

Matias Kallio

**TEKOÄLYN HYÖDYNTÄMINEN
RAKENNUSALAN TYÖTURVALLISUUS-
DEN KEHITTÄMISESSÄ**

Kandidaatintyö
Rakennetun ympäristön tiedekunta
Tarkastaja: Osku Torro
Toukokuu 2024

TIIVISTELMÄ

Matias Kallio: Tekoälyn hyödyntäminen rakennusalan työturvallisuuden kehittämisessä.
Utilizing artificial intelligence to improve occupational safety in the construction industry.
Kandidaatintyö
Tampereen yliopisto
Rakennustekniikka
Toukokuu 2024

Tutkimus käsittelee tekoälyn soveltamista rakennusalan työturvallisuuden kehittämisen näkökulmasta. Rakennusala on tunnetusti yksi tapaturma-alttiimmista toimialoista, jossa työtapa-
turmien määrä ja vakavuus ovat merkittäviä. Rakennusosalalla tapahtuu Suomessa vuosittain
noin 13 000 työtapa-
turmaa. Tässä tutkimuksessa selvitetään, miten tekoälyä voidaan käyttää
näiden tapaturmien vähentämiseen.

Tutkimus toteutettiin kirjallisuustutkimuksena, ja keskeiset tiedot saatiin vertaisarvioituista
tieteellisistä julkaisuista. Pääasialliset tietokannat olivat Google Scholar ja Andor. Ottaen huomi-
oon aiheen nopean kehityksen, tutkimuksessa keskityttiin käyttämään ainoastaan tuoreita ja
ajankohtaisia lähteitä. Tutkimuksessa tarkastellaan Suomen rakennusalan työturvallisuuden ny-
kytilaa, esitellään tekoälyn merkittävimmät sovellukset työturvallisuuden parantamisessa ja sel-
vitetään, miten näihin sovelluksiin kerätään dataa. Lopuksi vastataan päätutkimuskysymykseen:
”Miten tekoälyä voidaan hyödyntää rakennusalan työturvallisuuden kehittämisessä?” Tutkimuk-
sen tavoitteena on tuoda esiin tekoälyn mahdollisuuksia ja haasteita rakennusalan työturvalli-
suuden näkökulmasta.

Työturvallisuuden kannalta merkityksellisimmiksi tekoälyn osa-alueiksi todettiin koneoppimi-
nen, konenäkö, luonnollisen kielen käsittely ja tietopohjaiset järjestelmät. Tutkimuksen tulokset
osoittavat, että tekoäly tarjoaa laajat mahdollisuudet parantaa rakennusalan työturvallisuutta.
Tekoälyn avulla voidaan tunnistaa ja ennakoita potentiaaliset vaarat aikaisempien onnetto-
muuksien ja läheltä piti -tilanteiden datan perusteella. Erilaisten sensoreiden keräämää tietoa
voidaan käyttää reaaliaikaisesti työntekijöiden kunnon ja sijainnin seurantaan, mikä mahdollis-
taa varoittamisen vaaratilanteista ennen niiden kehittymistä. Tekoälyn ohjaama kameravalvonta
edistää jatkuvaa turvallisuuden tarkkailua työmaalla. Lisäksi tekoäly voi parantaa koulutusta si-
mulaatioiden ja interaktiivisten oppimisympäristöjen avulla. Haasteita tekoälyn käyttöönotossa
kohdataan erityisesti tekoälyn vaatimissa suurissa laskentaresursseissa ja pitkissä koulutus-
ajoissa. Lisäksi kulttuurinen muutosvastarinta, korkeat alkuinvestoinnit ja osaa-
ajapula muodosta-
vat esteitä tekoälyn tehokkaalle hyödyntämiselle.

Avainsanat: Tekoäly, Työturvallisuus, Koneoppiminen, Datan kerääminen, Rakennusala

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

ALKUSANAT

Tämä kandidaattityö on tehty kirjallisuustutkimuksena rakennustekniikan tutkinto-ohjelmaan keväällä 2024. Aiheeksi valikoitui nopeasti tekoälyn mahdollisuudet työturvallisuuden kehittämisessä, aiheen ajankohtaisuuden vuoksi. Tekoälyn integrointi työturvallisuuden alueelle näyttää lupaavalta ja voi mullistaa tavan, jolla rakennusalan turvallisuutta hallitaan ja kehitetään tulevaisuudessa.

Haluaisin erityisesti kiittää ohjaajaani Osku Torroa, hänen asiantuntevasta ohjauksestaan ja tuestaan koko työprosessin ajan. Hänen nevojensa ja kannustuksensa ansiosta olen pystynyt syventämään osaamistani sekä kehittämään työni lähestymistapaa ja laajentamaan näkökulmaani. Lisäksi haluaisin kiittää kanssaopiskelijoitani heidän arvokkaasta tuestaan ja palautteestaan työn aikana.

Tampereella, 07.05.2024

Matias Kallio

SISÄLLYSLUETTELO

1. JOHDANTO	1
1.1 Tutkimuksen tausta.....	1
1.2 Tutkimuksen tavoitteet, tutkimuskysymykset ja rajaus	1
2. TUTKIMUKSEN TOTEUTUS	3
2.1 Tutkimusmenetelmä	3
2.2 Tutkimusaineisto.....	4
3. TYÖTURVALLISUUS RAKENNUSALALLA	6
3.1 Työturvallisuuden haasteet ja tilastot	6
3.2 Laki työturvallisuudesta	7
4. TEKOÄLY YLEISESTI	9
4.1 Koneoppiminen.....	9
4.2 Konenäkö	11
4.3 Tietopohjaiset järjestelmät	11
4.4 Generatiivinen tekoäly	12
4.5 Luonnollisen kielen käsittely	13
4.6 Autonomiset tekoälyagentit.....	14
5. DATAN KERÄÄMINEN TEKOÄLYSOVELLUKSIIN	15
5.1 Kamerateat.....	15
5.2 Esineiden internet (IoT)	15
5.3 Rakennusalan dokumentit	16
5.4 Haasteet datan keräämisessä	16
6. TEKOÄLY TURVALLISUUSRISKIEN ARVIOINNISSA, ENNUSTAMISESSA JA EHKÄISYSSÄ.....	18
6.1 Koneoppiminen.....	18
6.2 Konenäkö	19
6.3 Tietopohjaiset järjestelmät	20
6.4 Luonnollisen kielen käsittely	21
6.5 Älykkäät henkilösuojaimet.....	21
6.6 Tekoälyn hyödyntäminen työturvallisuuskoulutuksessa	22
6.7 Tekoälyn käyttöönoton haasteet	23
7. PÄÄTELMÄT	25
7.1 Tutkimuksen tulokset.....	25
7.2 Tutkimuksen arviointi ja jatkotutkimusehdotukset	27
LÄHTEET	28

1. JOHDANTO

1.1 Tutkimuksen tausta

Rakennusallalla sattui vuonna 2022 noin 13 000 työtaturmaa. Tämä on noin 14 % kaikista vuodessa tapahtuneista työtaturmista. Rakennusalan tapaturmataajuus on myös kaikista toimialoista huomattavasti suurin. (Tapaturmavakuutuskeskus 2023) Samaan aikaan tekoälyn kehitys on ollut nopeampaa ja näkyvämpää, kuin koskaan. Onkin siis ajankohtaista tutkia, miten tekoälyä voidaan hyödyntää riskien arvioinnissa ja onnettomuuksien ennaltaehkäisyssä.

Tässä tutkimuksessa tarkastellaan, kuinka tekoäly voi muuttaa rakennusala tarjomaalla keinoja vähentää onnettomuuksia. Tutkimuksen tausta juontaa juurensa sekä tekoälyn nopeasta kehityksestä, että rakennusalan kasvavasta tarpeesta hyödyntää uutta teknologiaa, mikä tekee aiheesta paitsi ajankohtaisen myös kriittisen tarkastelun kohteen.

1.2 Tutkimuksen tavoitteet, tutkimuskysymykset ja rajaus

Tämän tutkimuksen tavoitteena on pyrkiä tuomaan esiin tekoälyn mahdollisuuksia ja haasteita rakennusalan työturvallisuuden näkökulmasta. Tutkimuksessa selvitetään, miten tekoälyä käytetään tällä hetkellä työturvallisuuden kehittämiseen ja tunnistetaan uusia innovatiivisia tapoja hyödyntää tekoälyä työturvallisuudessa ja sen valvonnassa.

Tutkimuksessa vastataan seuraavaan päätutkimuskysymykseen: miten tekoälyä voidaan hyödyntää rakennusalan työturvallisuuden kehittämisessä? Tutkimuksessa vastataan myös seuraaviin alatutkimuskysymyksiin:

- Mikä on rakennusalan työturvallisuuden nykytilanne ja haasteet?
- Mitä eri tekoälyjä on olemassa ja miten niitä pystytään hyödyntämään rakennusallalla työturvallisuuden näkökulmasta?
- Mitä keinoja on kerätä dataa rakennusallalla ja miten sitä pystytään hyödyntämään tekoälyssä?

Tutkimustuloksia voidaan käyttää nyt ja tulevaisuudessa vähentämään rakennusalan työtapaturmia ja parantamaan työturvallisuuskoulutusta. Nopeasti kehittyvän teknologian ansiosta tutkimus on erittäin ajankohtainen ja tulevaisuudessa entistä merkittävämpi.

Tutkimus on rajattu rakennusalaan. Tutkimuksessa keskitytään tekoälyn hyödyntämiseen rakennustyömaalla ja työturvallisuuskoulutuksessa. Nopeasti kehittyvän teknologian vuoksi työssä on pyritty käyttämään vain tuoreita ja ajankohtaisia lähteitä. Tutkimus on toteutettu kirjallisuustutkimuksena.

2. TUTKIMUKSEN TOTEUTUS

Tässä luvussa käsitellään tutkimuksen toteutusta, joka jakautuu kahteen pääosaan: käytettyihin tutkimusmenetelmiin ja aineistoon. Aluksi kuvaamme, miten aineisto on kerätty käyttäen erilaisia hakukoneita ja hakulausekkeita, ja miten tämä prosessi tukee tutkimuskysymysten ymmärrystä. Tämän jälkeen esittelemme tutkimuksessa käytetyn aineiston.

2.1 Tutkimusmenetelmä

Tutkimus on toteutettu kirjallisuustutkimuksena. Kirjallisuustutkimuksessa noudatettiin huolellisesti suunniteltua prosessia, joka sisälsi useiden lähiaikoina julkaistujen tieteellisten artikkelien systemaattisen analyysin, tiivistämisen, järjestämisen ja johtopäätösten esittämisen. Aluksi määriteltiin tutkimuskysymykset, jotka ohjasivat koko tutkimusprosessia. Tämän jälkeen suoritettiin kattava haku relevantteja tieteellisiä artikkeleita varten. Haussa käytettiin useita tietokantoja ja tarkkoja hakukriteereitä, jotta kaikki merkitykselliset tutkimukset saatiin sisällytettyä tarkasteluun.

Kirjallisuustutkimuksen tulokset strukturoitiin siten, että ne tarjoavat selkeän yhteenvedon tutkitusta aiheesta, korostaen uusia näkökulmia ja mahdollisia tutkimusaukkoja. Prosessin läpinäkyvyys ja tarkkuus ovat kriittisiä tekijöitä, jotka varmistavat tutkimuksen luotettavuuden.

Hakutermeinä käytettiin englanninkielisiä hakutermejä. Hakutermejä oli useita ja eri hakupalveluista hakemalla saatiin runsaasti tutkimuksia. Tekoälyn nopean kehittymisen vuoksi pyritään aineistoista valitsemaan, vain relevantit artikkelit. Hakutulokset on koottu taulukkoon 1.

Taulukko 1. Hakutulosten lukumäärä eri hakupalveluista.

Haku	Andor	Google Scholar	Andor (vuodesta 2023)	Google Scholar (vuodesta 2023)
"artificial intelligence" AND "occupational safety" AND "construction"	65	8 960	16	2 260
"artificial intelligence" AND "work safety" AND "construction"	15	2 260	2	617
"artificial intelligence" AND "occupational safety"	377	15 800	75	3 890
"artificial intelligence" AND "work safety"	89	3 680	19	997

Tekoälyyn ja työturvallisuuteen liittyviä aineistoja on hakutulosten määrästä päätellen useita. Yhdistelemällä hakutermejä ja rajaamalla aineistojen ilmestymisvuotta saadaan tuloksia kuitenkin rajattua riittävästi.

2.2 Tutkimusaineisto

Tässä kappaleessa käsitellään sitä, mistä ja miten tutkimuksessa käytetty aineisto kerättiin. Keskeinen osa kirjallisuustutkimuksen aineistoa saatiin kahdesta merkittävästä tietokannasta: Andor ja Google Scholar. Nämä tietokannat valikoituivat niiden laajan kattavuuden ja relevanssin tieteellisen tiedon lähteinä. Mahdollisimman luotettavan tiedon keräämiseksi lähteinä käytettiin vertaisarvioituja tieteellisiä artikkeleita. Työturvallisuus kappaleessa aineistoa kerättiin Tapaturmavakuutuskeskuksen Tikku-tilastosovelluksesta, mistä saatiin ajankohtaisinta ja luotettavaa tietoa työturvallisuudesta. Seuraavaksi esitellään kirjallisuustutkimuksen oleelliset lähteet.

- Abioye et al. (2021) Artificial intelligence in the construction industry: A review of present status, opportunities and future challenges.

Tutkimus tarkastelee tekoälyn integrointia rakennusalalle, arvioiden nykyisiä sovelluksia, potentiaalisia etuja ja haasteita. Aineistoa käytettiin tekoälyn eri sovellusten esittelyyn. Tutkimus on tuore, mutta tekoälyn nopean kehittymisen vuoksi artikkelissa esiintyy ajoittain vanhaa tietoa. Lisäksi generatiivista tekoälyä ja tekoälyagentteja artikkeli ei ottanut huomioon. Aineiston tueksi otettiin muita tutkimuksia.

- Tixier et al. (2016) Application of machine learning to construction injury prediction.

Tutkimuksessa onnistuttiin hyödyntämään koneoppimista rakennusalalla sattuneiden vammojen ennustamiseen. Tutkimus antaa esimerkin, miten koneoppimista on käytetty rakennusalalla työturvallisuuden näkökulmasta. Kokonaisvaltaisemman kuvan saamiseksi otettiin aineiston tueksi myös muita tutkimuksia aiheesta.

- Baduge et al. (2022). Artificial intelligence and smart vision for building and construction 4.0.

Artikkeli käsittelee keinotekoisien älyn, koneoppimisen ja syväoppimisen sovelluksia rakennus- ja rakennusteollisuuden alalla. Artikkelin käytettiin tuomaan esiin tekoälysovellusten data ongelmia.

- Moragane et al. (2022) Application of computer vision for construction progress monitoring: a qualitative investigation.

Tutkimus käsittelee konenäön hyödyntämistä rakentamisen edistymisen seurannassa ja laadun tutkimisessa. Aineisto antaa esimerkin konenäön hyödyntämisestä työturvallisuuden näkökulmasta. Tutkimuksen tueksi otettiin myös muita tutkimuksia tukemaan artikkeleita. Esimerkiksi Garyaev ja Garyaevn (2023) tutkimus tekoälyn ja videovalvontateknologian integroinnista rakennuslaitteiden valvontaan toi lisää näkökulmia tutkimukseen

- Márquez-Sánchez et al. (2021) Convolutional neural networks for Image classification

Tutkimuksessa kehitettiin älykäs henkilönsuojausjärjestelmä. Tutkimusta käytettiin esittelemään uusi innovatiivinen tapa käyttää tekoälyä työturvallisuuden kehittämiseen.

- Okudan, O., Budayan, C., Dikmen, I. (2021). A knowledge-based risk management tool for construction projects using case-based reasoning.

Tutkimus käsittelee tietopohjaisen riskienhallintatyökalun kehittämistä rakennusprojekteihin käyttämällä tapauspohjaista päättelyä. Tutkimusta käytettiin tuomaan esiin tietopohjaisten järjestelmien käyttömahdollisuuksia työturvallisuuden näkökulmasta.

- Hussain et al. (2024) Conversational AI-based VR system to improve construction safety training of migrant workers.

Artikkeli käsittelee virtuaaliodellisuuden perustuvaa järjestelmää, joka on suunniteltu parantamaan rakennusalan turvallisuuskoulutusta siirtotyöntekijöille. Tässä tutkimuksessa kehitetty järjestelmä, joka yhdistää tekoälyyn pohjautuvat keskustelurobotit interaktiiviseen VR-ympäristöön, mikä mahdollistaa koulutettavien kommunikoinnin virtuaaliopettajan kanssa. Artikkeleita käytettiin tuomaan esiin tekoälyn hyötyä työturvallisuuskoulutuksessa.


- Jarota (2023) Artificial intelligence in the work process. A reflection on the proposed European Union regulations on artificial intelligence from an occupational health and safety perspective.

Artikkeli esitti pohdintaa ehdotetuista tekoälyä koskevista Euroopan unionin säännöksistä työterveyden ja -turvallisuuden näkökulmasta. Aineisto antoi kattavan kriittisen näkökulman tekoälyn hyödyntämiseen.

3. TYÖTURVALLISUUS RAKENNUSALALLA

3.1 Työturvallisuuden haasteet ja tilastot


Työmaiden turvallisuuden osalta rakennusteollisuus kohtaa erityisiä haasteita. Tämä johtuu alan luonteesta, joka on jatkuvasti muuttuvaa ja liikkuvaa. Työmaiden sijainnin tiheä vaihtelu sekä monien eri urakoitsijoiden yhtäaikainen toiminta samassa paikassa tuovat lisähaasteita turvallisuuden ylläpitämiseen. Rakentamisessa ei ainoastaan kohdata tapaturmariskejä, vaan myös altistutaan melulle, erilaisille pölyille sekä lämpötilan ja sään vaihteluille. (Rakennusala) Muita haasteita rakentamisen työturvallisuustyöhön tuovat suuret massat ja energiat (Työturvallisuuskeskus). Tikku-tilastosovelluksen mukaan rakennusalan työtapaturmat vuodesta 2005 vuoteen 2022 esitetty kuvassa 1.



Kuva 1. Rakennusalan työtapaturmat vuodesta 2005 vuoteen 2022 (Tikku-tilastosovellus).

Kuvasta 1 voidaan huomata, että rakennusalan työtapaturmat ovat hieman vähentyneet. Kuitenkin vuonna 2022 sattui työpaikoilla 12 904 työtapaturmaa. Kuolemaan johtaneita työtapaturmia rakennusalaalla sattui 3 vuonna 2022. (Tikku-tilastosovellus) Kuvan 1 perusteella voidaankin todeta, että rakennusalaalla tehdään oikeanlaisia toimenpiteitä työturvallisuuden parantamiseksi. Toisaalta rakennusalan työturvallisuudessa on vielä paljon kehitettävää.

Kuitenkin parempi kuva rakennusalan työturvallisuuden nykytilanteesta saadaan tarkastelemalla tapaturmataajuutta. Tikku-tilastosovelluksen (2023) mukaan rakennusalan tapaturmataajuus (miljoonaa työtuntia kohden) vuodesta 2005 vuoteen 2022 on esitetty kuvassa 2.



Kuva 2. Rakennusalan tapaturmataajuus (miljoonaa työtuntia kohden) vuodesta 2005 vuoteen 2022 (Tikku-tilastosovellus).

Kuvasta 2 voidaan huomata, että vuonna 2021 ja 2022 tapaturmataajuus on hieman noussut. Vuonna 2022 tapaturmataajuus on ollut 59,7 tapaturmaa miljoonaa tehtyä työtuntia kohden. Tämä on enemmän kuin millään muulla toimialalla. (Tikku-tilastosovellus 2023) Rakennusalan tapaturmataajuus viestii alan onnettomuusherkkyydestä.

3.2 Laki työturvallisuudesta

Rakennusosalalle asetetut työturvallisuusvaatimukset on kirjattu valtioneuvoston rakennustöiden turvallisuutta koskevaan asetukseen (205/2009) 1 luvun 3 pykälän mukaan ”Rakennushankkeessa on rakennuttajan, suunnittelijan, työnantajan ja itsenäisen työntekijän yhdessä ja kunkin osaltaan huolehdittava siitä, ettei työstä aiheudu vaaraa työmaalla työskenteleville eikä muille työn vaikutuspiirissä oleville henkilöille”.

Rakennuttajan on nimettävä jokaiseen rakennushankkeeseen hankkeen vaativuutta vastaava pätevä turvallisuuskoordinaattori. Turvallisuuskoordinaattori vastaa rakennushankkeen turvallisuudesta (VNa 205/2009). Rakennustyömaalla tulee suorittaa vähintään kerran viikossa työmaatarkastus, jonka tarkoituksena on selvittää ja ennaltaehkäistä mahdollisia työstä tai laitteista aiheutuvia vaaratekijöitä. Viikoittainen työmaatarkastus suoritetaan usein nykyisin TR-mittauksella. (Rakennusala) Lyhenne "TR" tulee sanasta talonrakennus. Maa- ja vesirakentamisessa käytössä on MVR-mittari. (TR-mittaus)

TR-mittarilla havainnoitavat asiat ovat seuraavat (TR-mittaus):

- työskentely
- telineet, kulkusillat ja tikkaat
- koneet ja välineet
- putoamissuojaus
- sähkö ja valaistus
- järjestys
- pölyisyys.

Rakennuttajan velvollisuuksiin kuuluu laatia ja pitää ajan tasalla turvallisuusasiakirjaa, joka sisältää rakennushankkeen vaarat, haitat sekä työturvallisuus- ja terveystiedot. Lisäksi on laadittava hankkeen erityispiirteisiin perustuvat turvallisuussäännöt ja -menettelyt mukaan lukien seurantaohjeet ja henkilötunnisteen käyttö. Ennen töiden aloitusta päätoteuttajan on tehtävä suunnitelmat työturvallisuudesta ja työmaa-alueen käytöstä, jotta voidaan varmistaa turvallisuus ja vaarattomuus kaikille työmaan osapuolille. (Rakennusala)

4. TEKOÄLY YLEISESTI

”Tekoäly (artificial intelligence, AI) tarkoittaa koneen kykyä jäljitellä inhimillistä päätelyä” (CGI 2023). Tekoälyn historiallinen kehitys voidaan jakaa kolmeen päävaiheeseen. Ensimmäinen vaihe alkoi 1950-luvulla, jolloin tekoälyn perusideat ja algoritmit syntyivät. Tämän jälkeen, 1970-luvulta 1990-luvulle, keskityttiin symboliseen tekoälyyn ja asiantuntijajärjestelmiin, jolloin AI siirtyi enemmän tietoon perustuvaan lähestymistapaan. Viimeisin vaihe, 1990-luvulta nykypäivään, on keskittynyt koneoppimiseen ja syvään oppimiseen, hyödyntäen suuria datamääriä ja edistyneitä laskentatehoja tekoälyn kehittämiseen. (Delipetrev et al. 2020)

Työturvallisuuden sovelluksissa tärkeimmät tekoälyn osa-alueet ovat kirjallisuustutkimuksen mukaan koneoppiminen, konenäkö, luonnollisen kielen käsittely ja tietopohjaiset järjestelmät. Käyttökohteita löytyy kuitenkin todennäköisesti tulevaisuudessa myös generatiiviselle tekoälylle ja tekoälyagenteille, joskin niiden käyttö työturvallisuuden näkökulmasta on vielä vähäistä. Myös robotiikan kehittyminen saattaa välillisesti parantaa työmaan työturvallisuutta, vähentämällä ihmisten altistumista vaarallisille olosuhteille, mutta tässä tutkimuksessa ei perehdytä aiheeseen tarkemmin.

4.1 Koneoppiminen

Koneoppimisessa keskeisenä ajatuksena on sellaisten tietokoneohjelmien kehittäminen, jotka kykenevät oppimaan aikaisemmista kokemuksista tai historiallisista tiedoista. Tavoitteena on, että nämä ohjelmat voivat suorittaa mallinnusta, hallintaa tai ennusteita käyttämällä tilastollisia menetelmiä ilman, että niille on nimenomaisesti ohjelmoitu, miten tehtävät suoritetaan. (Abioye et al. 2021) Koneoppimisen alueet voidaan jakaa seuraaviin osiin (Abioye et al. 2021):

- valvottu oppiminen (Supervised machine learning)
- valvoton oppiminen (Unsupervised machine learning)
- vahvistusoppiminen (Reinforcement learning)
- syväoppiminen (Deep learning).

Valvotussa oppimismallissa koneet oppivat tehtäviä analysoimalla ennalta merkittäviä tietoaaineistoja, jotka sisältävät sekä syötteen että halutun lopputuloksen. Taas valvomattomassa oppimismallissa tavoitteena on saada koneet tunnistamaan piilotettuja ra-

kenteita merkitsemättömistä tietoaineistoista. Vahvistusoppiminen määritellään prosessiksi, jossa kone oppii valitsemaan toimintoja siten, että se maksimoi palkkion tai vahvistussignaalin. Tämä on laskennallinen menetelmä, joka perustuu vuorovaikutuksen tulosten oppimiseen ympäristön kanssa. Syväoppiminen edustaa koneoppimisen nykyaikaisinta ja edistyneintä muotoa, jossa käytetään monimutkaisia neuroverkkoja ennusteiden tekemiseen. Syväoppimisen on todettu tuottavan tarkempia tuloksia kuin perinteiset koneoppimismenetelmät. (Abioye et al. 2021) Neuroverkot, ovat koneoppimisen teknologiaa, joka käyttää laskennallisia malleja monimutkaisten tietojoukkorakenteiden oppimiseen. Nämä mallit koostuvat monista prosessointikerroksista, jotka voivat oppia edustamaan tietoa useilla abstraktiotasoilla (LeCun et al. 2015).

Koneoppimisen soveltaminen tietyille ongelmille voi olla haastavaa, vaatien useita iteraatioita ennen, kuin sopiva ratkaisu ongelmaan löytyy. Koneoppimisen merkittävimmät haasteet ovat (Tufail et al. 2023):

- Alisuoriutuminen (Underfitting): Malli ei opi riittävästi koulutusdatasta, mikä johtaa heikkoon suorituskykyyn sekä koulutus- että testidataa käytettäessä. Tämän välttämiseksi voidaan käyttää lisää koulutusdataa, pidentää koulutusaikaa tai parantaa ominaisuuksien ennakoitua.
- Ylisovittaminen (Overfitting): Malli oppii koulutusdatan "ulkoa", minkä seurauksena sen suorituskyky heikkenee uusilla, näkemättömillä datoilla. Tätä voidaan torjua käyttämällä enemmän koulutusdataa sekä seuraavia menetelmiä: Pudotuskerrokset, jotka ovat neuroverkkojen säännöllistämismenetelmä, jossa satunnaisesti poistetaan tietty prosenttiosuus prosessointikerroksista; aikaisempi pysäytys, jossa koulutus lopetetaan, kun mallin suorituskyky validointidatalla ei enää parane; säännöllistäminen, jossa mallin kustannusfunktioon lisätään rangaistus estääkseen liiallisen parametrien sovittamisen; ristivalidointi, jossa data jaetaan osiin ja malli arvioidaan useilla koulutus- ja testijoukoilla luotettavuuden parantamiseksi; ensemble-oppiminen, jossa yhdistetään useita eri malleja tarkemman ja luotettavamman ennusteen saamiseksi; sekä mallin kompleksisuuden vähentäminen, jossa käytetään yksinkertaisempia malleja, jotka eivät pysty oppimaan koulutusdatan monimutkaisia yksityiskohtia.
- Mallin valinta: Eri koneoppimismallit tuottavat eri tarkkuuksia samalle datalle. Mallin monimutkaisuuden kasvaessa sen suorituskyky voi muuttua. Optimaalisen mallin valinta perustuu usein sekä empiiriseen testaukseen että teoreettiseen ymmärrykseen.

- Data ongelmat: Suurten datamäärien käsittely ja mallien koulutus voi olla haastavaa laskentaresurssien rajallisuuden vuoksi. Laadukkaan ja kattavan koulutusdatan saatavuus on myös keskeistä koneoppimismallien menestykselle. Puuttuvat tiedot voivat vääristää mallien oppimista ja suorituskykyä.

4.2 Konenäkö

Konenäön tavoitteena on jäljitellä ihmisen näön kykyä keinotekoisesti. Tämän alan päämääränä on antaa koneille kyky ymmärtää digitaalisia kuvia ja moniulotteista visuaalista dataa syvällisellä tasolla. Tätä varten tietokonenäkö pyrkii toteuttamaan prosessin, jossa kuvat kaapataan käyttämällä asianmukaisia laitteita, minkä jälkeen kuvia prosessoidaan käyttäen algoritmeja. Lopuksi kuvat analysoidaan ja tämän avulla pyritään saavuttamaan koneiden kyky toimia ja tehdä päätöksiä samalla tavalla kuin ihminen visuaalisen tiedon perusteella. (Abioye et al. 2021)

Konenäössä on tapahtunut suurta kehitystä lähivuosina, erityisesti syväoppimisen ansiosta. Syväoppiminen on mahdollistanut tarkemman ja luotettavamman kuvien luokittelun, objektien tunnistamisen ja videoiden sisällön analysoinnin. Syväoppiminen on mahdollistanut monimutkaisten piirteiden oppimisen suoraan raakadatasta, mikä on johtanut ennennäkemättömään tarkkuuteen visuaalisen datan analysoinnissa. (Zhao et al. 2024)

Konvoluutioverkot (convolutional neural networks, CNN) ovat parantaneet konenäköä huomattavasti. Konvoluutioverkot ovat koneoppimisen alakategoria, joka on erikoistunut kuvien tunnistukseen ja analysointiin. Ne ovat syviä oppimismalleja, jotka kykenevät oppimaan monimutkaisia piirteitä kuvista useiden kerrosten kautta. Konvoluutioverkot käyttävät erilaisia kerroksia erottamaan ja analysoimaan kuvista tärkeitä ominaisuuksia eri tasoilla käyttämällä suodattimia, jotka tunnistavat erilaisia piirteitä, kuten reunoja, kulmia ja muita tekstuuri-elementtejä. Kunkin konvoluutiokerroksen jälkeen verkko kykenee tunnistamaan yhä monimutkaisempia piirteitä kuvasta. (Bharadiya 2023)

4.3 Tietopohjaiset järjestelmät

Tietopohjaiset järjestelmät (knowledge-based systems) hyödyntävät koneenpääätöksen tekoa olemassa olevan tiedon perusteella. Tietokanta luodaan tallentamalla alakohdista asiantuntijatietaa, aiempia tapauksia tai kokemuksia ja muita relevantteja tietolähteitä. Tietopohjaisten järjestelmien etuna on helppo pääsy suureen määrään erityisalaa koskevaa tietoa. (Cao et al. 2022)

Tietopohjaiset järjestelmät voidaan teoriassa jakaa neljään osaan: asiantuntijajärjestelmiin, tapauspohjaisiin päättelyjärjestelmiin, älykkäisiin opetusjärjestelmiin ja tietokantojen hallintajärjestelmiin. Asiantuntijajärjestelmät koostuvat tehtäväkohtaisesta tiedosta tietyltä asiantuntija-alueelta ja jäljittelee ihmisten päätöksentekoa ratkaistakseen tiettyjä ongelmia. Tapauspohjaiset päättelyjärjestelmät (case-based reasoning eli CBR) muodostuvat menneistä kokemuksista tai vanhoista tapauksista, joita käytetään uusien tilanteiden selittämiseen, tulkittamiseen tai arvosteluun. Älykkäät opetusjärjestelmät käyttävät tekoälytekniikoita tarjoamaan opettajille tietoa siitä, mitä he opettavat, kenelle he opettavat ja miten he opettavat. Tietokantojen hallintajärjestelmät sisältävät tekoälyohjattuja käyttöliittymiä. (Abioye et al. 2021)

Toinen keskeinen ongelma on moodin romahtaminen, jossa malli tuottaa vain rajallisia variaatioita, epäonnistuen koulutusdatan monimuotoisuuden tallentamisessa (Bandi et al. 2023). Moodin romahtaminen on tilastotieteellinen ilmiö, joka liittyy aineiston moodiin eli yleisimpään arvoon. Tämä ilmiö tapahtuu, kun aineistossa ei ole selvästi erottuvaa yleisintä arvoa, ja sen seurauksena moodi menettää merkityksensä tai "romahtaa". Generatiiviset mallit ovat usein myös epäselviä ja niiden päätöksentekoprosessit ovat läpinäkymättömiä, mikä voi heikentää luottamusta niihin erityisesti kriittisillä sovellusalueilla (Bandi et al. 2023).

4.4 Generatiivinen tekoäly

Generatiivinen tekoäly viittaa laskennallisiin tekniikoihin, jotka kykenevät tuottamaan uudenlaista, merkityksellistä sisältöä, kuten tekstiä, kuvia tai ääntä (Feuerriegel et al. 2024). Generatiivisen tekoälyn malli edustaa valvomattoman koneoppimisen suuntausta, erottaen sen aikaisemmista malleista, jotka ovat osoittaneet rajoitteita yleistämiskyvyssään. Generatiivinen tekoälyn kyky tuottaa multimodaalista sisältöä mahdollistaa sen soveltamisen laajasti eri aloilla. (Fui-Hoon Nah et al. 2023). Multimodaalinen sisältö tarkoittaa sellaista sisältöä, joka yhdistää useita eri ilmaisumuotoja tai "modeja" viestin välittämiseksi. Näitä ilmaisumuotoja voivat olla esimerkiksi teksti, kuva, ääni, video, animaatiot ja muut visuaaliset tai auditiiviset elementit.

Yksi merkittävimmistä haasteista generatiivisessa tekoälyssä on koulutusdatan vaatimukset; generatiiviset mallit tarvitsevat suuria ja monipuolisia datamääriä oppiakseen perustavanlaatuisia malleja ja tuottaakseen merkityksellisiä tuloksia. Tietoaineistojen hankinta ja käsittely voivat olla haastavia, ja niiden laadulla on suora vaikutus mallin suorituskykyyn. Lisäksi generatiivisten mallien koulutus ja käyttö vaativat merkittäviä laskentaresursseja, mikä edellyttää erikoistunutta laitteistoa. (Bandi et al. 2023)

4.5 Luonnollisen kielen käsittely

Luonnollinen kielen käsittely eli NLP (natural language processing) käsittelee ihmiskieltä tietokoneiden avulla. NLP mahdollistaa koneiden osallistumisen tehtäviin, kuten kääntämiseen eri kielten välillä, tekstisisällön automaattiseen yhteenvetoon, käyttäjäystävällisten rajapintojen kehittämiseen, monikielisen tiedonhaun toteuttamiseen, puheen tunnistukseen ja erikoisalojen asiantuntijajärjestelmiin. (Abioye et al. 2021)

Yksi keskeisistä haasteista luonnollisen kielen käsittelyssä on datan eristyneisyys, joka tarkoittaa, että käytettävissä olevat tiedot ovat hajallaan eri lähteissä tai formaateissa, mikä tekee niiden yhdistämisestä, jakamisesta ja hyödyntämisestä haastavaa. Haasteita tuo myös alan spesifisen terminologian ja kontekstin ymmärtäminen, mikä on kriittistä rakennusmääräysten ja -sopimusten tarkassa tulkitsemisessä. Datan saatavuuden ja laadun puute rajoittaa myös NLP-mallien koulutusta ja tehokkuutta, korostaen tarvetta paremmille datalähteille ja laadunvarmistusmenetelmille. (Ding et al. 2022)

Generatiivista tekoälyä voidaan käyttää luonnollisen kielen käsittelyn haasteiden ratkaisemiseen. Generatiiviset tekoälymallit voivat käsitellä hajanaista dataa eri lähteistä ja formaateista yhdistämällä sen yhtenäiseksi tietokokonaisuudeksi. Nämä mallit pystyvät tunnistamaan ja yhdistämään olennaisia tietoja eri dokumenteista ja tuottamaan yhteenvetoja tai raportteja. Generatiiviset tekoälymallit voidaan myös kouluttaa ymmärtämään erityisiä alan termejä ja kontekstia. Tämä tapahtuu hyödyntämällä alan asiantuntijoiden antamaa palautetta ja merkitsemällä dataa tarkasti, mikä auttaa malleja ymmärtämään ja käsittelemään alan spesifistä kieltä. Merkattu data tarkoittaa tietoa, johon on lisätty erilaisia merkintöjä, tunnisteita tai selityksiä, jotka tarjoavat lisätietoa datan eri osista. Tämä prosessi tunnetaan myös nimellä annotointi. (Ghaisas and Singhal, 2024)

Generatiivinen tekoäly voi parantaa datan saatavuutta ja laatua useilla menetelmillä. Ensinnäkin automatisoitu annotointi (automated labeling) käyttää työkaluja, jotka hyödyntävät heikkoa valvontaa (weak supervision) datan merkkäamisessä. Heikossa valvonnassa annotointiprosessissa käytetään sääntöpohjaisia menetelmiä, avainsanoja tai esikoulutettuja malleja automaattisesti luomaan etikettejä, mikä vähentää manuaalisen työn tarvetta ja parantaa datan johdonmukaisuutta. (Ghaisas and Singhal, 2024)

Prompting-tekniikat kuten zero-shot ja few-shot, mahdollistavat NLP käytön ilman laajaa erikoiskoulutusta. Zero-shot tarkoittaa, että malli saa suoritettavan tehtävän ilman esimerkkejä, kun taas few-shot sisältää muutaman esimerkin tehtävän suorittamiseksi. Tämä vähentää tarvetta suurelle määrälle merkittyä dataa ja parantaa datan hyödyntämistä olemassa olevilla resursseilla. (Ghaisas and Singhal, 2024)

Generatiiviset tekoälymallit voivat myös puhdistaa raakatekstiä ja poistaa kohinaa, kuten erikoismerkkejä ja formaattivirheitä. Ne voivat poimia ja jäsentää olennaisia tietoja strukturoimattomasta tekstistä, mikä tekee datasta laadukkaampaa ja käyttökelpoisempaa NLP-tehtäviin. Lisäksi generatiivinen tekoäly voi varmistaa datan edustavuuden ja vähentää ennakkoluuloja. Tämä tarkoittaa, että kerätty data edustaa kattavasti todellista maailmaa ja poistaa syrjiviä näytteitä tai muuttaa anonymiksi henkilökohtaisia tietoja, mikä parantaa mallien luotettavuutta ja eettisyyttä. (Ghaisas and Singhal, 2024)

4.6 Autonomiset tekoälyagentit

Tekoälyagentit ovat tekoälysovelluksia, jotka pystyvät operoimaan itsenäisesti ihmisen ohjauksesta riippumatta (Totschnig 2020). Nämä agentit ovat osoittaneet suurta potentiaalia monilla eri aloilla, kuten robotiikassa, terveydenhuollossa, liikenteessä ja taloudessa, tarjoten useita hyötyjä, kuten tehokkuuden lisääntyminen, virheiden väheneminen ja kyky käsitellä monimutkaisia tehtäviä, jotka ovat aikaa vieviä tai mahdottomia ihmisille. (Li ja Ning 2023)

Tekoälyagentit kykenevät hyödyntämään multimodaalisia datalähteitä, kuten tekstiä, kuvia, videoita ja sensoridataa. Lisäksi ne voivat oppia uusia taitoja itsenäisesti ja parantaa suorituskyykyään, mikä tekee niistä arvokkaita työkaluja muun muassa koulutukseen ja teknologian kehityksen seuraamiseen. (Torro 2024) Tekoälyagentteja voidaan myös opettaa matkimaan asiantuntijoiden toimintaa. Näissä sovelluksissa tekoälyagentit voivat oppia suoriutumaan monimutkaisista tehtävistä ja päätöksenteon haasteista ilman ihmisen suoraa ohjausta. (Shuford ja Islam 2024)

Lukemattomista käyttömahdollisuuksista huolimatta autonomiset agentit ovat edelleen kehitysvaiheessa ja niihin liittyy merkittäviä rajoituksia, kuten tekoälylle tyypillinen tilan tietoisuuden puuttuminen, joka voi johtaa tekoälyn ajautumiseen silmukoihin tai hyödyttömien tehtävien suorittamiseen. Lisäksi agenttien integrointi tuottaa omat haasteensa, mikä voi asettaa vaikeuttaa niiden käyttöönottoa. (Torro 2024)

5. DATAN KERÄÄMINEN TEKOÄLYSOVELLUKSIIN

Hyvän lopputuloksen saavuttaminen tekoälysovelluksissa edellyttää riittävästi korkealaatuista dataa. Rakennusalalla dataa pystytään keräämään usealla eri tavalla. Seuraavaksi esitellään työturvallisuutta kehittävien tekoälysovellusten kannalta merkittävimmät datan keräämisen menetelmät.

5.1 Kamerat

Kamerajärjestelmistä saadaan arvokasta dataa tekoäly sovelluksiin. Etenkin konenäkö vaatii erilaisten kamerajärjestelmien tuottamaa dataa toimiakseen. Kameroita on paljon erilaisia ja niistä voidaan saada hyvin laajasti erilaista dataa. Erilaisista kameroista voidaan esimerkiksi saada harmaasävykuvaa, RGB-värikuvaa, hyperspektrikuvaa tai kasvojen ominaisuuksia sisältävää kuvaa (Voulodimos et al. 2018). Lisäksi kuvat tai videot voivat olla joko 2- tai 3 ulotteisia. Myös 360 asteen kuvaus ja videokuvaus voi toimia konenäön data lähteenä esimerkiksi ennustamaan käyttäjien katseen suuntaa (Van Damme et al. 2022).

Kameralla varustettuja nelikoptereita, eli droneja voidaan käyttää kuvaamaan ja video kuvaamaan rakennustyömaiden toimintaa eri kulmista ja korkeuksista. Dronen avulla pystytään keräämään dataa vaikeapääsyisistäkin paikoista. Dataa pystytään lähettämään reaaliaikaisesti esimerkiksi syväoppimismalliin, joka analysoi dataa. Dronen käyttö datan keräämiseen on sekä tehokasta että kustannustehokasta. (Shanti et al. 2022)

5.2 Esineiden internet (IoT)

Esineiden internet eli englanniksi internet of things on fyysisten esineiden verkosto. kategoriaan kuuluu laaja valikoima laitteita, sensoreita, esineitä ja järjestelmiä, jotka on yhdistetty internetiin. Ne voivat kerätä ja jakaa tietoa automaattisesti ja niitä voidaan ohjata etänä. IoT:n tarkoituksena on tehdä esineistä "älykkäitä" antamalla niille kyky kommunikoida keskenään ja internetin välityksellä (Gokhale et al. 2018). Esimerkiksi, sensorit, jotka ovat keskeinen osa IoT-laitteita, voivat havaita tai mitata ympäristön muutoksia tuottaen tietoa, joka kertoo niiden tilasta tai jopa vuorovaikuttaa ympäristön kanssa (Lakshmana et al. 2022).

IoT- laitteiden tuottama data on hyvin monipuolista ja pystyvät tuottamaan esimerkiksi ympäristödataa, joka kattaa lämpötilan, kosteuden, valaistuksen, ilmanlaadun, äänitasot ja muut vastaavat olosuhteet. IoT-laitteita voidaan käyttää myös tarkan sijaintitiedon tuottamiseen, käyttäen hyväksi GPS:ää tai muita sijaintipalveluita. Tunnistetiedoista, kuten RFID-tunnisteista tai biometrisista tiedoista voidaan todentaa henkilöllisyys. Lisäksi terveystiedoista voidaan tunnistaa ihmisen syke, verenpaine ja fyysinen aktiivisuus. (Madakam et al. 2015) IoT- Laitteiden tuottamaa dataa voidaan analysoida esimerkiksi syväoppimisen menetelmin (Lakshmana et al. 2022).

5.3 Rakennusalan dokumentit

Rakennusalan dokumentit tarjoavat arvokasta dataa tekoälysovelluksille. Työturvallisuuden näkökulmasta voidaan tutkia esimerkiksi turvallisuusraportteja, työmaapäiväkirjoja tai turvallisuussuunnitelmia ja -ohjeistuksia. Tekstimuotoisia dokumentteja voidaan lukea ja analysoida tekoälyn avulla (Tixier et al. 2016). Dokumenttien avulla voidaan tutkia työturvallisuutta pitkältä aikaväliltä.

Haasteita dokumentteja analysoidessa kohdataan tietosuoja- ja yksityisyyslaissa (Baduge et al. 2022). Myös datan laatu ja kattavuus voivat tuottaa ongelmia datan hyödyntämisessä (Tixier et al. 2016).

5.4 Haasteet datan keräämisessä

Rakennusalalla datan keräämisessä kohdataan monia haasteita, jotka vaihtelevat teknologisista ja organisatorisista esteistä taloudellisiin ja tietoturvaan liittyviin kysymyksiin. Ensinnäkin suuren ja monimuotoisen datan hallinta on keskeinen haaste, sillä työmaat tuottavat valtavat määrät dataa erilaisista lähteistä. Tämän datan tehokas kerääminen, tallentaminen ja analysointi vaativat kehittyneitä teknologisia ratkaisuja. Lisäksi datan laadun varmistaminen on haastavaa sillä virheet, puutteet tai väärin kerätty tieto voivat johtaa harhaanjohtaviin tuloksiin ja päätöksentekoon. (Baduge et al. 2022)

Yksityisyys ja tietoturva ovat myös merkittäviä huolenaiheita, kun kerätään dataa, joka saattaa sisältää arkaluonteisia tietoja (Baduge et al. 2022). Yleisessä tietosuoja-asetuksessa asetetaan yrityksille ja organisaatioille henkilötietojen keräämistä, säilytystä ja hallinnointia koskevat tarkat vaatimukset (yleinen tietosuoja-asetus).

Teknologian integrointi olemassa oleviin järjestelmiin tuo omat haasteensa, sillä eri teknologioiden yhteensopivuus ja saumaton yhteistyö ovat avainasemassa datan hyödyntämisessä. Myös taloudelliset kustannukset uusien teknologioiden hankinnasta ja ylläpidosta voivat olla merkittäviä, mikä asettaa lisäpaineita projektien budjetteihin. Nämä

haasteet vaativat jatkuvaa huomiota ja innovatiivisia ratkaisuja, jotta rakennusala voi hyödyntää tehokkaasti kerättyä dataa ja parantaa toimintansa tehokkuutta ja turvallisuutta. (Baduge et al. 2022)

Tekoälysovellukset tuottavat suuria määriä dataa, mikä lisää vaatimuksia muistijärjestelmien suorituskyyvylle, kapasiteetille ja energiatehokkuudelle. Yksi keskeinen ongelma esiintyy, kun suurin osa energiankulutuksesta syntyy datan siirrosta prosessointiyksiköiden ja muistin välillä, mikä johtuu siitä, että muistiteknologian energiatehokkuus ei ole parantunut yhtä nopeasti kuin prosessointiteknologian. Tätä kutsutaan von Neumann -pullonkaulaksi, joka viivästyttää suorituskyykyä. Tekoälyn kaltaisissa sovelluksissa, jotka vaativat nopeaa pääsyä suuriin datamääriin, viivästykset suorituskyyvyssä voivat tuottaa suuria ongelmia. (Molas ja Nowak 2021)

6. TEKOÄLY TURVALLISUUSRISKIEN ARVIOINNISSA, ENNUSTAMISESSA JA EHKÄISYSSÄ

Tekoälyn ja älykkäiden teknologioiden käyttöönotto rakennustyömailla on avannut uusia mahdollisuuksia työturvallisuuden parantamiseen. Modernit tekoälyjärjestelmät pystyvät ennakoimaan turvallisuusriskejä sekä valvomaan työmaan olosuhteita reaaliajassa. Tekoälyä hyödyntämällä voidaan analysoida historiallista dataa onnettomuuksista ja työmaan toiminnasta, valvoa turvallisuusmääräysten noudattamista ja ennustaa laitteiston huoltotarpeita, mikä kaikki yhdessä luo turvallisemman ja tehokkaamman työympäristön rakennusalalla.

6.1 Koneoppiminen

Koneoppimismallit voivat oppia historiallisesta tapahtumadatasta ja tunnistaa piilotettuja kuvioita sekä suhteita, jotka voivat ennustaa tulevia tapahtumia tai onnettomuuksia. Esimerkiksi mallit voivat tunnistaa tietyt olosuhteet tai toiminnot, jotka usein johtavat onnettomuuksiin ja auttaa ennakoimaan niitä tulevaisuudessa.

Koneoppimisen hyödyllisyys työtapaturmien ennustamisessa on todettu usealla eri toimialoilla. Esimerkiksi terveydenhuollon alalla tehdyssä tutkimuksessa koneoppimisella on pystytty ennakoimaan mahdollisia turvallisuusriskejä sairaalaolosuhteissa (Koklonis et al. 2021). Myös intialaisessa terästehtaassa tehdyssä tutkimuksessa koneoppimisella pystyttiin ennakoimaan mahdollisia riskejä ja ennustamaan työtapaturmia suurella tarkkuudella (Sarkar et al. 2019).

Coloradon yliopistossa vuonna 2016 tehdyssä tutkimuksessa on onnistuttu hyödyntämään koneoppimisalgoritmeja ennustamaan rakennusalalla sattuneita vammoja. Tutkimuksessa hyödynnettiin rakennusalan vahinkoraportteja, jotka oli kerätty yli 470 urakoitsijalta ympäri maailmaa. Nämä raportit kattoivat miljoonia työtunteja ja sisälsivät yhteensä 5298 vahinkoraporttia, jotka edustivat laajaa kirjoa erilaisia vammoja ja turvallisuuteen liittyviä tapahtumia. (Tixier et al. 2016)

Vahinkoraportit olivat alun perin epäjärjestyntyttä tekstidataa, joka sisälsi kuvauksia tapahtuneista vahingoista, niiden olosuhteista ja seurauksista. Tämä data muunnettiin strukturoituun muotoon käyttämällä luonnollisen kielen käsittelyn tekoälysovellusta. NLP-työkalun avulla datasta voitiin tunnistaa ja erottaa keskeiset ominaisuudet, kuten vamman tyyppi, siihen johtaneet olosuhteet, vahingoittunut kehon osa ja vamman vakavuus. Tämä mahdollisti koneoppimismallien opettamisen tunnistamaan yhteyksiä

näiden ominaisuuksien välillä ja ennustamaan vastaavanlaisia tapahtumia tulevaisuudessa. (Tixier et al. 2016)

Koneoppimista hyödyntämällä on pystytty myös ennustamaan rakenteiden heikkene- mistä. Analysoimalla suurta määrää dataa eri lähteistä, koneoppiminen auttaa tunnistamaan mahdolliset vikaantumiset tai huollon tarpeet ennen kuin ne aiheuttavat suurempia ongelmia tai keskeytyksiä toiminnassa. Esimerkiksi rakennusten älykkäässä valvonnassa ja kunnon seurannassa käytetään koneoppimista tunnistamaan rakenteiden heikkenemisen merkkejä ajoissa. Tämä mahdollistaa huoltotoimenpiteiden suunnittelun ja toteuttamisen ennen kuin mahdolliset vauriot pahenevat tai aiheuttavat vaaratilanteita. Myös rakennustyömaiden laitteiston huoltotarvetta voidaan ennustaa analysoimalla laitteiston käyttödataa (Garyaev ja Garyaev 2023). Tekoälyn käyttö mahdollistaa laitteiston käyttöiän pidentämisen ja huoltokustannusten vähentämisen ennakoivalla ylläpidolla. (Baduge et al. 2022)

Koneoppimisen onnistunutta hyödyntämistä työtaturmien ennustamisessa voidaan pitää merkittävänä edistysaskeleena kohti turvallisempaa rakennusalaa. Koneoppimisen avulla yritykset kykenevät ennakoimaan ja estämään onnettomuuksia ennen niiden tapahtumista, mikä vähentää työntekijöiden loukkaantumisriskiä, kun ennaltaehkäisevät toimet voidaan kohdentaa juuri niihin kohteisiin, joissa vaikutus on suurin. Lisäksi ennakoivan työturvallisuuden strategia auttaa yrityksiä välttämään suuria taloudellisia tappioita, jotka voivat seurata työtaturmistista, kuten korvausvaatimuksia ja tuotannon keskeytyksiä.

6.2 Konenäkö

Konenäön ja syväoppimisen yhdistetyt mahdollisuudet työturvallisuuden kehittämässä ovat laajat ja aiheesta onkin tehty viime vuosina uutta tutkimusta. Konenäkö mahdollistaa jatkuvan turvallisuuden seurannan ja analysoinnin reaaliajassa (Fang et al. 2020). Syväoppiminen taas mahdollistaa monimutkaisten suhteiden oppimiseen suurista datamääristä (Mungoli 2023).

Konenäön avulla voidaan tunnistaa työntekijöitä, jotka eivät käytä asianmukaisia turva- varusteita, kuten turvaliivejä tai suojakypäriä, sekä havaita mahdollisia vaarallisia tilanteita, kuten työntekijöiden läheisyyttä korkeisiin reuna-alueisiin tai muihin vaarallisiin kohteisiin. Lisäksi konenäköteknologiaa voidaan käyttää ympäristön turvallisuuden varmistamiseen tunnistamalla betonin halkeamia, teräksen korroosiota, asfalttivrheitä ja muita rakenteellisia vikoja, jotka voivat vaarantaa sekä työntekijöiden että rakennuksen turvallisuuden. (Moragane et al. 2022)

Toimiakseen konenäkö vaatii huomattavan määrän dataa. Datana voidaan käyttää 2D- ja 3D-kuvia, videoita sekä IoT -laitteiden keräämää dataa. Myös tekstidatan, kuten turvallisuusraporttien ja visuaalisen datan yhdistäminen syväoppimisen menetelmin voi syventää ymmärrystä turvallisuusriskeistä. (Fang et al. 2020)

Moskovan rakennustekniikan yliopistossa tehdyssä tutkimuksessa tutkittiin tekoälyn videovalvonnan integrointia rakennustyömaiden laitteiston hallintaan. Keskeisenä tavoitteena oli parantaa rakennuskoneiden ja -laitteiden turvallisuutta ja tehokkuutta käyttämällä tekoälyalgoritmeja ja videovalvontajärjestelmiä. Tutkimuksen tuloksena kehitettiin konenäköön pohjautuva tekoälyprototyyppi, joka tunnistaa rakennustyömaan laitteisto videokuvasta ja seurata sen käyttöä reaaliajassa. Tekoäly pystyy havaitsemaan poikkeavuuksia laitteiston käytössä, kuten luvatonta alueen käyttöä. Prototyyppi tunnistaa myös vaaralliset työskentelyolosuhteet. (Garyaev ja Garyaev 2023)

Konenäön soveltamiseen työturvallisuuden näkökulmasta rakennusalalla liittyy merkittäviä haasteita. Yksi keskeisimmistä ongelmista on laadukkaan ja monipuolisen datan puute. rakennustyömaiden dynaaminen luonne tekee konenäön hyödyntämisestä haastavaa. Olosuhteet, kuten valaistus, sää ja työskentelyalueet, muuttuvat tiheästi, mikä voi vaikeuttaa turvallisuusuhkien tunnistamista visuaalisen datan avulla. Konenäön on pystyttävä sopeutumaan näihin muuttuviin tilanteisiin, jotta se voi tunnistaa potentiaaliset vaaratilanteet luotettavasti. (Fang et al. 2020)

Konenäön tekniset rajoitteet, kuten tunnistustarkkuus tuottavat myös haasteita. Etenkin erityisesti pienten tai monimutkaisten kohteiden, kuten henkilökohtaisten suojavaarusteiden tai rakenteellisten vikojen, tunnistamisessa konenäkö kohtaa suuria haasteita. Tarkkuuteen vaikuttavat useat tekijät, kuten kuvanlaatu ja kohteen peittävyys myös tuottavat omat haasteensa. Mallien kyky yleistää opittua uusiin, näkemättömiin tilanteisiin on haasteellista, erityisesti kun käytettävissä oleva koulutusdata on rajallista tai se keskittyy vain tiettyihin tilanteisiin. (Fang et al. 2020)

6.3 Tietopohjaiset järjestelmät

Turkissa tehdyssä tutkimuksessa kehitettiin tapauspohjainen päättelyjärjestelmä eli CBR (Case-Based Reasoning), joka ratkaisee uusia turvallisuusongelmia hyödyntämällä aikaisemmin kohdattuja, samankaltaisia tapauksia. Menetelmä alkaa ongelman määrittelyllä, jonka jälkeen se etsii tietokannasta vastaavia aiempia tapauksia. Löydettyä tapausa sovelletaan uuteen ongelmaan, tarvittaessa muokaten ja ratkaisun tehokkuutta arvioidaan. Jos ratkaisu on onnistunut, se tallennetaan tietokantaan uutena ta-

pauksena, jolloin järjestelmä oppii ja kehittyy. CBR soveltuu erityisesti alueille, joilla ongelmat ovat toistuvia tai samankaltaisia, mutta eivät täysin identtisiä. Tämä mahdollistaa räätälöityjen ja kontekstisidonnaisten ratkaisujen tarjoamisen ilman, että tarvitaan syvällistä peruseriänteiden ymmärrystä. (Okudan et al. 2021)

CBR kohtaa myös useita haasteita. Elävä tieto, joka tarkoittaa tietojen keräämistä reaaliajassa projektien edetessä, vaatii järjestelmien jatkuvaa päivitystä ja ylläpitoa, mikä on käytännössä haastavaa. Lisäksi riskienhallinnan eri vaiheet, kuten riskien tunnistaminen, analysointi, vastaustoimenpiteet ja seuranta, johtaa tiedon hajanaisuuteen ja vaikeuttaa kokonaisvaltaisen riskienhallintaprosessin toteuttamista. Tietokantojen täytyy myös olla jatkuvasti päivitettyjä ja kattavia, jotta ne voivat tarjota luotettavaa tietoa päätöksenteon tueksi, mikä on jatkuva haaste. Uuden teknologian käyttöönotto edellyttää käyttäjien koulutusta ja kohtaa usein vastustusta muutoksen pelosta, mikä tekee järjestelmän käyttöönoton ja sen hyväksynnän organisaatiossa haasteelliseksi. (Okudan et al. 2021)

6.4 Luonnollisen kielen käsittely

Luonnollisen kielen käsittelyn (NLP) soveltaminen rakennustyömaiden työturvallisuuden kehittämiseen tarjoaa innovatiivisen lähestymistavan turvallisuusriskeihin. Automaatisoimalla turvallisuusraporttien, työntekijöiden haastattelujen ja muiden tekstilähteiden analysoinnin (Ballal et al. 2024). Tämän jälkeen suurta määrää tekstidataa voidaan analysoida syväoppimisen algoritmeilla ja tunnistaa toistuvia ongelmia ja riskialttiita käyttäytymismalleja (Ricketts et al. 2023).

NLP tukee myös turvallisuusmääräysten ja -ohjeiden tehokasta analysointia, mikä edistää olennaisten turvallisuustietojen levittämistä työmailla. Kun NLP integroidaan rakennustyömaiden viestintäjärjestelmiin, se mahdollistaa vaaratilanteiden reaaliaikaisen tunnistamisen ja varoittamisen. Lisäksi NLP:n avulla kerätystä datasta voidaan räätälöidä koulutusmateriaaleja ja -ohjelmia, jotka vastaavat työmaan erityistarpeita, keskittyen erityisesti yleisimpiin riskeihin ja niiden välttämiseen. NLP ei ainoastaan paranna työturvallisuutta vaan myös edistää turvallisuuskulttuuria ja varmistaa, että työntekijät ovat perillä turvallisuuskäytännöistä. (Ballal et al. 2024)

6.5 Älykkäät henkilösuojaimet

Älykkäät henkilösuojaimet ovat teknologisesti edistyneitä laitteita, jotka on suunniteltu parantamaan turvallisuutta työpaikoilla. Nämä suojaimet sisältävät sensoreita, jotka ke-

räävät tietoja käyttäjästä ja hänen ympäristöstään reaaliajassa. Älykkäät suojaimet voivat esimerkiksi seurata työntekijän fyysistä kuntoa ja ympäristön olosuhteita, kuten ilmanlaatua ja lämpötilaa. Älykkäät suojaimet käsittelevät kerättyjä tietoja tekoälyn avulla ja pystyvät ennustamaan ja varoittamaan mahdollisista vaaratilanteista. (Márquez-Sánchez et al. 2021)

Márquez-Sánchez et al. (2021) tekemässä artikkelissa ehdotetaan kolmen älykkään henkilösuojaimen – kypärän, rannekkeen ja vyön – käyttöä työturvallisuuden parantamiseksi. Älykäs kypärä on varustettu sensoreilla, jotka mittaavat ympäristön olosuhteita kuten valaistusta, ilman laatua, lämpötilaa ja ilmanpainetta. Kypärässä on myös kyky tunnistaa fyysiset iskut ja putoamiset. Tietoja käytetään varoittamaan käyttäjää mahdollisista vaaroista, kuten korkeasta kaasupitoisuudesta tai huonosta ilmanlaadusta. Älykäs ranneke mittaa käyttäjän biometrisiä tietoja, kuten sykettä ja kehon lämpötilaa. Ranneke voi myös tunnistaa fyysisiä aktiivisuuksia ja hälyttää esimerkiksi, jos työntekijä kaatuu tai kokee muita fyysisiä vaaratilanteita. Rannekkeen tarkoitus on seurata työntekijän terveydentilaa ja varoittaa mahdollisista terveysriskeistä. Älykäs vyö on suunniteltu tunnistamaan putoamiset ja ympäristön äänitasot. Vyössä on paniikkinäppäin, jonka avulla työntekijä voi ilmoittaa hätätilanteesta. Vyön sensoreiden avulla voidaan havaita, jos työntekijä putoaa tai jos ympäristön melutaso nousee vaarallisen korkeaksi, mikä mahdollistaa nopean reagoinnin onnettomuuksiin ja vaaratilanteisiin. (Márquez-Sánchez et al. 2021)

Nämä laitteet kommunikoivat keskenään ja keskusjärjestelmän kanssa, joka käyttää tekoälyä ja reunatietojenkäsittelyä analysoimaan kerättyä dataa reaaliajassa. Tämä mahdollistaa varhaisten varoitusten antamisen ja nopean toiminnan, jos työympäristössä havaitaan riskejä. Lisäksi järjestelmä auttaa luomaan kokonaisvaltaisen kuvan työpaikan turvallisuustilanteesta, mikä mahdollistaa jatkuvat parannukset työturvallisuudessa. (Márquez-Sánchez et al. 2021)

6.6 Tekoälyn hyödyntäminen työturvallisuuskoulutuksessa

Työturvallisuuskoulutus on keskeinen tapa vähentää työpaikalla esiintyviä riskejä sekä hätätilanteissa että normaalissa päivittäisessä toiminnassa. Erityisesti koulutuksen tarkoituksena on kehittää työntekijöiden vastuullisuutta ja tietoisuutta terveydestä ja turvallisuudesta, vähentää altistumista riskeille ja onnettomuuksille sekä antaa taitoja ja tietämystä terveellisistä ja turvallisista työtavoista. Näitä tavoitteita tuetaan systemaattisilla koulutusistunnoilla, kursseilla ja käsikirjoilla, jotka on suunnattu erityisesti työntekijöiden työpaikoille. (Ljubić et al. 2016)

Suomessa työturvallisuuden kehittämiseksi on kehitetty valtakunnallinen työturvallisuuskorttikoulutus. Työturvallisuuskorttikoulutus antaa perustiedot työympäristön vaaroista ja työsuojelusta yhteisellä työpaikalla. Koulutuksen hyväksytystä suorittamisesta myönnetään viisi vuotta voimassa oleva, henkilökohtainen työturvallisuuskortti. (Työturvallisuuskeskus).

Hussain et al. (2024) tekemässä tutkimuksessa tutkittiin, miten tekoälyä ja virtuaalitoimittisuutta eli englanniksi virtual reality (VR) pystytään hyödyntämään rakennustyöntekijöiden, erityisesti siirtotyöläisten, turvallisuuskoulutuksessa. Tutkimuksessa generatiivista tekoälyä, erityisesti ChatGPT:tä, käytetään virtuaalisena opettajana, joka mahdollistaa vuorovaikutuksen ja kysymysten esittämisen reaaliajassa koulutuksen aikana. Tämän innovaation avulla pyritään parantamaan tiedonsiirtoa ja koulutuksen tehoa. VR-tekniikan avulla simuloitiin rakennustyömaan vaarallisia tilanteita, joka mahdollisti työntekijöille koulutuksen vaaratilanteiden tunnistamisesta ja niiden hallinnasta ilman todellista riskiä. Tämä sisälsi erilaisia skenaarioita, kuten työskentelyn korkealla ja turvallisen liikkumisen rakennustyömaalla. (Hussain et al. 2024)

VR- ja tekoäly pohjainen koulutusjärjestelmä paransi merkittävästi koulutukseen osallistuneiden tietämystä ja ymmärrystä turvallisuusasioista. Järjestelmä teki oppimisympäristöstä motivoivamman ja mukaansatempaavamman, ja se soveltui hyvin monikieliseen ja kulttuurisesti monimuotoiseen työvoimaan. Tutkimuksessa korostettiin erityisesti sitä, kuinka tärkeää on, että koulutusmateriaalit ja -menetelmät vastaavat kohdeyhmän tarpeita, kuten kielitaitoa ja kulttuuritaustaa. (Hussain et al. 2024)

6.7 Tekoälyn käyttöönoton haasteet

Tekoälyn käyttöönotto rakennusalalla herättää haasteita, jotka vaikuttavat työntekijöiden arkeen ja hyvinvointiin. Erityisesti psykologiset ja psykososiaaliset riskit ovat huolenaiheita, sillä tekoälyn käyttö työsuorituksen seurannassa ja arvioinnissa voi lisätä työntekijöiden kokemaa stressiä ja ahdistusta. Työn luonteen muutokset ja pelko työpaikan menetyksestä voivat myös heikentää työntekijöiden mielenterveyttä. Tietosuojaa ja yksityisyys muodostavat toisen merkittävän haasteen, sillä tekoälyn avulla kerättyjen henkilökohtaisten tietojen käsittely saattaa johtaa yksityisyyden suojan loukkauksiin ja tietoturvariskeihin. (Jarota 2023)

Lisäksi syrjintä ja oikeudenmukaisuus ovat keskeisiä kysymyksiä, kun tekoälyjärjestelmiä hyödynnetään työsuoritusten arvioinnissa. Mikäli järjestelmät nojaavat puutteellisiin tai ennakkoluuloisiin tietoaistoihin, voi seurauksena olla epäoikeudenmukaisuutta ja

eriarvoisuutta työpaikalla. Liiallinen riippuvuus tekoälystä puolestaan voi alentaa työntekijöiden kykyä tehdä itsenäisiä päätöksiä ja ratkaista ongelmia, erityisesti kun tekoäly kohtaa odottamattomia tilanteita tai toimintahäiriöitä. Nämä haasteet vaativat huolellista pohdintaa ja strategioita. (Jarota 2023)

Teknisiä haasteita esiintyy tekoäly algoritmien koulutuksen ja toteutuksen vaativissa huomattavissa laskentaresursseissa. Etenkin muisti ja prosessointitehoa tekoälyjen koulutus vaatii huomattavan määrän. Lisäksi koulutusaikojen pituus tuo omat haasteensa. Tekoälyjen koulutus voi kestää tunteja, päiviä tai jopa viikkoja, riippuen datan koosta, mallin monimutkaisuudesta ja käytettävissä olevista laskentaresursseista. (Garyaev ja Garyaev 2023)

Muita haasteita tekoälyn käyttöönottoon rakennusalalla tuo muun muassa kulttuurinen muutosvastarinta, korkeat alkuinvestoinnit, osaajapula sekä internet-yhteyksien puutteet rakennustyömailla. Näiden haasteiden ratkaiseminen vaatii selkeitä toimenpiteitä ja innovatiivisia ratkaisuja, jotta tekoälystä voidaan hyötyä rakennusalalla tehokkaammin. (Abioye et al. 2021)

7. PÄÄTELMÄT

Tässä kirjallisuustutkimuksessa tutkittiin tekoälyn hyödyntämistä rakennusalan työturvallisuuden kehittämisessä. Seuraavaksi esitellään tutkimuksen tulokset ja vastaan tutkimuskysymyksiin. Tämän jälkeen esitellään tutkimuksen päätelmät. Lopuksi arvioidaan tutkimuksen onnistumista ja esitellään jatkotutkimusehdotukset.

7.1 Tutkimuksen tulokset

Tutkimuksessa oli kolme alatutkimuskysymystä, joiden avulla pyritään vastaamaan kysymykseen: ”miten tekoälyä voidaan hyödyntää rakennusalan työturvallisuuden kehittämisessä?” Aihetta tarkasteltiin ensin esittelemällä Suomen työturvallisuuden nykytilanne. Tämän jälkeen esiteltiin työturvallisuuden näkökulmasta merkittävimmät tekoälysovellukset. Jota seurasi datan keräämisen esittely kyseisiin tekoälysovelluksiin. Lopuksi esiteltiin tutkimuksia, jotka käsittelivät tekoälyllä työturvallisuuden kehittämistä.

Tutkimuksen ensimmäinen alakysymys oli: ”Mikä on rakennusalan työturvallisuuden nykytilanne ja haasteet?” Kysymykseen vastataan kappaleessa kolme. Rakennusalalla sattuu vuosittain noin 13 000 työtapaturmaa (Tikku-tilastosovellus). Rakennusalan työtapaturmat ovat laskussa, joskin alan tapaturmataajuus viestii alan suuresta tapaturmaherkkyydestä ja siitä, että alalla on vielä paljon varaa kehittyä turvallisuuden näkökulmasta.

Toinen alakysymys oli: ”Mitä eri tekoälyjä on olemassa ja miten niitä pystytään hyödyntämään rakennusalalla työturvallisuuden näkökulmasta?” Kysymykseen vastataan kappaleessa neljä. Rakennusalan työturvallisuuden kannalta oleellimmat tekoäly ala-alueet ovat koneoppiminen, konenäkö, luonnollisen kielen käsittely ja tietopohjaiset järjestelmät. Todettiin myös generatiivisen tekoälyn ja tekoälyagenttien merkitys tulevaisuudessa. Lopuksi mainittiin robotiikan välillinen hyöty työturvallisuudessa.

Kolmas ja viimeinen alakysymys oli: ”Mitä keinoja on kerätä dataa rakennusalalla ja miten sitä pystytään hyödyntämään tekoälyssä?” Kysymykseen vastataan kappaleessa viisi. Todettiin, että esiteltyihin tekoälyn ala-alueisiin pystytään keräämään dataa kame-roista, IoT-laitteista ja rakennusalan dokumenteista. Perehdyttiin myös datankeräämisen haasteisiin ja laillisuuteen, jossa esille tuli yksityisyyden- ja tietoturvanongelmat, sekä lisäkustannuksien tuomat taloudelliset ongelmat.

Tutkimuksen tuloksena havaittiin, että tekoäly tarjoaa monipuolisia mahdollisuuksia rakennusalan työturvallisuuden kehittämiseen. Sen avulla voidaan toteuttaa ennakoivaa

analytiikkaa, joka tunnistaa potentiaaliset vaarat aikaisempien onnettomuuksien ja läheltä piti -tilanteiden datasta. IoT-laitteiden keräämää dataa voidaan hyödyntää reaaliaikaisesti työntekijöiden kunnon ja sijainnin seurannassa, varoittaen vaarallisista tilanteista ennen niiden eskaloitumista. Tämän lisäksi tekoölyyn perustuva kameravalvonta mahdollistaa jatkuvan tarkkailun työmaalla, tunnistuen välittömästi turvallisuusrikkomukset, kuten puutteelliset suojavarusteet tai riskialttiit työskentelytavat.

Tekoöly voi myös parantaa koulutusta tarjoamalla simulaatioita ja interaktiivisia oppimisympäristöjä, jotka valmistavat työntekijöitä kohtaamaan työmaan haasteet turvallisesti. Kun nämä teknologiat yhdistetään jatkuvaan koulutukseen ja kulttuurin kehittämiseen, voidaan rakentaa entistä turvallisempia työympäristöjä. Haasteita tekoölyn käyttöönotossa kohdataan erityisesti tekoölyn vaatimissa suurissa laskentaresursseissa ja pitkissä koulutusajoissa. Lisäksi kulttuurinen muutosvastarinta, korkeat alkuinvestoinnit ja osaajapula muodostavat esteitä tekoölyn tehokkaalle hyödyntämiselle. Taulukossa 2 on tiivistetty eri tekoölynmuotojen käyttökohteet rakennusalan työturvallisuuden näkökulmasta.

Taulukko 2. Tekoölymuotojen käyttökohteet työturvallisuuden näkökulmasta.

Tekoöly	Käyttökohteet rakennusalan työturvallisuuden näkökulmasta
Koneoppiminen	Analysoi rakennustyömaan tietoja, tunnistaa riskitekijöitä ja ennustaa mahdollisia tapaturmia, mikä mahdollistaa ennaltaehkäisevien toimenpiteiden suunnittelun ja toteutuksen.
Konenäkö	Mahdollistavat vaaratilanteiden havaitsemisen reaaliajassa kameroiden avulla. Voivat seurata työmaiden turvallisuuskäytäntöjen noudattamista, kuten suojavarusteiden käyttöä, ja varoittaa vaaratilanteista ennen niiden syntymistä.
Tietopohjaiset järjestelmät	Tarjoavat työntekijöille välittömiä ja tarkkoja ohjeita turvallisuusprotokollista sekä parhaista käytännöistä, mikä parantaa päätöksentekoa ja vähentää virheitä.
Luonnollisen kielen käsittely	Analysoivat työturvallisuusraportteja ja onnettomuuskertomuksia, tunnistuen yleiset riskit ja kehityskohteet, sekä auttaa luomaan selkeitä ja ymmärrettäviä turvallisuusohjeita.
Generatiivinen tekoöly	Voidaan käyttää työturvallisuuskoulutuksessa virtuaalisena opettajana. Tulevaisuudessa käyttökohteet todennäköisesti lisääntyvät huomattavasti.

Tulevaisuudessa suurimmat hyödyt tekoälyn käytöstä työturvallisuuden parantamiseen saavutetaan yhdistämällä eri tekoälymuotojen tuomat turvallisuusedut. Kattavasti tekoälysovelluksia hyödyntämällä voidaan luoda äärimmäisen tehokas ja reagoiva turvallisuusjärjestelmä, joka integroi rakennusalan dataa, reagoi dynaamisesti työympäristön muutoksiin, vähentää inhimillisiä virheitä ja optimoi turvallisuustoimenpiteitä.

7.2 Tutkimuksen arviointi ja jatkotutkimusehdotukset

Tutkimuksen onnistumisen kannalta olennaista on lähdeaineiston oikeellisuus. Tekoälyn nopean kehittymisen vuoksi useissa tutkimuksissa on vanhentunutta tietoa, joten pyrittiin käyttämään mahdollisimman tuoreita lähteitä. Työturvallisuustilastojen osalta käytettiin ajankohtaisimpia lukuja. Lähteinä pyrittiin käyttämään vertaisarvioituja tieteellisiä artikkeleita.

Kirjallisuustutkimus tarjosi arvokasta tietoa tekoälyn käytöstä rakennusalan työturvallisuuden kehittämisessä. Tutkimuksen vahvuutena oli sen kyky koota ja analysoida laaja-alaisesti olemassa olevaa tietoa, mikä mahdollistaa yleiskuvan saamisen aiheesta ja sen nykytilasta. Tämä on erityisen tärkeää nopeasti kehittyvällä teknologian alueella, jossa uudet innovaatiot ja sovellukset muuttavat jatkuvasti kenttää. Tutkimus myös korostaa tekoälyn potentiaalia vähentää onnettomuuksia ja parantaa työmaiden turvallisuutta tehokkaasti. Vaikka kirjallisuustutkimus tarjoaa kattavan yleiskatsauksen, se ei välttämättä pysty syventymään yksittäisten tutkimusten yksityiskohtiin tai arvioimaan niiden laatua yhtä perusteellisesti kuin primaaritutkimus. Tämän seurauksena kirjallisuustutkimuksen tulokset on nähtävä lähtökohtana jatkotutkimuksille, jotka voivat tarjota tarkempia analyysejä ja sovelluksia käytännön työturvallisuuden kehittämiseen.

Primääritutkimus tekoälyn käytöstä rakennusalan työturvallisuuden kehittämisessä voisi hyödyntää erilaisia tutkimusmenetelmiä, joilla saadaan syvällistä tietoa ja käytännön todisteita teknologian vaikutuksista. Kokeelliset tutkimukset voisivat testata tekoälysovelluksia kontrolloiduissa olosuhteissa tai suoraan rakennustyömailla, arvioiden niiden turvallisuusvaikutuksia verrattuna perinteisiin menetelmiin. Tapausanalyysit tarjoaisivat yksityiskohtaista tietoa tekoälyn integroinnista ja käytännön haasteista, sisältäen haastatteluja ja havainnointia.

LÄHTEET

- Abioye, S.O., Oyedele, L.O., Akanbi, L., Ajayi, A., Davila Delgado, J.M., Bilal, M., Akinade, O.O., Ahmed, A. (2021). Artificial intelligence in the construction industry: A review of present status, opportunities and future challenges. *Journal of Building Engineering* 44, 103299. Saatavissa: <https://doi.org/10.1016/j.jobe.2021.103299>
- Baduge, S.K., Thilakarathna, S., Perera, J.S., Arashpour, M., Sharafi, P., Teodosio, B., Shringi, A., Mendis, P. (2022). Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. *Automation in Construction* 141, 104440. Saatavissa: <https://doi.org/10.1016/j.autcon.2022.104440>
- Ballal, S., Patel, K., Patel, D. (2024). Enhancing Construction Site Safety: Natural Language Processing for Hazards Identification and Prevention. *Journal of Engineering, Project, and Production Management*. Saatavissa: <https://doi.org/10.32738/JEPPM-2024-0014>
- Bandi, A., Adapa, P.V.S.R., Kuchi, Y.E.V.P.K. (2023). The Power of Generative AI: A Review of Requirements, Models, Input–Output Formats, Evaluation Metrics, and Challenges. *Future Internet* 15, 260. Saatavissa: <https://doi.org/10.3390/fi15080260>
- Bharadiya, J. (2023). Convolutional Neural Networks for Image Classification. *International Journal of Innovative Research in Science Engineering and Technology* 8, 673. Saatavissa: <https://doi.org/10.5281/zenodo.7952031>
- Cao, Q., Zanni-Merk, C., Samet, A., Reich, C., Beuvron, F. de B. de, Beckmann, A., Giannetti, C. (2022). KSPMI: A Knowledge-based System for Predictive Maintenance in Industry 4.0. *Robotics and Computer-Integrated Manufacturing* 74, 102281. Saatavissa: <https://doi.org/10.1016/j.rcim.2021.102281>
- CGI (2023). Mitä on tekoäly? Saatavissa (Viitattu 4.3.2024): <https://www.cgi.com/fi/fi/mita-on-tekoaly>
- Delipetrev, B., Tsinaraki, C., Kostic, U. (2020). Historical Evolution of Artificial Intelligence. Publications Office of the European Union. Saatavissa: <https://publications.jrc.ec.europa.eu/repository/handle/JRC120469>
- Ding, Y., Ma, J., Luo, X. (2022). Applications of natural language processing in construction. *Automation in Construction* 136, 104169. Saatavissa: <https://doi.org/10.1016/j.autcon.2022.104169>
- Euroopan parlamentin ja neuvoston asetus (EU) 2016/679, annettu 27 päivänä huhtikuuta 2016, luonnollisten henkilöiden suojelusta henkilötietojen käsittelyssä sekä näiden tietojen vapaasta liikkuvuudesta ja direktiivin 95/46/EY kumoamisesta (yleinen tietosuoja-asetus). (2016). OJ L. Saatavissa: <http://data.europa.eu/eli/reg/2016/679/oj>
- Fang, W., Ding, L., Love, P.E.D., Luo, H., Li, H., Peña-Mora, F., Zhong, B., Zhou, C. (2020). Computer vision applications in construction safety assurance. *Automation in Construction* 110, 103013. Saatavissa: <https://doi.org/10.1016/j.autcon.2019.103013>

Feuerriegel, S., Hartmann, J., Janiesch, C., Zschech, P. (2024). Generative AI. *Bus Inf Syst Eng* 66, 111–126. Saatavissa: <https://doi.org/10.1007/s12599-023-00834-7>

Fui-Hoon Nah, F., Zheng, R., Cai, J., Siau, K., Chen, L. (2023). Generative AI and ChatGPT: Applications, challenges, and AI-human collaboration. *Journal of Information Technology Case and Application Research* 25, 277–304. Saatavissa: <https://doi.org/10.1080/15228053.2023.2233814>

Garyaev, A., Garyaev, N. (2023). Integration of artificial intelligence and video surveillance technology to monitor construction equipment. *E3S Web of Conf.* 410, 04002. Saatavissa: <https://doi.org/10.1051/e3sconf/202341004002>

Ghaisas, S., Singhal, A. (2024). Dealing with Data for RE: Mitigating Challenges while using NLP and Generative AI. <https://doi.org/10.48550/arXiv.2402.16977>

Gokhale, P., Bhat, O., Bhat, S. (2018). Introduction to IOT 5, 41–44. Saatavissa: <https://doi.org/10.17148/IARJSET.2018.517>

Hussain, R., Sabir, A., Lee, D.-Y., Zaidi, S.F.A., Pedro, A., Abbas, M.S., Park, C. (2024). Conversational AI-based VR system to improve construction safety training of migrant workers. *Automation in Construction* 160, 105315. Saatavissa: <https://doi.org/10.1016/j.autcon.2024.105315>

Jarota, M. (2023). Artificial intelligence in the work process. A reflection on the proposed European Union regulations on artificial intelligence from an occupational health and safety perspective. *Computer Law & Security Review* 49, 105825. Saatavissa: <https://doi.org/10.1016/j.clsr.2023.105825>

Koklonis, K., Sarafidis, M., Vastardi, M., Koutsouris, D. (2021). Utilization of Machine Learning in Supporting Occupational Safety and Health Decisions in Hospital Workplace. *Eng. Technol. Appl. Sci. Res.* 11, 7262–7272. Saatavissa: <https://doi.org/10.48084/etasr.4205>

Lakshmana, K., Kaluri, R., Gundluru, N., Alzamil, Z.S., Rajput, D.S., Khan, A.A., Haq, M.A., Alhussen, A. (2022). A Review on Deep Learning Techniques for IoT Data. *Electronics* 11, 1604. Saatavissa: <https://doi.org/10.3390/electronics11101604>

LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>

Li, Z., Ning, H. (2023). Autonomous GIS: the next-generation AI-powered GIS. *International Journal of Digital Earth* 16, 4668–4686. Saatavissa: <https://doi.org/10.1080/17538947.2023.2278895>

Ljubić, M., Raković, B., Dimitrov, L., Garvanov, I. (2016). Training of workers as an important safety measure for risk management, in: 2016 19th International Symposium on Electrical Apparatus and Technologies (SIELA). Presented at the 2016 19th International Symposium on Electrical Apparatus and Technologies (SIELA). Saatavissa: <https://doi.org/10.1109/SIELA.2016.7543022>

Madakam, S., Ramaswamy, R., Tripathi, S. (2015). Internet of Things (IoT): A Literature Review. *Journal of Computer and Communications* 3, 164–173. Saatavissa: <https://doi.org/10.4236/jcc.2015.35021>

Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., Corchado, J.M. (2021). Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors* 21, 4652. Saatavissa: <https://doi.org/10.3390/s21144652>

Molas, G., Nowak, E. (2021). Advances in Emerging Memory Technologies: From Data Storage to Artificial Intelligence. *Applied Sciences* 11, 11254. Saatavissa: <https://doi.org/10.3390/app112311254>

Moragane, H.P.M.N.L.B., Perera, B.A.K.S., Palihakkara, A.D., Ekanayake, B. (2022). Application of computer vision for construction progress monitoring: a qualitative investigation. *Construction Innovation* 24, 446–469. Saatavissa: <https://doi.org/10.1108/CI-05-2022-0130>

Mungoli, N. (2023). Advancements in Deep Learning: A Comprehensive Study of the Latest Trends and Techniques in Machine Learning. *International Journal of Advanced Engineering Technologies and Innovations* 1, 43–64. Saatavissa: <https://doi.org/10.765656/e690z688>

Okudan, O., Budayan, C., Dikmen, I. (2021). A knowledge-based risk management tool for construction projects using case-based reasoning. *Expert Systems with Applications* 173, 114776. Saatavissa: <https://doi.org/10.1016/j.eswa.2021.114776>

Rakennusala. Työsuojelu. Verkkosivu. Saatavissa (Viitattu 18.2.2024): <https://tyosuojelu.fi/tyoolot/rakennusala>

Ricketts, J., Barry, D., Guo, W., Pelham, J. (2023). A Scoping Literature Review of Natural Language Processing Application to Safety Occurrence Reports. *Safety* 9, 22. Saatavissa: <https://doi.org/10.3390/safety9020022>

Sarkar, S., Vinay, S., Raj, R., Maiti, J., Mitra, P. (2019). Application of optimized machine learning techniques for prediction of occupational accidents. *Computers & Operations Research* 106, 210–224. Saatavissa: <https://doi.org/10.1016/j.cor.2018.02.021>

Shanti, M.Z., Cho, C.-S., de Soto, B.G., Byon, Y.-J., Yeun, C.Y., Kim, T.Y. (2022). Real-time monitoring of work-at-height safety hazards in construction sites using drones and deep learning. *Journal of Safety Research* 83, 364–370. Saatavissa: <https://doi.org/10.1016/j.jsr.2022.09.011>

Shuford, J., Islam, M.M. (2024). Exploring the Latest Trends in Artificial Intelligence Technology: A Comprehensive Review. *Journal of Artificial Intelligence General science (JAIGS)* ISSN:3006-4023 2. Saatavissa: <https://doi.org/10.60087/jaigs.v2i1.p13>

Tikku-tilastosovellus. (2023). Tapaturmavakuutuskeskus. Saatavissa (Viitattu 14.2.2024): <https://www.tvk.fi/tilastot/tilastosovellus-tikku/>

Tixier, A.J.-P., Hallowell, M.R., Rajagopalan, B., Bowman, D. (2016). Application of machine learning to construction injury prediction. *Automation in Construction* 69, 102–114. Saatavissa: <https://doi.org/10.1016/j.autcon.2016.05.016>

Torro, O. (2024). Tekoälyn hyödyntäminen kiinteistö- ja rakennusalalla. Tampereen yliopisto. <https://urn.fi/URN:ISBN:978-952-03-3451-2>

Totschnig, W. (2020). Fully Autonomous AI. *Sci Eng Ethics* 26, 2473–2485. Saatavissa: <https://doi.org/10.1007/s11948-020-00243-z>

TR- mittaus. Työsuojelu. Verkkosivu. Saatavissa (Viitattu 18.2.2024): <https://tyosuojelu.fi/tyosuojelu-tyopaikalla/tyoolosuohdemittarit/tr-mittari->

Tufail, S., Riggs, H., Tariq, M., Sarwat, A.I. (2023). Advancements and Challenges in Machine Learning: A Comprehensive Review of Models, Libraries, Applications, and Algorithms. *Electronics* 12, 1789. Saatavissa: <https://doi.org/10.3390/electronics12081789>

Työturvallisuuskeskus. Rakennusala. Verkkosivu. Saatavissa (Viitattu 18.2.2024): <https://ttk.fi/tyoturvaluisuus/toimialakohtaista-tietoa/rakennusala/>

Työturvallisuuskeskus. Työturvallisuuskortti – työturvallisuus yhteisellä työpaikalla. Saatavissa (Viitattu 13.2.2024): <https://tyoturvaluusuuskortti.fi/>

Valtioneuvosto. Asetus rakennustyön turvallisuudesta 26.3.2009/205. Saatavissa (Viitattu 18.2.2024): <https://www.finlex.fi/fi/laki/alkup/2009/20090205>

Van Damme, S., Vega, M.T., De Turck, F. (2022). Machine Learning Based Content-Agnostic Viewport Prediction for 360-Degree Video. *ACM Trans. Multimedia Comput. Commun. Appl.* 18, 50:1-50:24. Saatavissa: <https://doi.org/10.1145/3474833>

Voulodimos, A., Doulamis, N., Doulamis, A., Protopapadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience* 2018, e7068349. Saatavissa: <https://doi.org/10.1155/2018/7068349>

Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., Parmar, M. (2024). A review of convolutional neural networks in computer vision. Saatavissa: <https://doi.org/10.1007/s10462-024-10721-6>