmän välttääkseen väärin hälytysten aiheuttamia ongelmia. Vuonna 2018 tapahtui ensimmäinen dokumentoitu tapaus, jossa Uberin itseohjautuva auto tappoi jalankulkijan. Auton järjestelmä ei havainnut jalankulkijaa, vaikka oli kirkas ilta ja auto hälytti ongelmasta vasta 0,2 sekuntia ennen törmäystä. Oikeudessa esitetystä videomateriaalista nähtiin, että operaattorina toiminut henkilö katsoi puhelintaan törmäyshetkellä. (Kaminski, 2023).

#### 3.5.2 Roskaa sisään, roskaa ulos

Suuri osa suurista yrityksistä, kuten McDonald's, JP Morgan ja LinkedIn, hyödyntää tekoälytyökaluja rekrytoinneissa. Jopa 90 prosenttia Fortune 500 -yrityksistä käyttää jollain tavoin automaatiota työnhakijoiden seulontaan ja



arviointiin. Amazon kehitti vuonna 2014 rekrytointiohjelman automatisoidakseen lahjakkaiden työntekijöiden etsinnän. Ohjelma koulutettiin käyttämällä ansioluetteloilla, jotka oli lähetetty heille kymmenen vuoden aikana, mutta vuonna 2015 havaittiin, että tekoälyjärjestelmä suosi selvästi miehiä. (Kaminski, 2023).

Tekoälyjärjestelmä alensi pisteytystä kaikille ansioluetteloilla, joissa mainittiin sana "naisten", ja rankaisi hakijoita, jotka olivat valmistuneet ainoastaan naisille tarkoitetuista yliopistoista. Tekoälyjärjestelmä toisti koulutusaineistossa havaitun ennakkoluulon, jossa suurin osa menestyneistä työnhakijoista viimeisen kymmenen vuoden aikana oli ollut miehiä. (Kaminski, 2023).

Amazonin tapaus on klassinen esimerkki tilanteesta, jossa koneoppimismallien laatu on suoraan verrannollinen niiden koulutusaineiston laatuun. Tekoälyjärjestelmien käyttö rekrytoinnissa kasvaa edelleen, ja yritykset, jotka ottavat näitä järjestelmiä käyttöön, usein väittävät niiden olevan objektiivisempia ja vähemmän ennakkoluuloisia kuin ihmiset. Rekrytointialgoritmien on kuitenkin havaittu, samoin kuin ihmistenkin, rankaisevan hakijoita, joilla on afrikkalaisperäinen nimi, tai palkitsevan hakijoita, joilla ansioluettelon kuvassa on silmälasit tai kirjahylly taustalla. (Kaminski, 2023).

## 4 TEKOÄLYN HYÖDYNTÄMINEN RAKENNUSALLA

Kuten muillakin aloilla, myös rakennusallalla kerätään suuria määriä dataa. Datan määrä tarjoaa yrityksille haasteita sekä mahdollisuuksia. Nykypäivänä datan monimutkaisuus ja määrä haastavat perinteiset datan analysointimenetelmät, mutta täsmällisellä tiedonloughinnalla yritykset voivat saavuttaa kilpailullisia etuja ja parantaa tuottavuutta. (Ahiaga-Dagbui & Smith, 2014). Tässä luvussa käydään läpi neljä tutkimusta, joissa esitellään eri tapoja hyödyntää tekoälyä rakennusteollisuudessa.

### 4.1 Tekoäly budjetin arvioinnissa

Ahiaga-Dagbui ja Smithin artikkeli käsittelee heidän tekemänsä yhteistyötä suuren Iso-Britannialaisen vesi-infrastruktuuriurakoitsijan kanssa, selvittääkseen tiedonloughinnan ja koneoppimisen tehokkuutta määrittelemättömien putkitöiden lopullisen hinnan arvioinnissa. Tutkimuksessa käytettyjen urakoiden hintahaarukka oli noin 1000 punnasta 30 miljoonaan puntaan ja urakoiden kestot vaihtelivat 3 kuukaudesta 5 vuoteen. Projektin alkuvaiheessa suuri osa budjettia koskevista päätöksistä joudutaan tekemään ympäristössä, jossa vallitsee suuri epävarmuus ja tarkan arvion tekemistä auttavaa tietoa on vähän saatavilla. Koneoppimisalgoritmin kouluttamisessa käytettiin 1600 aiemmin suoritettua projektia ja tätä kautta tekoäly oppi erottelamaan dataan upotettua tietoa, millä pyrittiin vastaamaan tiedon vähyyteen ennen projektin alkua. Erilaisia tiedonloughintamenetelmiä ja koneoppimista hyödyntäen tutkijat onnistuivat kehittämään malleja, joiden kustannusarviot osuivat  $\pm 10$  % sisälle 92 prosentissa tapauksissa ja  $\pm 5$  % sisälle 77 prosentissa tapauksissa (taulukko 2). (Ahiaga-Dagbui & Smith, 2014). Toisessa tutkimuksessa 800 vesi- ja viemäriprojektin otannassa, joiden budjettiarvioinnissa ei hyödynnetty tekoälyä, havaittiin 60 prosentin ristiriita budjettiarvion ja projektin todellisen hinnan välillä (Alex ym., 2010).

TAULUKKO 2 Satunnainen 20 tapauksen otanta putkitöiden todellisista hinnoista sekä tekoälymallin arviot. Hinnat on ilmoitettu puntina ja tulee kertoa tuhannella. (Ahiaga-Dagbui & Smith, 2014).

Tapaus	Todellinen hinta	Mallin arvio	Todellisen hinnan ja mallin arvion erotus	Absoluuttinen % virhe
1	4 846	4 990	144	2,97
2	1 586	1 590	4	0,25
3	24 986	23 760	1 226	4,91
4	11 143	10 934	209	1,88
5	5 328	5 765	437	8,20
6	3 787	3 723	64	1,69
7	17 346	16 967	379	2,18
8	4 136	4 033	103	2,49
9	3 117	2 994	123	3,95
10	1 000	939	61	6,10
11	1 773	1 674	99	5,58
12	3 779	3 600	179	4,74
13	209	192	17	8,13
14	3 960	3 810	150	3,79
15	294	300	6	2,04
16	2 296	2 220	76	3,31
17	2 104	2 038	66	3,14
18	248	247	1	0,40
19	208	192	16	7,69
20	201	197	4	1,99

Mallien tekemät kustannusarviot olivat sadasta sille aiemmin täysin tuntemattomasta projektista tehtyjä ja tutkimuksessa mukana ollut alan yritys auttoi nostamaan arvioiden luotettavuutta ja tarkkuutta. Mallien luomiseen päätettiin käyttää neuroverkkoja, koska ne pystyvät suoriutumaan datan epälineaarisista suhteista sekä kategorisista muuttujista. Malleja kehitettiin hienosäätämällä verkon parametreja ja syötteitä, kunnes hyväksyttävät virhearvot saavutettiin ja mallien kehitystä ei enää havaittu. (Ahiaga-Dagbui & Smith, 2014).

Vaikka tutkimuksessa kehitetyt kustannusmallit eivät suoraan lisää itse rakennustyömaan tuottavuutta, vähentää se vaadittavien resurssien määrää projektin esituotantovaiheessa. Yllättävillä ja ennakoimattomilla budjettien ylityksillä voi kuitenkin olla epäsuoria vaikutuksia myös rakennustyömaan tuottavuuteen, kuten artikkelin julkaisuaikana YIT:n strategisen kehitysohjelman johtajana toiminut Maarit Sääksi toteaa Rakennuslehden artikkelissa:

”Riitelykulttuuria on Sääksen mielestä vahvistanut sekin, että perinteisessä hankemallissa suunnittelija on valittu sen perusteella, kuka tekee täydellisen suunnitelman pienimmällä tuntimäärällä. Rakentajaksi on otettu se, joka tekee urakan halvimmalla. ”Sitten tulee muutoksia, kun suunnitelmat eivät olleetkaan kunnossa. Siitä syntyy riita. Aika menee kaikkeen toissijaiseen, eli hukkaan ja selvittelyyn.” (Lohilahti & Mölsä, 2017)

Täytyy kuitenkin pitää mielessä, että tässä tutkimuksessa oli kyse ainoastaan vesi-infrastruktuuriurakoista ja tutkimuksessa ei mainittu kuinka käytetty malli soveltuu muiden rakennusprojektin osa-alueiden tai esimerkiksi kokonaisen kerrostalon rakentamiseen vaaditun budjetin arviointiin. Vastaavien mallien käyttöönoton kynnyksykysymykseksi nousee mahdollisesti hintakilpailu. Tarkin budjetti-arvio useimmissa tilanteissa ei luultavasti ole rakennusteollisuuden hintakilpailuissa edullisin vaihtoehto. Jos rakennuttajat alkaisivat kuitenkin suosimaan tarkinta budjetti-arviota sen sijaan, että valitsisivat halvimman tarjouksen, monilta budjetin ylityksistä johtuvilta viivästyksiltä ja ylimääräisen ajan ja energian tuhlaamiselta kinasteluun saatettaisiin välttyä tulevaisuudessa.

## 4.2 Tuottavuuteen vaikuttavien tekijöiden kartoittaminen

Kaiken kattavan näkemyksen saaminen työn tuottavuudesta on hankalaa, koska se on yhdistelmä hallittavia sekä hallitsemattomia tekijöitä. Erityisesti yhdistetyt epäsäännöllisyydet aiheuttavat ongelmia mallinnettaessa rakennustyön tuottavuutta. Neuroverkkomenetelmät, jotka käyttävät ohjatun oppimisen algoritmeja, ovat kuitenkin osoittautuneet mallintamisen helppouden ja tarkkuuden osalta varteenotettaviksi vaihtoehtoisiksi tätä ongelmaa ratkaistaessa. (Golnaraghi ym., 2019).

Tutkimuksessaan Golnaraghi, Zangenehmadar, Moselhi ja Alkass vertailivat neljän eri neuroverkkomenetelmän tarkkuutta ja tehokkuutta tarkkaillessaan yksittäisen työryhmän työn tuottavuutta kahdessa rakennusprojektissa, jotka suoritettiin Montrealissa. Tutkimuksessa keskityttiin valumuottien asentamiseen, koska ne muodostavat merkittävän osan kokonaistyöstä betonirakentamisessa. Käytetyt menetelmät olivat vastavirta-algoritmi (engl. *backpropagation*), radiaaliskantafunktio-verkko (engl. *radial basis network*), yleistetty regressio-neuroverkko (engl. *generalized regression neural network*) ja adaptiivinen neurosumea päättelyjärjestelmä (engl. *adaptive neuro-fuzzy inference system*). Toinen rakennuksista oli korkeudeltaan 17 kerrosta ja toinen 16 kerrosta ja projektien valmistumiseen kului kolme vuotta. (Golnaraghi ym., 2019).

Tuottavuuteen vaikuttavat tekijät jaettiin säähän, miehistöön ja työtehtävään. Näiden katsottiin aiheuttavan vaihtelua tuottavuuteen päivittäin. Yhdeksään tekijään, jotka sisältyvät näihin kolmeen pääkategoriaan, oli saatavilla dataa. Sähän kuului lämpötila, ilmankosteus, tuulen nopeus ja sademäärä. Miehistö jaettiin työryhmän kokoon ja prosenttiosuuteen työryhmän koosta, jota käytettiin kyseiseen työtehtävään. Työtehtävä jaettiin työn tyyppiin, kerrokseen, jossa työ suoritetaan ja työmenetelmään. Työn tyyppi saattoi olla muottien asentaminen laatoille, seinille tai pylväille. Työmenetelmä jakautui joko paikan päällä rakentamiseen tai valmiiden muottien asentamiseen. Nämäkin valittiin niiden mahdollisista vaikutuksista päivittäiseen tai lyhytaikaiseen

tuottavuuteen. Tutkimuksessa vertailluista menetelmistä tehokkuus ja tarkkuus huomioiden parhaaksi osoittautui vastavirta-algoritmi. (Golnaraghi ym., 2019).

Vastavirta-algoritmin avulla pystyttiin myös näkemään, kuinka suuri vaikutus tuottavuuteen eri tekijöillä oli valumuottien asentamisessa. Selvästi suurin vaikutus tuottavuuteen oli lämpötilalla ja kerroksella, missä työskentely suoritettiin. Vaikka nämä saattavat olla jo ennalta tiedossa, demonstroi tämä hyvin, kuinka tekoälyllä voidaan selvittää eri asioiden välisiä yhteyksiä. Tutkijoiden mukaan mallia pystytään myös hyödyntämään ennustettaessa ajanjaksoja, jolloin tuottavuus on alhaisempaa. Tämä voi olla hyödyllinen työkalu suunnittelussa ja aikatauluttamisessa ja sen avulla voidaan varautua ennalta mahdollisiin sudenkuoppiin. (Golnaraghi ym., 2019).

Vaikka tutkimuksessa käsiteltiin ainoastaan tuottavuutta valumuottien asennustöissä, ei ole lainkaan mahdoton ajatus, että vastaavia malleja voitaisiin kehittää myös muille rakennustöiden vaiheille. Tutkijat myös mainitsevat, että tutkimuksen rajoitteena on kerätyn datan määrä ja tutkimuksessa huomioidut parametrit. Kyseisen tutkimuksen ennalta-arvattavista tuloksista huolimatta se voi edelleen toimia hyvänä pohjana vastaaville tutkimuksille. Tämä voi kannustaa tutkimaan muita rakennusurakoiden osa-alueita sekä analysoimaan eri tekijöitä ja niiden keskinäisiä riippuvuuksia, mikä voi paljastaa yllättäviäkin tuottavuuteen vaikuttavia tekijöitä. Kunhan kerätään riittävästi laadukasta, monipuolista ja olennaista dataa sekä suoritetaan tarkka analyysi, tällä on mahdollisesti suuri merkitys rakennusprojektien suunnitteluun.

### 4.3 Työntekijän tuottavuuden seuraaminen

Raskas fyysinen työ, kuten käsin tehtävä raskaiden asioiden nostaminen sekä toistuvat fyysisesti vaativat työt ovat jatkuvasti läsnä rakennusalalla. Tämä johtaa työvoiman säännölliseen väsymiseen ja altistaa usein myös turvallisuusriskeille. Näistä syistä työntekijöiden toimintojen mittaaminen, arvioiminen ja kehittäminen on oleellista ajan ja kustannusten hallinnan kannalta sekä mahdollisten turvallisuusriskien havaitsemiseksi. (Sanhudo ym., 2021).

Tutkimuksessa "Activity classification using accelerometers and machine learning for complex construction worker activities" Sanhudo ja kumppanit tutkivat kiihtyvyyksmittareiden ja ohjattujen koneoppimisalgoritmien hyödyntämistä rakennusalan työntekijöiden toimintojen mittaamiseen ja arviointiin. Tämän kaltaisia tutkimuksia on tehty jo aikaisemminkin, mutta heidän mukaansa suurimmassa osassa näistä tutkimuksista käsitellään ainoastaan pientä määrää toimintoja, jotka testihenkilöt suorittavat opetetulla tavalla. Tämä saattaa parantaa algoritmien tarkkuutta ja samalla myös vääristää testituloksia. (Sanhudo ym., 2021).

Saadakseen aidompia tuloksia, tutkijat sisällyttivät tähän tutkimukseen suuremman määrän monimutkaisia rakentamiseen kuuluvia toimintoja, joista useimmat voidaan tulkita useiden yksinkertaisempien

tehtävien ryppäinä. Toiminnot jaettiin kolmeen ryhmään. Ensimmäisessä ryhmässä olivat muuraaminen, maalaaminen ja rappaaminen. Toisessa ryhmässä oli vasarointi, sahaaminen ja ruuvaaminen. Kolmannessa ryhmässä oli varusteiden päälle laittaminen, paikallaan seisominen ja kävely. Yksinkertaisempia tehtäviä olivat esimerkiksi vasaran nostaminen, naulojen nostaminen, naulojen sijoittaminen, naulojen vasarointi ja työkalujen tiputtaminen. Testihenkilöiden ohjeistamisen sijaan tutkijat loivat kolme eri skenaariota. Käyttäjistä riippuvainen ja riippumaton, jossa suoritetaan kaikki toiminnot sekä käyttäjistä riippumaton, jossa suoritetaan vain osa toiminnoista. Käyttäjistä riippuvainen ja riippumaton eroavat toisistaan siinä, suoritetaanko järjestelmälle ylimääräinen koulutusvaihe jokaisen uuden käyttäjän kohdalla. (Sanhudo ym., 2021).

Datan keräämiseen tutkijat käyttivät edullisia, päälle puettavia kiihtyvyyssmittareita sekä kouluttivat 13 eri koneoppimisalgoritmia nähdäkseen, mikä tai mitkä algoritmit antaisivat optimaalisimmat tulokset. Kiihtyvyyssmittarit puettiin molempiin ranteisiin sekä dominoivaan jalkaan. Päätös kiihtyvyyssmittareiden määrästä ja sijoitteluista tehtiin aiempien tutkimuksien perusteella, jotka tosin perustuivat arkipäivän askareiden seuraamiseen. Toiminnot suoritettiin testihuoneessa, minne oli rakennettu jokaista toimintoa varten suorituspisteet. Suorituspisteet suoritettiin yhtenäisenä ratana kuuden testihenkilön toimesta. Saatu data lajiteltiin manuaalisesti käyttäen apuna synkronoitua videotallennetta käyttäen. Videotallenteen kuvannut kamera oli sijoitettu niin, että koko radan suorittaminen saatiin kuvattua yhdellä otolla. (Sanhudo ym., 2021).

Käyttäjistä riippumattomissa skenaarioissa algoritmeista parhaiten suoriutui gradienttitehostus eli GrB (engl. *gradient boosting*), joka on yhdistelmä heikompia koneoppimisalgoritmeja, mutta luovat yhdessä tehokkaan mallin (Javatpoint, 2011). Gradienttitehostus saavutti 85,5 % tarkkuuden. Käyttäjistä riippuvaisessa skenaariossa paras algoritmi oli k-lähimmän naapurin menetelmä, eli KNN (engl. *k-nearest neighbor method*), saavuttaen jopa 93,7 % tarkkuuden. Se on yksi yksinkertaisimmista ja tehokkaimmista ohjatun oppimisen koneoppimisalgoritmeista, joka varastoi kaiken saatavilla olevan datan ja luokittelee uuden datan verraten sitä aiemmin luokiteltujen datapisteiden samankaltaisuuden perusteella (Javatpoint, 2021). Käyttäjistä riippumattomissa skenaarioissa parhaiten selvinnyt GrB pärjäsi myös tässä skenaariossa hyvin, saavuttaen 92,5 % tarkkuuden. Käyttäjistä riippuvaisessa skenaariossa lähes KNN:n tasolle ylsi adaptiivinen tehostus (engl. *adaptive boosting*), eli AdB, ja heikoin suoriutuminen oli lineaarisella tukivektorikoneella (engl. *linear support-vector machine*), eli LSVM:llä (taulukko 3). Tutkijat suosittelivatkin käyttäjistä riippuvaista menetelmää ja jokaisen työntekijän tulisi suorittaa vastaavanlainen tutkimuksessa käytetty rata. (Sanhudo ym., 2021).

TAULUKKO 3 Kolme parasta ja huonoiten suoriutunut algoritmi käyttäjästä riippuvaisessa skenaariossa, jossa suoritettiin kaikki toiminnot. (Sanhudo ym., 2021).

Toimintojen määrä	KNN	AdB	GrB	LSVM
Kaikki	0.9369	0.9357	0.9254	0.7582

Tulokset olivat siis lupaavia ja tämän tutkimukset tekijät aikovatkin testata kehittämänsä menetelmää oikeassa rakennustyöympäristössä useammalla testihenkilöllä testatakseen KNN -algoritmin suoriutumista tosielämän tapaustutkimuksessa. He aikovat myös lisätä toiseen jalkaan kiihtyvyyssanturin nähdäkseen, että onko sillä vaikutusta algoritmin tarkkuuteen.

Työntekijöiden tehokkuuden ja toimintojen seuraaminen olisi varmasti tehokas tapa havaita ongelmakohtia työmaalla, mutta tämänkaltaiseen seurantaan saatetaan Suomessa soveltaa lakia yksityisyyden suojasta työelämässä, joka kieltää tietyn tai tiettyjen työntekijöiden kameravalvonnan välttämättömiä poikkeustapauksia lukuun ottamatta tai ilman työntekijän suostumusta (Yksityisyyden suoja työelämässä 5:16§). Rakennustyömailla tehdään myös paljon esimerkiksi sähkö-, putki- ja hitsaustöitä ja pelkkien kiihtyvyyssantureiden avulla näiden töiden eri toiminnot on mahdollisesti haastava tunnistaa.

#### 4.4 Riskienhallinta

Rakennusalalla riskienhallinnalla ja -tunnistamisella voi olla merkittävä vaikutus tuottavuuteen. Tehokkaalla riskienhallinnalla voidaan vähentää projektien viivästymisen riskiä, minimoida ylimääräisiä kustannuksia, parantaa työturvallisuutta ja pienentää mahdollisuutta laatuongelmiin. Tärkeystään huolimatta nykyajan menetelmät rakennushankkeiden riskienhallintaan (engl. *construction project risk management*), eli CPRM, vaativat monimutkaista suunnittelua, systemaattista arviointia sekä kattavia hallintatoimenpiteitä. CPRM -käytäntöjen kehityksestä huolimatta ne yleensä jäävät tehokkuudessaan ja tarkkuudessaan puutteellisiksi, mutta tekoälystä on arvioitu ongelmaan pelastajaa. (Wu, Yang, Lai & Antwi-Afari, 2020; Changali ym., 2015; Nyqvist ym., 2024).

Tutkimuksessa "Can ChatGPT exceed humans in construction project risk management?" Nyqvist, Peltokorpi ja Seppänen ottivat selvää, kuinka ChatGPT GPT-4 pärjää rakennusalan riskienhallinnassa alan ammattilaisiin nähden. ChatGPT GPT-4 valittiin heidän tutkimukseensa, koska se toimii generatiivisena tekoälynä, joka pystyy tuottamaan tekstiä käyttäjän antamien kehoitteiden perusteella. Lisäksi se oli heidän mukaansa johtava generatiivinen tekoälyratkaisu tutkimuksen aikana keväällä 2023. (Nyqvist ym., 2024).

Tutkimuksessa käytettiin monimenetelmäistä tapaa, jossa tekoäly asetettiin vastakkain alan asiantuntijoiden kanssa. Tutkimuksessa kerättiin yhteensä 16 vastausta ihmisasiantuntijoilta ja heidät oli valittu eri rakennusalan yrityksistä heidän aikaisemman CPRM -kokemuksen perusteella. Osallistujien kokemus vaihteli 4 ja 38 vuoden välillä. Osallistujat ja tekoäly vastasivat joukkoon kysymyksiä liittyen riskienhallintaan simuloitua tapaushanketta varten. Tutkimuksen osallistujat eivät tienneet tekoälyn osallisuudesta ja vastausten saavuttua kaikki vastaukset tehtiin nimettömiksi. (Nyqvist ym., 2024).

Vastausten arviointiin osallistui 19 asiantuntijaa sekä ChatGPT GPT-4. Jokaiselle arvioijalle annettiin kaksi satunnaisesti valittua vastausta, pois lukien omansa, ja tekoälyn antama vastaus. Tekoäly arvioi kaikki vastaukset mukaan lukien oman vastauksensa. Jokaiselta arvioijalta pyydettiin antamaan pisteet jokaiselle yksittäiselle kysymykselle asteikolla 1–10, kokonaispisteet ja laadullista palautetta jokaisesta arvioidusta vastauksesta. Kyselyyn kuuluivat seuraavat kysymyssarjat: Vastaajan tiedot, kuten "nimi", "asema" ja "kokemusvuodet". Toiseksi, "tunnistakaa ja listatkaa mahdolliset riskit hankkeelle". Kolmanneksi, "mitkä näistä riskeistä ovat kaikkein kriittisimpiä?" "Voitteko analysoida niitä?" Neljänneksi, "kertokaa mitä teette näiden kriittisten riskien hallitsemiseksi?" (Nyqvist ym., 2024).

Tapausesimerkki oli tutkijoiden mukaan huolellisesti suunniteltu jäljittelemään todellista tilannetta ja monimutkaisuuksia, joita CPRM:ssä kohtaa. Esimerkki oli räätälöity sisältämään aluekohtaista tietoa ja jäljittelemään tilannetta, jossa paikalliset asiantuntijat saattavat olla etulyöntiasemassa. Tapausesimerkin kuvaus oli seuraava: "Olet pääurakoitsija keskikokoisen terveykeskuksen peruskorjaushankkeessa Helsingissä. Kohde sijaitsee tiheään asutulla alueella Töölössä. Rakennus on alun perin rakennettu 1930-luvulla, mutta sitä on kunnostettu useita kertoja sen elinkaaren aikana. Korjattava alue kattaa noin 4 500 neliömetrin alueen. Korjaushanke on tilattu taloudellisesti vakaalta yritykseltä, jonka kanssa sinulla on kiinteähintainen sopimus korjaustyöstä. Sopimuksessa määrätään, että koko korjaustyö on suoritettava vuonna 2024. Hankkeen erityispiirteenä on, että osa tiloista pysyy terveystakeskuksena hankkeen aikana." (Nyqvist ym., 2024).

ChatGPT saavutti huomattavasti parempia arvioita kuin asiantuntijat sekä ihmisarvioijien että ChatGPT:n itsensä arvioinnissa. Ihmisten keskimääräinen pistemäärä oli 5,7, kun taas ChatGPT:n keskimääräinen pistemäärä oli 8,6 ihmisten arvioinnissa ja yksikään asiantuntijavastaaajista ei ylittänyt ChatGPT:n keskimääräistä pistemäärää. Osa arvioijista kehui ChatGPT:n kykyä tarjota kattavia ja yksityiskohtaisia riskiarviointeja, mutta huolta aiheutti riskienhallinnan tarkkuus ja käytännöllisyys. Tekoälyn vastauksia ei ihmisarvioijien mielestä räätälöity rakennushankkeen tiettyihin olosuhteisiin ja tekoälyn laajoista vastauksista huolimatta niitä pidettiin liian yleisinä ja niistä puuttuivat konkreettiset toimenpiteet. (Nyqvist ym., 2024).

Ongelmana oli myös tekoälyn ehdottamien strategioiden toteutettavuus. Jotkut arvioijat huomauttivat, että ehdotetut toimenpiteet saattaisivat olla vaikeasti toteutettavissa käytännössä. Tässä tutkijoiden mukaan korostui



tekoälyjärjestelmien kyvyttömyys ottaa huomioon käytännön rajoituksia ja esteitä. ChatGPT:n vastaukset saivat kritiikkiä myös liian yksityiskohtaisesta lähestymistavasta, joka voisi johtaa keskittymisen herpaantumiseen tai ylittää hankkeen sidosryhmien kapasiteetin heikentäen projektin osapuolien kykyä hyödyntää kaikkea saatua tietoa ja suoriutumasta parhaalla mahdollisella tavalla. Yksi arvioija myös korosti projektin kriittisten riskien, kuten työtilan käytettävyyden, työmaalla työskentelevien henkilöiden turvallisuuden ja projektiin sisältyvien ainutlaatuisten riskien huomiotta jättämistä. (Nyqvist ym., 2024).

ChatGPT:n riskienhallintasuunnitelma sai siis kiitosta sen kattavuudesta, mutta kritiikkiä käytännöllisyyden ja tarkkuuden puutteesta annetun rakennusprojektin kannalta. Ihmisten vastauksia taas arvosteltiin niiden puutteellisesta kattavuudesta, mutta ne tarjosivat tarkempia ja toteuttamiskelpoisempia ratkaisuja. Kukaan tutkimukseen osallistuneista ei ilmoittanut käyttäneensä tekoälyä apuna vastastessaan kysymyksiin. Tutkijoiden mukaan tekoälyn hyödyntäminen olisi saattanut nostaa ihmisvastaajien keskimääräisen pistemäärän ChatGPT:n yli. Heidän mukaansa tällä hetkellä ei ole ajankohtaista miettiä ihmisen korvaamista tekoälyllä rakennusteollisuuden riskienhallinnassa, vaan käyttää tekoälyä täydentävänä työkaluna parantamaan ihmisten suorituskykyä. (Nyqvist ym., 2024).

Tutkimuksessa esitelty ratkaisu vaikuttaa yksinkertaiselta toteuttaa käytännössä. ChatGPT:n käyttöönotto ei vaadi isoja investointeja tai organisaatiomuutoksia, sillä tällä hetkellä ChatGPT GPT-3.5:tä voi käyttää ilmaiseksi ja edullisin lisenssi GPT-4:ään maksaa 20 dollaria, jonka viestimäärää tosin on rajoitettu. Tekoäly sai kritiikkiä epäkäytännöllisistä vastauksista ja puutteellisesta tarkkuudesta kyseistä projektia ajatellen, sekä liian laajat vastaukset herättivät arvostelijoiden huolta. Näiden ongelmien korjaamiseksi vaaditaan ihmisen väliintuloa. Riskienhallinnan ammattilaisen tulee selvittää miten tekoälyn antamat epäkäytännölliset ratkaisut voidaan muuttaa käytännöllisemmiksi, tunnistaa projektin erityisalueet, joita tekoäly ei ole osannut huomioda ja räätälöidä vastaukset sisältämään ainoastaan olennaiset asiat. Tutkimustuloksen perusteella ChatGPT on loistava apuväline rakennushankkeen riskienhallintaan.

## 5 YHTEENVETO

Rakennusala on paininut jo pitkään tuottavuusongelmien kanssa ja on yhden prosentin vuosittaisen tuottavuuskasvun myötä kaukana perässä kokonaistalouden 2,8 prosentin tuottavuuskasvusta (Barbosa ym., 2017). Projektien viivästymisiin pyritään usein vastaamaan palkkaamalla lisää työvoimaa, eikä suinkaan kehittelemällä tehokkaampia menetelmiä (Hanna, 2010). Rakennusteollisuus on yksi vähiten digitalisoituneista aloista ja rahaa tutkimus- ja kehitystyöhön käytetään hyvin niukasti (Gandhi ym., 2016; Changali ym., 2015). Ainakin osittainen ratkaisu löytyy mahdollisesti tekoälyteknologiasta, jonka kehitys on ottanut suuria harppauksia.

Digitalisaation ja tekoälyn vaikutus tuottavuuteen on kiistanalainen, mutta tulevaisuudessa niiltä tuskin välttyy millään alalla. AlphaGo antoi esimakua tekoälyn oppimiskyvystä ja arvioiden tarkkuudesta vuonna 2016 ja tekoälykehitys ei ole suinkaan pysähtynyt (Silver ym., 2017). Vaikka tekoäly osoittaa suurta lupausa datan ja informaation käsittelyssä sekä arvioiden tarkkuudessa, sitä ei tulisi käyttää ilman ihmisen vuorovaikutusta. Muuttuvassa maailmassa myös tekoälyä täytyy kouluttaa säännöllisesti uudella ja laadukkaalla datalla. Tekoäly ei myöskään ole erehtymätön, joten ihmisen tulee aina tarkistaa sen antamat vastaukset ja korjata mahdolliset puutteet ja virheet. Tekoälyn mukana tulevat mahdollisuudet ovat saaneet myös tutkijat kiinnostumaan tekoälyn hyödyntämisestä rakennusalalla.

Tarkemmilla budjettiarvioilla voidaan helpottaa projektisuunnittelua, erityisesti mikäli menetelmä kehittyy pisteeseen, jossa malli kykenee erittelemään budjetin osatekijät. Tuottavuuteen vaikuttavien tekijöiden tunnistaminen ja analysointi tekoälyn avulla voi merkittävästi parantaa projektisuunnittelua ja vähentää suunnittelun aikana tapahtuvia virheitä. Tekoälyn hyödyntäminen riskienhallinnassa oli sitä koskevan tutkimuksen tulosten valossa selvä parannus verrattuna perinteiseen riskienhallintaan, jossa tehtävät suoritetaan ilman tekoälyn tukea. Tekoälyn positiivinen vaikutus tuottavuuteen on kuitenkin havaittu lähinnä pienissä ja keskisuurissa yrityksissä,

sillä niillä on parempi mahdollisuus sopeutua uusiin olosuhteisiin nopeammin kuin suurilla yrityksillä (Damioli ym., 2021), mutta ehkä tulevaisuudessa onnistutaan kehittämään menetelmiä, joiden käyttöönotto ei ole niin haastavaa myöskään suurille yrityksille. On kiinnostava nähdä, kuinka rohkeasti suuret rakennusyrietykset uskaltavat lähteä kehittämään tekoälypatenteja.

Rakennusteollisuuden tuottavuuskasvun suurimpina kompastuskivinä on tehoton projektisuunnittelu sekä suunnitteluvirheet (Naoum, 2016). Tässä kirjallisuuskatsauksessa kartoitettiin keinoja parantaa rakennusteollisuuden tuottavuutta tekoälyn avulla ja esiteltiin neljä tutkimusta, joiden menetelmien avulla on mahdollista tehostaa projektisuunnittelua ja vähentää suunnittelun aikana tapahtuneita virheitä. Tekoälyn hyödyntäminen rakennusteollisuudessa ja siihen liittyvä tutkimustyö on kuitenkin vielä vähäistä. Jatkotutkimukselle olisi siis kovasti tarvetta, ja olisi tärkeää tutkia, miten tekoälyä voitaisiin hyödyntää tukena rakennusurakoiden projektinhallinnassa, kokonaisvaltaisemmin projektisuunnittelussa ja esimerkiksi hankintaketjujen optimoinnissa. Myös tuottavuuteen vaikuttavien tekijöiden laajempaa kartoitusta tarvittaisiin.

## 6 LÄHTEET

- Agarwal, R., Chandrasekaran, S., & Sridhar, M. (2016). *Imagining construction's digital future*. McKinsey Global Institute.  
<https://www.mckinsey.com/capabilities/operations/our-insights/imagining-constructions-digital-future-infographic>
- Ahiaga-Dagbui, D. D., & Smith, S. D. (2014). Dealing with construction cost overruns using data mining. *Construction Management and Economics*, 32(7–8), 682–694. <https://doi.org/10.1080/01446193.2014.933854>
- Alex, D. P., Al Hussein, M., Bouferguene, A., & Fernando, S. (2010). Artificial Neural Network Model for Cost Estimation: City of Edmonton's Water and Sewer Installation Services. *Journal of Construction Engineering and Management*, 136(7), 745–756. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000184](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000184)
- Australian Bureau of Statistics. (ei pvm.). *Statistical Language – What are Data?*  
<https://www.abs.gov.au/websitedbs/D3310114.nsf/Home/Statistical+Language+-+what+are+data>
- Barbosa, F., Woetzel, J., Mischke, J., Ribeirinho, M. J., Sridhar, M., Parsons, M., Bertram, N., Brown, S. (2017). *Reinventing construction executive summary*. McKinsey Global Institute.  
<https://www.mckinsey.com/capabilities/operations/our-insights/reinventing-construction-through-a-productivity-revolution>
- Brynjolfsson, E. (1993). The Productivity Paradox of Information Technology. *Commun. ACM*, 36, 66–77. <https://doi.org/10.1145/163298.163309>
- Chan, P., & Kaka, A. (2004). Construction productivity measurement: A comparison of two case studies. *20th Annual ARCOM Conference, 1-3 September 2004, Heriot Watt University. Association of Researchers in Construction Management, Vol. 1*, 3-12. [https://www.arcom.ac.uk/-docs/proceedings/ar2004-0003-0012\\_Chan\\_and\\_Kaka.pdf](https://www.arcom.ac.uk/-docs/proceedings/ar2004-0003-0012_Chan_and_Kaka.pdf)

- Changali, S., Mohammad, A., & van Nieuwland, M. (2015). *The construction productivity imperative*. McKinsey Global Institute.  
<https://www.mckinsey.com/capabilities/operations/our-insights/the-construction-productivity-imperative>
- Corrado, C., Haskel, J., & Jona-Lasinio, C. (2021). Artificial intelligence and productivity: An intangible assets approach. *Oxford Review of Economic Policy*, 37(3), 435–458. <https://doi.org/10.1093/oxrep/grab018>
- Damioli, G., Van Roy, V., & Vertesy, D. (2021). The impact of artificial intelligence on labor productivity. *Eurasian Business Review*, 11(1), 1–25. <https://doi.org/10.1007/s40821-020-00172-8>
- Dozzi, S. P., AbouRizk, S.M. (2024). *Productivity in Construction*. NRC Publications Archive  
<https://nrc-publications.canada.ca/eng/view/object/?id=52dc96d5-4ba0-40e6-98d2-8d388cba30cd>
- Golnaraghi, S. (2019). Application of Artificial Neural Network(s) in Predicting Formwork Labour Productivity. *Advances in Civil Engineering*, 1–11.  
<https://doi.org/10.1155/2019/5972620>
- Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5–14.  
<https://doi.org/10.1177/0008125619864925>
- Hanna, A. S. (2010). *Construction Labor Productivity Management and Methods Improvement*. Hanna Consulting Group.
- Heßler, M. (2017). The Triumph of ‘Stupidity’: Deep Blue’s Victory over Garri Kasparov. The Controversy about its Impact on Artificial Intelligence Research. *NTM*, 25(1), 1–33. <https://doi.org/10.1007/s00048-017-0167-6>
- Hitt, L., & Brynjolfsson, E. (1996). Productivity, Business Profitability, and Consumer Surplus: Three Different Measures of Information Technology Value. *MIS Quarterly*, 20, 121–142. <https://doi.org/10.2307/249475>
- Huang, H.-C., & Lin, S.-C. (2009). Non-linear finance–growth nexus. *The Economics of Transition*, 17(3), 439–466. <https://doi.org/10.1111/j.1468-0351.2009.00360.x>
- IBM (5.11.2021). *What is Machine Learning?*  
<https://www.ibm.com/cloud/learn/machine-learning>
- Javatpoint. (2011). *Data Mining vs Machine Learning*  
<https://www.javatpoint.com/data-mining-vs-machine-learning>
- Kaminski, M. E. (2023). Regulating the Risks of Ai. *Boston University Law Review*, 103(5), 1347–1411. <http://dx.doi.org/10.2139/ssrn.4195066>

- Khanna, S., Gandhi, P., Ramaswamy, S. (2016). *Which industries are the most digital*. McKinsey Global Institute.  
<https://www.mckinsey.com/mgi/overview/in-the-news/which-industries-are-the-most-digital>
- Krutova, O., Koistinen, P., Turja, T., Melin, H., & Särkikoski, T. (2021). Two sides, but not of the same coin: Digitalization, productivity and unemployment. *International Journal of Productivity and Performance Management*, 71(8), 3507–3533. <https://doi.org/10.1108/IJPPM-05-2020-0233>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lohilahti, O. & Mölsä, S. (Syyskuu 2017). Rakennusalalla työn tuottavuus ei ole kasvanut 40 vuodessa – Onko allianssista tai leanista apua? *Rakennuslehti*.  
<https://www.rakennuslehti.fi/2017/09/rakennusalalla-tyon-tuottavuus-ei-ole-kasvanut-40-vuodessa-onko-allianssista-tai-leanista-apua/>
- Maggioni, M. (2012). WHAT IS...Data Mining? *Notices of the American Mathematical Society*, 59, 1. <https://doi.org/10.1090/noti831>
- Manyika, J., Lund, S., Chui, M., Bughin, J., Woetzel, L., Batra, P., Ko, R., Sanghvi, S., (2017). *Jobs lost jobs gained executive summary december*. McKinsey Global Institute. <https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages>
- Naoum, S. G. (2016). Factors influencing labor productivity on construction sites: A state-of-the-art literature review and a survey. *International Journal of Productivity and Performance Management*, 65(3), 401–421.  
<https://doi.org/10.1108/IJPPM-03-2015-0045>
- Nyqvist, R., Peltokorpi, A., & Seppänen, O. (2024). Can ChatGPT exceed humans in construction project risk management? *Engineering, Construction and Architectural Management*, 31(13), 223–243.  
<https://doi.org/10.1108/ECAM-08-2023-0819>
- Salian, I. (2.7.2018). *NVIDIA Blog: Supervised Vs. Unsupervised Learning*. Nvidia.  
<https://blogs.nvidia.com/blog/2018/08/02/supervised-unsupervised-learning/>
- Sanhudo, L., Calvetti, D., Martins, J. P., Ramos, N. M. M., Mêda, P., Gonçalves, M. C., & Sousa, H. (2021). Activity classification using accelerometers and machine learning for complex construction worker activities. *Journal of Building Engineering*, 35, 102001.  
<https://doi.org/10.1016/j.jobbe.2020.102001>
- Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., Hubert, T., Baker, L., Lai, M., Bolton, A., Chen, Y., Lillicrap, T., Hui, F.,

- Sifre, L., van den Driessche, G., Graepel, T., & Hassabis, D. (2017). Mastering the game of Go without human knowledge. *Nature*, 550(7676), 354–359. <https://doi.org/10.1038/nature24270>
- Tangen, S. (2002). Understanding the concept of productivity. *Proceedings of the 7th Asia-Pacific Industrial Engineering and Management Systems Conference, Taipei* (pp. 18-20)
- Työntekijän yksityisyyden suojalaki.  
<https://www.finlex.fi/fi/laki/ajantasa/2004/20040759>
- Wu, Z., Yang, K., Lai, X., & Antwi-Afari, M. F. (2020). A Scientometric Review of System Dynamics Applications in Construction Management Research. *Sustainability*, 12(18), 7474.  
<https://doi.org/10.3390/su12187474>
- Yang, C.-H. (2022). How Artificial Intelligence Technology Affects Productivity and Employment: Firm-level Evidence from Taiwan. *Research Policy*, 51(6), 104536. <https://doi.org/10.1016/j.respol.2022.104536>
- Zhao, T., & Dungan, J. M. (2014). Improved Baseline Method to Calculate Lost Construction Productivity. *Journal of Construction Engineering and Management*, 140(2), 06013006.  
[https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000800](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000800)