

# Koneoppimismenetelmien hyödyntäminen IoT-datan poikkeavien arvojen havaitsemiseen

TURUN YLIOPISTO  
Tietotekniikan laitos  
LuK-tutkielma  
Tietojenkäsittelytiede  
Toukokuu 2024  
Akseli Virtanen

TURUN YLIOPISTO  
Tietotekniikan laitos

AKSELI VIRTANEN: Koneoppimismenetelmien hyödyntäminen IoT-datan poikkeavien arvojen havaitsemiseen

LuK-tutkielma, 26 s.  
Tietojenkäsittelytiede  
Toukokuu 2024

---

IoT-laitteiden yleistymisen myötä myös niiden tuottama data on moninkertaistunut. Jotta dataa voidaan hyödyntää, tulee sen tulkitsemisen olla helppoa ja tehokasta. Yksi datan tulkintaan vaikuttavista ongelmista on siinä ilmenevät poikkeavat arvot. Poikkeava arvo on muista havainnoista selkeästi eroava havainto. Tämä ongelma ilmenee etenkin IoT-dataa analysoitaessa, sillä IoT-verkon eri sensorit ovat alttiita monenlaisille häiriöille, jonka seurauksena syntyy poikkeavia arvoja. Datamäärän kasvun seurauksena perinteiset menetelmät eivät ole riittävän tehokas tapa havaita poikkeavia arvoja. Tästä syystä on kehitetty erilaisia koneoppimismenetelmiä poikkeavien arvojen nopeampaan ja tarkempaan havaitsemiseen.

Tutkielma toteutettiin kirjallisuuskatsauksena ja siinä käsitellään koneoppimismenetelmien hyödyntämistä poikkeavien arvojen havaitsemisessa. Tutkielmassa tarkastellaan eri käyttökohteita ja niissä käytettyjä menetelmiä. Lisäksi pyrittiin löytämään syitä käytettyjen menetelmien valintaan.

Eri koneoppimismenetelmillä on kaikilla heikkouksia ja vahvuuksia. Koneoppimismenetelmän valintaan vaikuttaa paljon sen käyttökohde. IoT-laitteet ovat yleistyneet etenkin terveyden ja lääketieteen, teollisuuden ja älykotien ja -kaupunkien yhteydessä. Analysoitavan datan tulee olla hyvänlaatuista, joten mahdolliset virheelliset arvot ja viat tulee tunnistaa aikaisin. Koneoppimismenetelmät parantavat suurten datamäärien analysoinnin tehokkuutta ja mahdollistavat monenlaisten eri datatyyppien poikkeavien arvojen löytämisen. Koneoppimismenetelmien hyödyntämisen etuna on poikkeavien arvojen ja niihin johtaneiden tapahtumien yhteyden tunnistaminen, sekä mahdollinen käytöksen pitkäaikaisen muutoksen havaitseminen ja uusien kaavojen havaitseminen.

Koneoppimismenetelmistä yleisimpiä poikkeavien arvojen havaitsemiseen ovat tukivektorikone ja K:n keskiarvon ryvästys. Eri menetelmien tehokkuuksia vertaillen tehtävästä riippuen oli paljon vaihtelua menetelmien toimivuudessa, mutta monia menetelmiä yhdistelevät hybridimallit toimivat parhaiten poikkeavuuksien havaitsemisessa. Menetelmien toimivuuteen vaikuttaa paljon käyttökohteen data.

Asiasanat: esineiden internet, poikkeava arvo, koneoppiminen

# Sisällys

<b>1</b>	<b>Johdanto</b>	<b>1</b>
<b>2</b>	<b>Poikkeavat arvot datassa</b>	<b>5</b>
2.1	Poikkeava arvo ja IoT . . . . .	6
2.2	Datan valmistelu . . . . .	9
<b>3</b>	<b>Koneoppimisen käyttö poikkeavien arvojen havaitsemiseen</b>	<b>11</b>
3.1	Käyttökohteet . . . . .	13
3.2	Yleisimpiä koneoppimismenetelmiä . . . . .	18
<b>4</b>	<b>Yhteenveto</b>	<b>25</b>

# 1 Johdanto

Viime vuosina laitteiden yhdistäminen verkkoon on yleistynyt, ja sen tuomia etuja on alettu hyödyntää yhteiskunnan eri osa-alueilla (Mosallam & Ahmed, 2023). Tätä laitteiden yhdistämistä kutsutaan nimellä *esineiden internet* (engl. Internet of Things, IoT). IoT koostuu useista toisiinsa yhdistetyistä laitteista ja sensoreista, jotka havaitsevat, keräävät, käsittelevät ja välittävät tietoa. Tätä verkkoa voi ajatella kytköksenä digitaalisen ja fyysisen maailman välillä. Erilaiset laitteet tuottavat eri muotoista dataa, jota voidaan hyödyntää muun muassa ihmisten tai laitteiden käytöksen seuraamiseen tai niiden toiminnan tehostamiseen. (Bzai ym., 2022; Jiang ym., 2020) IoT-verkkoon voi olla kytkettynä esimerkiksi jääkaappi, puhelin, ovikello, lämpömittari tai valvontakamera.

Voidakseen hyödyntää IoT:n tuottamaa dataa, tulee sitä keräävän tahon voida havaita datassa tapahtuvia muutoksia ja eroavaisuuksia. Saadakseen haluttuja tuloksia dataa analysoitaessa, tulee analysoitavan datan olla siistiä ja hyvänlaatuisia. Laadulla tarkoitetaan datan luotettavuutta, tarkkuutta ja yhtenäisyyttä. Datan siistimisellä voidaan viitata esimerkiksi normaalista poikkeavien arvojen poistamiseen datasta. Yleisesti poikkeavalla arvolla tarkoitetaan muista havainnoista selkeästi eroavaa havaintoa. Koko datan analysoinnin lisäksi voidaan myös keskittyä poikkeavien arvojen analysointiin ja tutkia muun muassa niiden syntyyn johtavia syitä ja niistä tehtäviä johtopäätöksiä. (Jiang ym., 2020; Zhou ym., 2017)

Dataa keräävät laitteet ja sensorit ovat alttiita kaikenlaiselle häiriölle ja saattavat sen seurauksena tuottaa poikkeavia arvoja. Näiden arvojen syntyyn vaikuttaa itse IoT-verkon sensorit ja niihin kohdistuvat ulkoiset vaikutteet. Esimerkki sensorin vaikutteesta on sensorin sisäinen vika, kuten pariston varauksen tyhjeneminen. Ulkoisia vaikutteita ovat esimerkiksi sääolot ja muut sensorin ympäristön muutokset. Tässä tutkielmassa ei tarkastella sensorien häirinnästä johtuvia vaikutteita ja niiden seurauksia. (Al-khatib ym., 2019; Bzai ym., 2022)

IoT-verkon tuottamat suuret datamäärät sisältävät paljon poikkeavia arvoja. Suurten datamäärien analysointi perinteisillä tilastollisilla menetelmillä on työlästä ja aikaa vievää. Täten viime aikoina on alettu tutkimaan erilaisten koneoppimismenetelmien hyödyntämistä poikkeavien arvojen havaitsemiseen. (Jan ym., 2019; Zhou ym., 2017) Koneoppiminen on tekoälyn osa-alue, jossa tutkitaan datan ja sen sisältämän tiedon yhteyttä. Koneoppiminen perustuu algoritmin kouluttamiseen esimerkkien perusteella sääntöjen sijaan. Tämä on analyysin kannalta paljon nopeampi ja tehokkaampi tapa tutkia dataa, ja se antaa uusia mahdollisuuksia datan tulkitsemiseen. Koneoppimisen hyödyntäminen mahdollistaa nopean ja tarkoituksenmukaisen analyysin laitteeseen tai järjestelmään syntyvistä muutoksista. (Dwivedi ym., 2021; Shah & Tiwari, 2018) Erilaisia koneoppimismenetelmiä on kuitenkin monia ja niiden tehokkuus ja käyttökohteet vaihtelevat. Täten onkin tärkeää valita oikea koneoppimisalgoritmi haluttuun tehtävään.

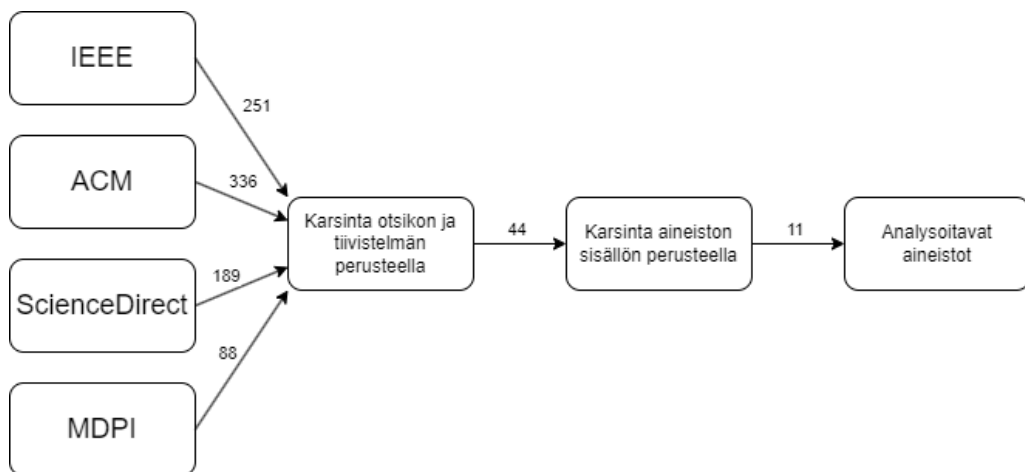
Tässä tutkielmassa vastataan seuraaviin tutkimuskysymyksiin:

**TK1:** Miten koneoppimismenetelmiä voidaan hyödyntää IoT-datan poikkeavien arvojen havaitsemiseen?

**TK2:** Mitkä koneoppimismenetelmät toimivat havaitsemisessa parhaiten?

Tutkielma on toteutettu kirjallisuuskatsauksena. Tutkielman tiedonhakua varten etsittiin aiheeseen liittyviä artikkeleita, kirjoja ja konferenssijulkaisuja eri tietolähteistä. Pääasiallisiksi tietokannoiksi muodostuivat IEEE Xplore, ACM Digital

Library ja ScienceDirect. Hakulauseeksi valikoitui ”(‘outlier detection’ OR ‘anomaly detection’) AND ‘machine learning’ AND (iot OR ‘internet of things’ OR internet-of-things)”. Saatuja julkaisuja karsittiin ensin otsikon ja tiivistelmän perusteella, minkä jälkeen jäljelle jääneet julkaisut luettiin kokonaisuudessaan ja valittiin niistä tutkimukseen parhaiten sopivat. Valittujen julkaisujen tuli vastata seuraaviin kriteereihin: englanniksi kirjoitettu tieteellinen julkaisu, JUFO-luokitus vähintään perustaso ja julkaisu käsittelee koneoppimisen hyödyntämistä IoT-verkkojen datassa ja poikkeavien arvojen havaitsemista. Näiden julkaisujen lopullinen määrä oli 11. Lisäksi mukaan valikoitui tutkielman taustaa ja kokonaisuuden ymmärtämistä tukevia julkaisuja. Alla kuvassa 1.1 esitettynä aineiston hakuprosessin eteneminen.




Kuva 1.1: Aineistojen karsintaprosessi. Numerot nuolien vieressä ilmaisevat kyseisessä vaiheessa ollutta julkaisujen määrää.

Tutkielma jakautuu neljään lukuun. Luvussa 2 käsitellään tutkielman kannalta oleellista taustatietoa poikkeavista arvoista ja datan valmistelusta. Luvussa 3 tarkastellaan, miten koneoppimismenetelmiä voidaan hyödyntää poikkeavien arvojen havaitsemiseen. Tässä luvussa käsitellään aiheeseen liittyvän kirjallisuuden mainitsemia käyttökohteita, koneoppimismenetelmien mahdollisia ongelmia poikkeavien arvojen havainnoissa IoT-datassa sekä esitellään yleisimmin käytettyjä koneoppimismenetelmiä. Luvun lopussa vertaillaan näiden menetelmien suorituskykyä kirjal-

lisuudessa tehtyjen testien pohjalta ja pohditaan niiden tehokkuutta. Luvussa 4 on yhteenveto tutkielmasta, vastataan tutkimuskysymyksiin sekä pohditaan mahdollista jatkotutkimusta.

## 2 Poikkeavat arvot datassa

Poikkeavalla arvolla (engl. outlier, anomaly) tarkoitetaan havaintoa, joka poikkeaa huomattavasti muista havainnoista (Hawkins, 1980). Kuvassa 2.1 on havainnointu poikkeavia arvoja datassa. Poikkeavan arvon tulee siis erottua datan normaalista käyttäytymisestä. Ne voidaan pisteyttää niiden poikkeavuuden mukaan tai luokitella binäärisesti. Tällä luokittelulla arvo joko on tai ei ole poikkeava muuhun dataan nähden. (Aggarwal, 2016, s. 2)



Kuva 2.1: Esimerkki poikkeavista arvoista datassa. Poikkeavat arvot on merkitty kuvaan punaisella.




## 2.1 Poikkeava arvo ja IoT

IoT:n yhteydessä laitteiden tuottama data on altis poikkeaville arvoille. IoT-verkon sensorit mittaavat jatkuvasti erilaisia havaintoja, kuten liikettä vaihtelevissa olosuhteissa, jolloin vikojen todennäköisyys on suuri ja normaalista eroavien tapahtumien ilmeneminen yleistä. Poikkeavien arvojen syntymiseen vaikuttaa eri tekijät (engl. factor). Poikkeavia arvoja tuottavia tekijöitä voidaan kutsua myös vaikutteiksi. Useimmiten tekijät jaetaan kolmeen kategoriaan: *vioista johtuvat* poikkeavat arvot (engl. fault outlier), *tapahtumista johtuvat* poikkeavat arvot (engl. event outlier) ja *häirinnästä johtuvat* poikkeavat arvot (engl. intrusion outlier) (Al-khatib ym., 2019). Lisäksi voidaan jakaa vikojen tekijät ympäristön ja sensoreiden sisäisistä vaikutuksista johtuviin tekijöihin (Jiang ym., 2020). Tässä tutkielmassa ei käsitellä häirinnän eli hyökkäyksen, häirinnän tai tunkeutumisen seurauksena syntyviä poikkeavia arvoja.

Kukin tekijä vaikuttaa poikkeavien arvojen syntymiseen eri tavalla. Ympäristön tekijöillä tarkoitetaan IoT:n sensorien ympäristön olosuhteista johtuvia poikkeavia arvoja joko itse mittauksessa tai sen tulosten lähettämisessä. Esimerkki tämänkaltaisesta vaikutuksesta on sensorin sijainnin ankarat sääolosuhteet. Sensorien sisäisillä vaikutuksilla tarkoitetaan sensorien mekaanisista ominaisuuksista johtuvia vikoja. Näitä ovat esimerkiksi sensorin pariston vähentynyt varaus tai häiriö yhteydessä (Ye ym., 2016). Tapahtumien seurauksena syntyvät vaikutukset ovat havaittavassa ympäristössä tapahtuneina äkillisinä muutoksina. Tämänkaltaisia muutoksia ovat esimerkiksi maanjäristys tai tulva. (Ayadi ym., 2017; Gaddam ym., 2020) Tämän tyyppiset vaikutukset poikkeavien arvojen syntyyn ovat tutkielman kannalta hyvin kiinnostavia niiden sisältämän piilotetun ja potentiaalisesti hyödyllisen tiedon vuoksi. Piilotetulla tiedolla tarkoitetaan datan sisältämää tietoa, joka ei näy suoraan sitä tarkastellessa. Sen havaitseminen voi vaatia esimerkiksi tilastollista analyysiä. (Al-khatib ym., 2019; Ayadi ym., 2017)

Poikkeavat arvot voidaan luokitella koko datasta erottuviin ja paikallisiin arvoihin sekä koko datajoukossa että aika-akselilla tehdyn tarkastelun suhteen. Tätä on havainnoitu kuvassa 2.2. Koko datasta erottuvat poikkeavat arvot voidaan huomata kaikkia tietopisteitä tarkastellessa. Paikalliset poikkeavuudet ilmenevät tarkastelemalla kyseisen pisteen lähimpien naapureiden eli sen läheisten pisteiden muodostaman joukon pisteiden eroavaisuuksia. (Ayadi ym., 2017)



Kuva 2.2: Esimerkki paikallisesta ja koko datasta erottuvasta poikkeavasta arvosta. Paikalliset poikkeavat arvot on merkitty kuvaan vihreällä, koko datasta erottuvat punaisella.

Edellä esitetyn lisäksi poikkeavat arvot voidaan luokitella kolmeen eri alaryhmään niiden tyyppin mukaan. Poikkeavan arvon tyyppi voi olla *pistepoikkeama*, *tilannesidonnainen poikkeama* tai *yhteispoikkeama* (Fahim & Sillitti, 2019; Wu ym., 2022). Pistepoikkeama on havainto, jonka arvo eroaa selkeästi muista datan arvoista. Se voi tapahtua täysin sattumalta eikä sille välttämättä ole selkeää syytä. Se voi joutua muun muassa viallisen sensorin antamasta lukemasta. Pistepoikkeama on koko datasta erottuva poikkeava arvo. Tilannesidonnainen poikkeama kuvaa poikkeavaa

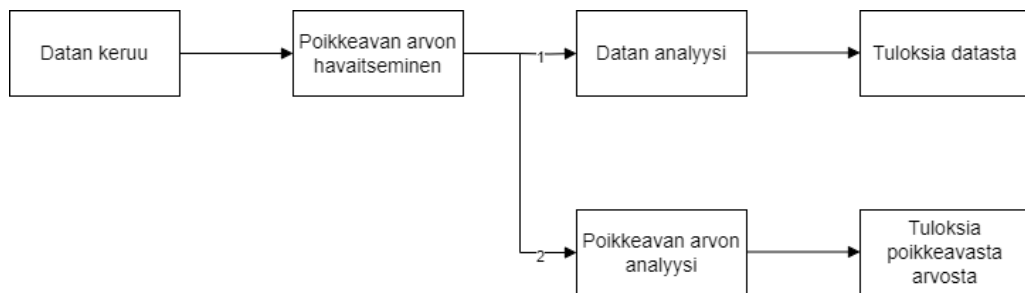
tapahtumaa tietyssä yhteydessä. Tilanteesta riippuen arvo voi olla joko normaali tai poikkeava. Yleisimpiä asiayhteyksiä arvoille on aika ja paikka. Esimerkiksi arkipäivänä suuri määrä verkkoliikennettä yrityksen toimistossa on normaalia, mutta suuri liikenteen määrä yrityksen verkossa yöllä viikonloppuna voi viitata vikaan. Tilannesidonnaisesta poikkeamasta johtuvia poikkeavia arvoja analysoidessa tulee kiinnittää huomiota eri muuttujiin, verrata datan arvoja eri aikaväleiltä sekä kiinnittää huomiota mahdollisiin toistuviin ilmiöihin. Yhteispoikkeama kuvaa poikkeavaa tapahtumaa tapauksessa, jossa yksittäinen arvo ei välttämättä poikkea läheisistä arvoista huomattavasti, mutta lähesiten pisteiden ryhmiä tarkastelemalla voidaan löytää joukko muista poikkeavia arvoja. Tällainen tilanne on esimerkiksi sykemitarin hetkellinen joukko korkeampia lukemia. Se voi johtua liikuntasuorituksesta, kun taas jatkuvat ja peräkkäiset korkeat joukot voivat viitata sydämen vajaatoimintaan. (Fahim & Sillitti, 2019; Wu ym., 2022) Tilannesidonnaiset poikkeamat ja yhteispoikkeamat ovat paikallisia poikkeamia.

Poikkeavat arvot datassa vaikuttavat siihen monella tavalla. Niiden seurauksena laitteen tehokkuus voi kärsiä ja laite voi mahdollisesti tuottaa virheellistä tai epävarmaa dataa. Tämä voi pahimmassa tapauksessa aiheuttaa ongelmia laitteen toiminnassa (Gaddam ym., 2020). Poikkeavat arvot datassa vaikuttavat datan käsittelyyn ja jatkokäyttöön. IoT-verkot koostuvat useista eri tasoista, joilla on kullakin oma tehtävänsä. *Laitetasolla* on fyysiset asiat, kuten sensorit ja muut dataa tuottavat laitteet. *Porttitasolla* tapahtuu datan esikäsittely. *Hallintatasolla* dataa analysoidaan ja siitä voidaan tehdä mallinnuksia. Lopuksi *pilvipalveluiden tasolla* voidaan tehdä kokonaisvaltaisia analyysejä datasta. (Huang & Wu, 2022) Täten porttitasolla data tulee siistiä ja mahdolliset poikkeavuudet havaita ja ottaa huomioon ennen ylempiin tasoihin ja analyysiin siirtymistä. Poikkeavuudet voi joko suodattaa pois datasta tai ne voidaan luokitella myöhempää tarkastelua varten (Mosallam & Ahmed, 2023).

Poikkeavien arvojen havaitsemiseen on useita eri menetelmiä, jotka luokitellaan usein niiden yleisten piirteiden mukaan. Arvoja voi havaita muun muassa tilastollisilla menetelmillä tai koneoppimisalgoritmien avulla *luokittelua* ja *ryvästystä* hyödyntäen. On myös mahdollista yhdistellä eri menetelmiä ja käyttää näistä muodostettua hybridimallia. (Ayadi ym., 2017)

## 2.2 Datan valmistelu

Poikkeavia arvoja tarkastellessa tulee päättää halutaanko poikkeavat arvot siistiä pois datasta analyysia varten, vai halutaanko poikkeavat arvot ottaa erikseen tarkasteluun. Tätä on havainnointu kuvassa 2.3. Kuvassa poikkeavan arvon havaitsemisen jälkeen on kaksi eri polkua, joihin analyysissä voidaan edetä. Poikkeavat arvot voidaan poistaa datasta, minkä jälkeen voidaan edetä analyysiin siistityllä datalla. Vaihtoehtoisesti voidaan keskittyä itse poikkeavien arvojen analysointiin ja tehdä tulkintoja muun muassa niiden syntymisestä ja vaikutuksista muuhun dataan.



Kuva 2.3: Analyysin eteneminen poikkeavien arvojen havaitsemisen jälkeen.

Kerätyn datan alkuperäisten tavoitteiden analyysin kannalta poikkeavat arvot tulee tunnistaa ja poistaa datasta. Tämä on kuvassa 2.3 polku 1. Poikkeavien arvojen poistaminen tulee tehdä ennen datan analyysiä, sillä datassa olevat virheet voivat hankaloittaa analyysien tekoa ja tuottaa vääränlaisia tulkintoja havainnoista. Poikkeavien arvojen tarpeeksi aikaisella havaitsemisella voidaan minimoida vahinko-

ja ja taloudellisia tappioita esimerkiksi teollisuudessa <sup>1</sup>. Ongelma ilmenee myös koneoppimisen yhteydessä, sillä virhellisiä arvoja sisältävän datan pohjalta koulutettu malli ei välttämättä toimi odotetulla tavalla. Datasta tulee tunnistaa ja tarvittaessa poistaa arvot, joissa kaksi eri otosta kuvaa samaa havaintoa. Lisäksi datassa olevat häiritsevät arvot (engl. noise), kuten puuttuvat tai poikkeavat arvot, tulee siistiä datasta pois. (Singhal ym., 2022; Zhou ym., 2017)

IoT-verkko kerää sensoreilla useita eri tyyppisiä dataa. Näitä tyyppisiä ovat muun muassa video ja ääni. Eri tyyppiset tulokset tulee tarpeen mukaan olla analysoitavissa ja vertailtavissa, joten datan tulee olla yhdenmuotoista. Myös datan diskreettisyys, eli mahdollisten arvojen rajallisuus tulee huomioida datan valmistelussa. (Zhou ym., 2017)

Poikkeavien arvojen havaitseminen ja erottaminen muusta datasta mahdollistaa arvojen tarkastelun ja tutkimisen. Tätä on kuvattu kuvassa 2.3 polulla 2. Tässä tapauksessa poikkeavat arvot ovat analyysin kannalta koko datan arvokkain osa. Poikkeavat arvot voivat sisältää paljon kiinnostavaa ja hyödyllistä tietoa. Etenkin tapahtumien seurauksena syntyneet poikkeavat arvot sisältävät IoT-laitteen toiminnan tai ympäristön muutoksen kannalta tärkeää tietoa, jonka tulkinta voi mahdollistaa esimerkiksi aikaisemman reagoinnin vikaan.

---

<sup>1</sup>BBC (2020), IoT-verkon hyödyntäminen vesivahinkojen nopeaan ja tarkkaan havaitsemiseen, url: <https://www.bbc.com/news/business-53274914> (viitattu 11.02.2024)

# 3 Koneoppimisen käyttö poikkeavien arvojen havaitsemiseen

Nykyään lähes jokainen ihminen ja laite on jatkuvasti kytketty verkkoon jollain tavalla. Esimerkkejä verkkoon yhdistetyistä laitteista ovat muun muassa puhelimet ja älykellot. Ne sisältävät monenlaisia sensoreita, kuten kameroita, gyroskooppeja ja sykemittareita. (Al-Dhief ym., 2020; Fahim & Sillitti, 2019) Kannettavien laitteiden lisäksi kehitystä IoT-laitteiden hyödyntämisessä on tapahtunut etenkin terveyden ja lääketieteen (engl. Internet of Medical Things, IoMT), teollisuuden (engl. Industrial Internet of Things, IIoT, Industry 4.0) ja älykotien ja äykaupunkien osa-alueilla.

IoT-verkon ja sen sensorien liittäminen eri elämän osiin on luonut tarpeen tehokkaalle tavalle siistiä dataa sen analysointia varten. Poikkeavien arvojen määrän kasvaessa vaaditaan uusia tekniikoita niiden havaitsemiseen ja syyn löytämiseen. Koneoppimismenetelmien hyödyntäminen mahdollistaa poikkeavien arvojen havaitsemisen nopeasti ja tarkasti. Eri käyttötarkoituksissa voidaan hyödyntää eri koneoppimismenetelmiä. Taulukossa 3.1 on esitetty kirjallisuuskatsaukseen valitun aineiston käsittelemät aiheet koneoppimisen hyödyntämisestä IoT-datan poikkeavien arvojen havaitsemiseen ja niissä käytetyt koneoppimismenetelmät. Julkaisuissa käsitellään eri käyttökohteita ja koneoppimismenetelmiä.

Taulukko 3.1: Aineistossa käsitellyt käyttökohteet ja koneoppimismenetelmät

	Käyttökohde			Koneoppimis- menetelmät
	IoMT	IIoT	Älykaupunki ja älykoti	
Al-Dhief ym. (2020)	X			GMM, SVM, DBSCAN
Bzai ym. (2022)	X	X	X	SVM, K-means, KNN
Dwivedi ym. (2021)	X			hybridi
Fahim ja Sillitti (2019)	X	X	X	SVM, PCA
Gultekin ja Aktas (2022)		X		Random forest, päättöspuu
Jiang ym. (2020)				SVM, DBSCAN, K-means, KNN, PCA, LOF
Shah ja Tiwari (2018)		X		GMM, regressio
Shahid ym. (2023)	X		X	K-means, LOF
Tang ym. (2019)			X	päättöspuu, regressio, hybridi
Ta-Shma ym. (2018)			X	K-means
Wu ym. (2022)		X		GNN

## 3.1 Käyttökohteet

*Terveyden ja lääketieteen osa-alueella* IoT-laitteiden hyödyntäminen voi tapahtua monella eri tasolla. IoT-laitteita voidaan hyödyntää esimerkiksi sairaalan aulassa, lääkärin vastaanotolla tai potilaan kodissa langattomien sensorien avulla. IoT mahdollistaa muun muassa seuraavia asioita terveyden ja lääketieteen osa-alueella: su-lava yhteydenpito potilaan, terveyskeskuksen ja lääkärin välillä, taudin tarkempi määrittäminen, lääketieteellisen hätätilanteen havaitseminen, kroonisten tautien havainnointi ja potilaan reaaliaikainen seuranta. Koneoppiminen voi auttaa potilaan hoi-don suunnittelussa ja hallinnassa, tietojen päivittämisessä sekä taudin etenemisen ennustamisessa. (Al-Dhief ym., 2020)

Potilaita ympäröivä sensoriverkosto mahdollistaa potilaan käytöksen lyhyt- ja pitkäaikaisen seurannan ja muutosten havainnoinnin. Jatkuvan seurannan lisäksi sensorit ovat myös potilaille mukavampi ja helpompi tapa antaa itsestään tietoa. Potilas voi kokea jatkuvan videokuvan epämiellyttäväksi, mutta liiketunnistin ei ehkä tunnu yhtä tunkeutavalta tavalla seurata liikettä. Myös esimerkiksi sykettä seuraava ranneke on paljon helpompi ja mukavampi käyttää kuin kehossa kiinni olevat anturit. IoT-laitteet voivat välittää tietoa ja havaita muutoksia silloinkin kun terveydenhuol-lon ammattilainen ei ole paikalla. Lisäksi koneoppimismenetelmiä hyödyntämällä voidaan tunnistaa esimerkiksi ottamatta jäänyt lääkeannos. Datan poikkeavuuksia havaitsemalla hoitaja voi seurata muutoksia ja arvioida niiden merkitystä. Koneop-piminen toimii hoitajan apurina poikkeavuuksien varhaisemmassa ja tarkemmassa havaitsemisessa. IoT-verkon keräämä data mahdollistaa potilaan käytöksessä tapah-tuvien muutosten vertailun muiden samassa tilanteessa olevien henkilöiden kanssa. Tätä hyödyntämällä voidaan tutkia mahdollisia syitä muutoksille. (Fahim & Sillitti, 2019; Shahid ym., 2023)

Ihmisten terveyttä tarkastellessa virheellisen tiedon ja mahdollisten muutosten tunnistaminen on hyvin tärkeää oikeanlaisen diagnoosin tekemistä varten. Jatkuvas-



ti liikkeessä olevat sensorit ja niiden altistuminen poikkeaville tilanteille synnyttää paljon poikkeavia arvoja. Useiden poikkeavien arvojen tarkka ja nopea havaitseminen vaatii tehokkaiden koneoppimismenetelmien hyödyntämistä. Koneoppimismenetelmät tallentavat tietoa ja kirjaavat ylös mahdollisia poikkeavia arvoja automaattisesti. Lisäksi helposti saatavilla oleva tieto ja tehokas tapa löytää poikkeavuuksia auttaa koulutuksessa ja tulevaisuuden kehityksessä. Koneoppimismenetelmien hyöty poikkeavien arvojen havaitsemisessa liittyy myös eri tyyppisten poikkeavien arvojen tehokkaampaan tunnistamiseen. Terveystieteiden ja lääketieteen osa-alueella poikkeavat arvot ovat usein tilannesidonnaisia tai yhteispoikkeamia niiden käyttökohteista johtuen. Tämä johtuu ihmisten vaikutuksesta sensorien havaitsemaan ympäristöön. Ihmisten toiminnan muutokseen on usein jokin syy ja yleinen teema eri käyttökohteiden välillä on muutoksen ja siihen johtaneen ihmisen toiminnan yhteyden löytäminen. Lääketieteelliset muutokset ovat usein kytkettynä johonkin tiettyyn tapahtumaan, jonka pohjalta voidaan tehdä päätelmiä tapahtuman ja poikkeavuuden yhteyksistä. Yhteispoikkeamia tunnistamalla voidaan huomata muutoksia potilaan käytöksessä pitkällä aikavälillä. Erilaiset hybridialgoritmit ja kehittyneemmät versiot koneoppimismenetelmistä parantavat poikkeavien arvojen havaitsemisen tarkkuutta ja sen seurauksena tuottavat tarkempia ja nopeampia tuloksia kerätyn datan analysoinnista. Lisäksi koneoppiminen mahdollistaa personoidun analyysin ja kustannusten vähentämisen. Kustannusten vähenemisen myötä yhä useamman on mahdollista saada parempaa ja tehokkaampaa hoitoa. (Al-Dhief ym., 2020; Dwivedi ym., 2021; Fahim & Sillitti, 2019)

*Teollisuuden osa-alueella* koneoppimismenetelmien edut ilmenevät etenkin jatkuvan datavirran analysoinnissa. Verkon kautta toisiinsa kytketyt laitteet ja sensorit mahdollistavat datan keräämisen ja analysoinnin sekä laitteiden automaattisen hallinnan kerätyn tiedon pohjalta. Suuri määrä sensoreita välittää jatkuvasti paljon tietoa, ja sen reaaliaikainen analysointi vaatii tehokasta laskentaa. Tähän teh-

tävään koneoppimisen mahdollistama suuren mittakaavan analysointi sopii täydellisesti. Kerätyn datan nopea analyysi ja poikkeavuuksien tunnistaminen mahdollistaa tarpeeksi aikaisen reagoinnin mahdollisiin vikoihin. Teollisuudessa laitteiden viat ilmenevät usein pistepoikkeamina. Niiden tunnistaminen on hyvin nopeaa tehokkaiden koneoppimismenetelmien avulla. Koneoppimisen tehostama datan siistiminen pitää datan laadukkaana ja mahdollistaa sen jatkuvan analyysin. Laadukkaan datan avulla kerätty tieto on tarkempaa ja järjestelmiä voidaan huoltaa ja kehittää paremmin. Poikkeavien arvojen varhaisempi havaitseminen parantaa vikojen ennakointia, minkä myötä voidaan vähentää järjestelmien seisokkiaikaa ja pidentää osien käyttöikä parantaen tehtaan tuottavuutta. (Gultekin & Aktas, 2022; Wu ym., 2022)

Teollisuudessa sensorit on sijoitettu monenlaisiin ympäristöihin ja niihin kohdistuu useita eri vaikutteita. Erilaiset koneet ovat jatkuvassa käytössä, minkä seurauksen vikojen syntyminen on yleistä. Tämä on yksi erityisesti teollisuuden IoT-verkoissa ilmenevä piirre sensorien nopeammasta kulumisesta johtuen. Poikkeavia arvoja voi syntyä esimerkiksi mekaanisen vian, yhteysvian, rankkojen sääolojen, virrassa olevan häiriön tai sähkömagneettisen häiriön seurauksena. Tästä johtuen vikojen nopea havaitseminen on kriittistä tehtaan toiminnan, tehokkuuden ja tuottavuuden kannalta. Esimerkiksi ympäri vuorokauden toimivan linjaston rikkoutuminen voi johtaa pitkävaikutteisiin viivästyksiin tuotannossa ja tilausten valmistumisessa. (Bzai ym., 2022)

Koneoppimiseen perustuva poikkeavien arvojen havaitseminen tunnistaa poikkeavuudet järjestelmän toiminnassa ja ilmoittaa niistä järjestelmän valvojalle. Täten valvojan ei tarvitse jatkuvasti seurata järjestelmän toimintaa, vaan hänen täytyy vain seurata ilmeneviä ongelmia ja tehdä päätöksiä niiden suhteen. Teollisuuden laitteilla on usein ennalta määritettyjä vaatimuksia niiden toiminnalle, jolloin algoritmin on helppo tunnistaa muutos toiminnassa. Muutoksen syynä voi olla esimerkiksi vika tai laitteen kuluminen. Vian syy saadaan selville analysoimalla laitteen sen-

sorien tuottamaa dataa ja tunnistamalla missä vaiheessa poikkeavia arvoja syntyy. (Shah & Tiwari, 2018)

Koneoppimisen hyödyntäminen on tärkeässä roolissa *älykotien ja -kaupunkien* mahdollistamisessa. Älykodilla- ja kaupungilla tarkoitetaan IoT-verkon tukemaa ympäristöä, jossa lähes kaikki on kytketty verkkoon, joka jakaa ja hyödyntää kerättyä tietoa. Älykodissa esimerkiksi valaistus, lämmitys ja kodinkoneet ovat kytkettynä verkkoon, jonka kautta niitä voidaan hallita. Älykaupunkissa muun muassa liikenne, jätehuolto ja sähköntuotanto ovat kytkettynä IoT-verkkoon. IoT-verkon avulla voidaan optimoida käytettyjä resursseja ja ratkaista ongelmatilanteita. Älykodi- ja kaupungit ovat jatkuvassa vuorovaikutuksessa ihmisten kanssa, jolloin poikkeavien arvojen syntyminen on hyvin todennäköistä. IoT-verkon tuoma mukavuus ja turvallisuus perustuu kerätyn datan tehokkaaseen käyttöön. Ihmisten kanssa tekemisissä olevat laitteet ovat alttiita poikkeaville arvoille ihmisten käytöksen seurauksena ihmisten toiminnan ennalta-arvaamattomuudesta johtuen. Täten tehokas poikkeavien arvojen tunnistaminen on datan käytettävyyden kannalta pakollista. (Bzai ym., 2022; Tang ym., 2019)

Sensoriverkoston mahdollistama älykaupunki voi hyödyntää koneoppimismenetelmiä esimerkiksi julkisen liikenteen ruuhkien havaitsemiseen, veden puhtauden ja ilman laadun tarkkailuun, vihannesten tuoreuden tarkkailuun tai yleisen ihmisten elämänlaadun seurantaan. Poikkeavien arvojen havaitsemista voidaan myös käyttää muun muassa vakuutuskorvausten päättämisestä autokolarin jälkeen. Datasta kerätyillä poikkeavilla arvoilla voidaan havaita, onko kuski mahdollisesti ajanut normaalia poikkeavalla tai vaarallisella tavalla. Älykodin IoT-verkon tukena voidaan hyödyntää koneoppimista esimerkiksi pihan automaattisen valaistuksen toiminnan taakamisessa. Valaistuksen liiketunnistimen sensorin linssiin päätyneet likat voivat peittää osan havaitsemisalueesta. Koneoppimisalgoritmi tunnistaa jatkuvan häiriön senso-

rissa ja ilmoittaa asukkaalle mahdollisesta ongelmasta liiketunnistimessa. (Bzai ym., 2022; Ta-Shma ym., 2018)

Koneoppimismenetelmien hyödyntämisessä poikkeavien arvojen havaitsemiseen IoT-datassa seuraa koneoppimisesta johtuvia sille ominaisia ongelmia. IoT-verkon sensorien keräämä data voi olla peräisin usealta eri henkilöltä. Esimerkiksi älykodin sensorit voivat havainnoida vanhemman ja nuoremman lapsen yökäyttäytymistä, jolloin yksittäisten henkilöiden erottaminen on olennaista mahdollisten poikkeavuuden huomaamiseksi. Täten yksittäisten henkilöiden käytösprofiilin luomiseen ja päivittämiseen tarvitaan erillisiä menetelmiä, jolloin koneoppimisjärjestelmän hyödyntäminen monimutkaistuu. Lisäksi poikkeavien arvojen tunnistamiseen vaikuttaa laitteiden vaihteleva käyttö. Esimerkiksi ruokaa valmistetaan useita kertoja viikossa, mutta siivous voi tapahtua vain kerran. Koneoppimismenetelmien toimivan hyödyntämisen kannalta on siis tärkeää ymmärtää mahdolliset rajoitteet ja muuttujat havainnoitavassa ympäristössä, minkä seurauksena voidaan joutua tekemään valmis-televaa työtä ennen menetelmien käyttöönottoa. (Fahim & Sillitti, 2019)

Etenkin teollisuuden ja terveyden ja lääketieteen aloilla data voi olla muodoltaan hyvinkin monimutkaista. Tämänkaltaisessa tapauksessa koneoppimismenetelmän kouluttaminen vie paljon aikaa ja resursseja. Kouluttaminen täytyy tehdä hyvin, jotta koneoppimisalgoritmi voi toimia halutulla tavalla. Havaittujen poikkeavien arvojen pohjalta tehty analyysi ei aina vastaa suoraan kysymykseen niiden synnystä, vaan vian ydinaiheuttajan tunnistamiseen voidaan vaatia ylimääräistä analyysiä. Lisäksi koneoppimismenetelmien avulla havaitut poikkeavuudet ja niistä tehdyt analyysit tulee ilmaista helposti tulkittavalla tavalla. Vaikka itse algoritmin toiminta olisikin hyvin monimutkaista, tulee poikkeavuudet pystyä näyttämään ja perustelemaan selkeästi ja ytimekkäästi, jotta niiden pohjalta tehdyt muutokset ja korjaukset ovat oikeanlaiset. (Fahim & Sillitti, 2019)

Koneoppismenetelmien hyödyntämiseen liittyy myös teknisiä haasteita. Nämä haasteet liittyvät muun muassa verkkoyhteyden laatuun ja saatavuuteen sekä laskennallisen tehon tarpeeseen. Lisäksi koneoppimismenetelmien tehokas ja menestyksenkäs hyödyntäminen eri IoT-verkkojen datan poikkeavien arvojen tunnistamisessa ja datan siistimisessä vaatii ihmiskunnan luottoa koneoppimismenetelmien tekemisiin päätöksiin ja valmiutta hyväksyä se osana järjestelmää ja päivittäistä toimintaa. (Bzai ym., 2022)

## 3.2 Yleisimpiä koneoppimismenetelmiä


Poikkeavien arvojen havaitsemiseen hyödynnettävät koneoppimismenetelmät voidaan jakaa muutamalla eri tavalla. Ensimmäinen tapa on jakaa eri menetelmät hyvin karkeasti ohjattuun ja ohjaamattomaan oppimiseen perustuviin menetelmiin. Lisäksi on mahdollista hyödyntää ohjatun ja ohjaamattoman oppimisen yhdistelmästä muodostettuja hybridialgoritmeja. Hybridimalleissa yhtenä alakategoriana on koosteoppiminen (engl. ensemble learning), jossa hyödynnetään useita eri algoritmeja muun muassa tehokkuuden ja tarkkuuden parantamiseksi (Al-khatib ym., 2019; Dwivedi ym., 2020a, 2021; Jiang ym., 2020).

Julkaisuissa yleisimmin hyödynnetyiksi koneoppimismenetelmiksi osoittautuivat tukivektorikone (engl. support vector machine, SVM), K:n keskiarvon ryvästys (K-means), paikallisen poikkeaman tekijä (engl. local outlier factor, LOF), kohinaa sisältävien sovellusten tiheyteen perustuva spatiaalinen ryvästys (engl. Density-based spatial clustering of applications with noise, DBSCAN), Gaussin sekoitemalli (Gaussian Mixture Model, GMM) ja erilaiset hybridialgoritmit. Hybridimallien käytössä on paljon vaihtelevuutta ja eri algoritmeja sovelletaan eri tavoin. Julkaisuissa muodostettiin erilaisia hybridialgoritmeja tekemällä erilaisia yhdistelmiä. Yleisimmin julkaisuissa käytetyt tukivektorikone ja K:n keskiarvon ryvästys esiintyivät kirjallisuus-

katsauksen julkaisuissa 5 kertaa. Muut tarkasteluun otetut koneoppimismenetelmät esiintyivät 3 kertaa.

Kukin algoritmi tunnistaa poikkeavia arvoja omalla tavallaan. Luokitteluun perustuvat algoritmit vaativat toimiakseen etukäteen leimattua dataa, johon koneoppimisalgoritmi vertaa sensorien keräämien havaintojen arvoja tunnistaa mahdolisii poikkeavuuksia. Tukivektorikoneet perustuvat datan pisteavaruuteen luotuun hypertasoon. Tukivektorit ovat hypertason lähellä olevien pisteiden etäisyyksiä tasosta. Hypertason ja tukivektorien välistä etäisyyttä kutsutaan marginaaliksi. Tätä havainnoitu kuvassa 3.1 Suurimman marginaalin antava hypertaso on datan luokitteluun parhaiten sopiva. Tukivektorimenetelmän yleisyys johtuu todennäköisesti sen joustavuudesta ja helppoudesta käyttää erilaisissa tehtävissä ja datajoukoissa. Tukivektorikoneen toimintaperiaate on hyvin yksinkertainen ja koneoppimista hyödyntämällä voidaan käyttää useita tukivektorikoneita samassa datajoukossa poikkeavien arvojen havaitsemisen tehostamiseksi. Tukivektorikoneen käyttö on yleistä esimerkiksi terveyden ja lääketieteen osa-alueella etenkin sen joustavuuden vuoksi. Terveyden alalla IoT-verkko kerää monentyypistä dataa, jonka poikkeavien arvojen tunnistamiseen tukivektorikone sopii hyvin. (Dwivedi ym., 2020b; Jiang ym., 2020)

K:n keskiarvon ryvästys perustuu datan datapisteiden ryhmittelyyn joukoiksi. Näitä joukkoja kuvataan yhdellä pisteellä, joka on niiden keskiarvo. Näiden pisteiden pohjalta voidaan luokitella kaikkien datapisteiden samankaltaisuus keskiarvopisteiden perusteella. Muiden pisteiden luokittelun jälkeen ryhmän keskiarvopiste ei välttämättä enää ole ryhmän keskellä, joten prosessi toistetaan, kunnes keskiarvopiste ei enää liiku. Ryhmien määrä tulee määritellä etukäteen. Ryhmien määrällä on suuri merkitys menetelmän tehokkuuden ja toimivuuden kannalta, sillä liian suuri tai pieni määrä ryhmiä jakaa pisteet ryhmiin väärin. Datan arvojen samankaltaisuutta arvioidaan mittaamalla niiden etäisyyttä. Muodostettujen joukkojen sisällä arvojen samankaltaisuus on suurta, mutta joukkojen välillä pientä. Tämän



Kuva 3.1: Parhaimman hypertason tunnistaminen tukivektorikoneen avulla luokittelua varten. Kuvassa on 3 hypertasoa ( $H_1$ - $H_3$ ). Hypetasoista  $H_3$  ei erota luokkia erilleen.  $H_1$  ja  $H_2$  hypertasojen välillä  $H_2$  tason marginaali on suurempi. Kuva lisensioitu CC0 -lisenssillä (<https://creativecommons.org/publicdomain/zero/1.0/>).

menetelmän avulla havaitut poikkeavat arvot eivät joko sovi yhteenkään ryhmään etäisyyksiensä puolesta tai ne kuuluvat ryhmään, mutta koko ryhmä eroaa muista huomattavasti etäisyytensä puolesta. K:n keskiarvon ryvästykseen yleisyys johtuu todennäköisesti sen yksinkertaisuudesta ja skaalautuvuudesta. K:n keskiarvon ryvästys sopii hyvin suurienkin datamäärien tarkasteluun. Tästä johtuen sen käyttö on yleistä älykotien ja älykaupunkien poikkeavien arvojen havaitsemisessa. Näissä käyttökohteissa IoT-verkon sensorien määrä on hyvin suuri ja dataa kerätään paljon. (Jiang ym., 2020)

LOF-menetelmä perustuu datajoukon arvoille annettaviin tiheyteen perustuviin asteisiin. Tämä aste kuvastaa arvon poikkeavuutta sen muihin läheisiin arvoihin verrattuna. Tiheydellä tarkoitetaan lähimpien arvojen etäisyyttä tutkitusta arvosta. Lähekkäin olevien arvojen etäisyyksien pohjalta voidaan muodostaa niille tiheys,

ja samankaltaiset tiheydet kuvaavat yhtenäisiä alueita. Arvot, joiden asteet ovat suuret, eli toisin sanoen niiden tiheys poikkeaa huomattavasti niiden läheisistä arvoista, voidaan tulkita poikkeaviksi arvoiksi. Artikkelissaan Shahid ym. (2023) käyttivät LOF-menetelmää sen kaavojen tunnistamisen hyötyjen vuoksi. Heidän datansa seuraa normaaleja kaavoja, jolloin poikkavat arvot löytyvät normaalien kaavojen ulkopuolelta. LOF-menetelmä soveltuu myös pitkäaikaisten kaavojen tunnistamiseen. (Al-khatib ym., 2019; Jiang ym., 2020)

DBSCAN-menetelmä on monella tapaa samanlainen kuin  $K$ :n keskiarvon ryvästys. Erona menetelmien välillä on niiden lähestymistapa ryhmien määrittelyyn. DBSCAN määrittää ryhmäksi suurimmat joukot toisiaan lähellä olevia arvoja etukäteen annetun naapurien määrän sijaan. DBSCAN-menetelmä pystyy luomaan mielelläisen muotoisia ryhmiä. Poikkeavat arvot ovat ryhmien ulkopuolelle jääviä arvoja. DBSCAN toimii tehokkaasti suurillakin datamäärillä, mutta se ei sovellu suurilukuisen aineiston datapisteiden tulkintaan, sillä sen tiheyttä on haastavampi määrittää. Lisäksi suuret vaihtelevuudet ryhmien koossa ja etäisyyksissä heikentävät algoritmin toimintaa. DBSCAN-menetelmän tarkemmat vaatimukset ovat sen suosion kannalta hyvä ja huono asia. Hyvää ja sen suosiota kasvattavaa on sen omatoimisuus verrattuna esimerkiksi samankaltaiseen  $K$ :n keskiarvon ryvästykseen. Menetelmän itse määrittelemä ryhmien määrä antaa todennäköisesti tarkempia ja parempia tuloksia poikkeavien arvojen havaitsemisessa. Huono asia omatoimisuudessa on menetelmän heikko toimintakyky sen vaatimusten puuttuessa. Jos IoT-verkon keräämän datan ryhmien koot ja etäisyydet pysyvät enimmäkseen samanlaisina, voi DBSCAN-menetelmä olla muita parempi vaihtoehto. Tämän vuoksi Al-Dhief ym., 2020 hyödynsivät sitä äänen tunnistamiseen. (Al-khatib ym., 2019; Ester ym., 1996; Jiang ym., 2020)

Gaussin sekoitemalli on pitkälti samanlainen, kuin  $K$ :n keskiarvon ryvästys. Ero on Gaussin sekoitemallin mahdollisuus sisällyttää yksittäinen arvo useaan eri



ryhmään. Gaussin sekoitemallissa ryhminä toimivat Gaussin jakaumat eli normaali-jakaumat. Gaussin sekoitemallin kanssa voidaan hyödyntää EM-algoritmia (engl. expectation-maximization algorithm) menetelmän sovittamiseksi. EM-algoritmi optimoi ryvästeet sopivan kokoisiksi. Gaussin sekoitemalli voi toimia paremmin sekalaisen datan poikkeavien arvojen ja uusien tapahtumien tunnistamisessa sen joustavamman luokittelun vuoksi. (Fahim & Sillitti, 2019; Shah & Tiwari, 2018)

Suurimmalla osalla menetelmistä on niiden toimivuuden ja tehokkuuden kannalta tietynlaisia rajoitteita, kuten ryhmien määrä tai koko. Tästä johtuen on kehitetty useamman menetelmän yhdistelmiä tehostamaan toimintaa ja tarkentamaan tuloksia. Näitä kutsutaan hybridimenetelmiksi. Monet esitellyistä menetelmistä ovat toiminnaltaan melko yksinkertaisia. Yksinkertaisuuden seurauksena monet menetelmistä ovat herkkiä erilaisille muuttujille datassa. Sen vuoksi niitä on kehitetty joko lisäämällä ominaisuuksia kyseiseen algoritmiin tai käyttämällä sitä yhdessä toisen algoritmin kanssa. (Al-khatib ym., 2019; Jiang ym., 2020) Kehitettyjä malleja ovat esimerkiksi SVM-mallin pohjalta kehitetty OCSTuM, joka perustuu vektoriarvuuden sijaan tensoriarvuuteen (Deng ym., 2019). Tensorilla tarkoitetaan matemaattista oliota, joka kykenee kuvaamaan useita ulottuvuuksia. Hybridimallista voidaan mainita esimerkkinä kolmen menetelmän yhdistelmä, jossa hyödynnetään varianssianalyysiä, tukivektoriregressiota ja K:n keskiarvon ryvästystä (Saneja & Rani, 2018).

Koneoppimismenetelmän valintaan vaikuttaa paljon käyttökohde ja sen datan muoto ja ulottuvuudet. Moniulotteinen data vaatii tietynlaisia algoritmeja sen analysointiin ja poikkeavien arvojen tunnistamiseen. Lisäksi datan sisältämä häiriö voi vaikuttaa algoritmista riippuen paljon tai vähän sen toimivuuteen. Koneoppimismenetelmän valinnan kannalta on olennaista päättää, käytetäänkö ohjattua vai ohjaamatonta oppimista. Ohjatun oppimisen menetelmiä varten tulee luoda koulutusdataa, mikä itsessään kuluttaa huomattavasti aikaa ja resursseja. Tämän lisäksi tulee

huomioida mahdolliset rajoitteet viiveessä, tehonkulutuksessa ja virhemarginaaleissa (Jiang ym., 2020). Kullakin menetelmällä on omat etunsa ja haittansa.

Artikkelissaan Jiang ym. (2020) tutkivat eri koneoppimismenetelmien välisiä eroja poikkeavien arvojen havaitsemisessa. Koneoppimismenetelmien tuloksia vertailtiin kahdessa mittarissa: oikeiden positiivisten ja väärin positiivisten tulosten määrä. Erilaiset hybridialgoritmit toimivat kummassakin mittarissa parhaiten. Erilaisten menetelmien kehittyneemmät versiot, kuten OCSTuM ja RPCA tuottavat parempia tuloksia varsinkin oikeiden positiivisten tunnistamisessa. Tästä voisi siis päätellä, että vanhat ja yksinkertaiset koneoppimismenetelmät eivät ole kovin tehokas tapa havaita IoT:n suuressa datamäärässä usein esiintyviä poikkeavia arvoja. Artikkelissa tehdyn vertailun pohjalta huomataan esimerkiksi K:n keskiarvon ryvästykseen olevan huonompi menetelmä poikkeavuuksien havaitsemiseen kehittyneempiin, kuten OCSTuM, ja hybridimenetelmiin, kuten DBSCAN-SVM, verrattuna.

Erityyppisillä koneoppimismenetelmillä on kuitenkin kaikilla omat vahvuutensa ja heikkoutensa. Käyttökohde vaikuttaa menetelmän valintaan muun muassa datan reaaliaikaisuuden ja tulosten tarkkuuden kautta. Esimerkiksi naapureihin perustuvat menetelmät tuottavat vähemmän vääriä positiivisia tuloksia, mutta ovat etäisyyksiin perustuvia menetelmiä huonompia poikkeavuuksien tunnistamisessa. Lisäksi datan monimutkaisuus voi vaikuttaa menetelmän valintaan etenkin ohjatun oppimisen algoritmeja käytettäessä. Monimutkaiselle datalle on hyvin vaikeaa luoda hyviä leimoja luokittelua varten. (Jiang ym., 2020)

Menetelmän valintaan liittyvistä ongelmista johtuen olisi hyvä tehdä enemmän laajamittaista vertailua eri menetelmien välillä, jotta voitaisiin löytää eroja niiden tehokkuudessa ja tarkkuudessa. Lisäksi kysymys IoT-laitteen keräämän datan muodon vaikutuksesta menetelmän valintaan jäi vastaamatta. Se kuitenkin vaikuttaa oleellisesti käytetyn menetelmän valintaan, joten sen tutkiminen voisi edelleen parantaa koneoppimismenetelmien toimintaa. Kehittyneempien versioiden ja hybridi-

mallien paremmasta tehokkuudesta ja tarkkuudesta johtuen olisi hyvä saada selville muita mahdollisia hybridimalleja, jotka saattaisivat toimia jopa nykyisiä paremmin.

## 4 Yhteenveto

Koneoppimismenetelmien hyödyntämistä poikkeavien arvojen havaitsemisessa IoT-datassa tarkasteltiin tutkielmassa eri käyttökohteiden ja niissä käytettyjen menetelmien pohjalta. IoT-laitteiden keräämä data saa helposti ylimääräisiä vaikutteita, jotka tulee tulkita joko turhiksi tai mielenkiintoa herättäviksi. Poikkeavien arvojen havaitsemista tarvitaan, sillä riippuen poikkeavan arvon tyypistä tulee se joko poistaa datasta onnistuneen analyysin takaamiseksi tai eritellä se omaa analyysiä varten. Analyysin pohjalta voidaan tehdä esimerkiksi muutoksia tai korjauksia järjestelmään.

Ensimmäiseen tutkimuskysymykseen *”Miten koneoppimismenetelmiä voidaan hyödyntää IoT-datan poikkeavien arvojen havaitsemiseen?”* vastattiin tutkielmassa tutkimalla ensin eri osa-alueita, joissa IoT-verkkoja hyödynnetään. Hyviä käyttökohteita löytyi terveyden ja lääketieteen, teollisuuden ja älykodin ja -kaupungin osa-alueilta. Koneoppimismenetelmien hyödyntämisen edut IoT-datan yhteydessä ilmenevät poikkeavien arvojen havaitsemisen tarkkuudessa, syy-seuraussuhteen löytämisessä ja suurten datamäärien käsittelyssä.

Koneoppimismenetelmiä hyödyntämällä voidaan mahdollistaa IoT-datan tehokas analyysi ja aikaistaa esimerkiksi koneen vian tai potilaan tilan muutoksen havaitsemista. Koneoppimismenetelmien etu poikkeavien arvojen havaitsemisessa perinteisiin tilastollisiin menetelmiin verrattuna on niiden kyky oppia tunnistamaan

poikkeavuuksia ja tehdä niiden pohjalta luokittelua tai ryvästystä, jonka seurauksena poikkeavien arvojen havaitseminen nopeutuu ja sen tarkkuus paranee.

Toiseen tutkimuskysymykseen ”*Mitkä koneoppimismenetelmät toimivat havaitsemisessa parhaiten?*” pyrittiin löytämään tutkielmassa vastausta vertailemalla julkaisuissa käytettyjä koneoppimismenetelmiä ja niiden toimivuudesta saatuja tuloksia toisiinsa, sekä mittaamalla niiden toimivuutta ja tarkkuutta. Yhdistävänä tekijänä vertailussa voitiin huomata koneoppimismenetelmän valinnan olevan melko tapauskohtaista käyttötarkoituksen ominaisuuksista, kuten datan tyypistä ja määrästä, sekä rajoitteista riippuen. Lisäksi esimerkiksi analyysin tai havaitsemisen reaaliaikaisuuden tarve vaikuttaa menetelmän valintaan ja sen toiminnan tehokkuuteen. Erilaisten hybridialgoritmien ja menetelmien kehittyneempien versioiden suoriutuvan parhaiten. Aineistoissa yleisimmin käytettyjä menetelmiä olivat tukivektorikone ja K:n keskiarvon ryvästys niiden joustavuudesta ja yksinkertaisuudesta johtuen. Niiden toimivuuden paremmuudesta ei kuitenkaan saatu selkeää vastausta.

Eri koneoppimismenetelmien hyötyjen ja toimivuuden vertailun pohjalta voidaan esittää seuraavat kolme tutkimuskysymystä, joiden avulla voidaan saada lisää selkeyttä menetelmän valintaprosessiin:

1. Mitkä eri koneoppimismenetelmien yhdistelmät tuottavat parhaiten toimivia hybridimalleja poikkeavien arvojen havaitsemiseen?
2. Miten kerätyn datan muoto vaikuttaa koneoppimismenetelmän valintaan?
3. Mikä koneoppimismenetelmä sopii parhaiten minkäkin tyyppiseen dataan?

Yleisellä tasolla koneoppimismenetelmien merkitys IoT-datan poikkeavien arvojen havaitsemisessa tulee tulevaisuudessa todennäköisesti kasvamaan ja alan tutkimuksen ja kehityksen myötä tulokset paranevat ja yhä useammat siirtyvät koneoppimismenetelmien hyödyntämiseen. IoT-laitteiden yleistymisellä tulee olemaan suuri merkitys tehdyn data-analyysin määrään, ja sitä kautta tarkempaan ja nopeampaan poikkeavien arvojen havaitsemiseen.

# Lähdeluettelo

- Aggarwal, C. C. (2016). An Introduction to Outlier Analysis. Teoksessa *Outlier Analysis* (s. 1–34). Springer International Publishing. [https://doi.org/10.1007/978-3-319-47578-3\\_1](https://doi.org/10.1007/978-3-319-47578-3_1)
- Al-Dhief, F. T., Latiff, N. M. A., Malik, N. N. N. A., Salim, N. S., Baki, M. M., Albadr, M. A. A., & Mohammed, M. A. (2020). A Survey of Voice Pathology Surveillance Systems Based on Internet of Things and Machine Learning Algorithms. *IEEE Access*, 8, 64514–64533. <https://doi.org/10.1109/access.2020.2984925>
- Al-khatib, A. A., Balfaqih, M., & Khelil, A. (2019). A survey on outlier detection in Internet of Things big data. Teoksessa *Big Data-Enabled Internet of Things* (s. 225–272). Institution of Engineering; Technology. [https://doi.org/10.1049/pbpc025e\\_ch11](https://doi.org/10.1049/pbpc025e_ch11)
- Ayadi, A., Ghorbel, O., Obeid, A. M., & Abid, M. (2017). Outlier detection approaches for wireless sensor networks: A survey. *Computer Networks*, 129, 319–333. <https://doi.org/10.1016/j.comnet.2017.10.007>
- Bzai, J., Alam, F., Dhafer, A., Bojović, M., Altowaijri, S. M., Niazi, I. K., & Mehmood, R. (2022). Machine Learning-Enabled Internet of Things (IoT): Data, Applications, and Industry Perspective. *Electronics*, 11(17), 2676. <https://doi.org/10.3390/electronics11172676>

- Deng, X., Jiang, P., Peng, X., & Mi, C. (2019). An Intelligent Outlier Detection Method With One Class Support Tucker Machine and Genetic Algorithm Toward Big Sensor Data in Internet of Things. *IEEE Transactions on Industrial Electronics*, *66*(6), 4672–4683. <https://doi.org/10.1109/tie.2018.2860568>
- Dwivedi, R. K., Kumar, R., & Buyya, R. (2021). A Novel Machine Learning-Based Approach for Outlier Detection in Smart Healthcare Sensor Clouds. *International Journal of Healthcare Information Systems and Informatics*, *16*(4), 1–26. <https://doi.org/10.4018/ijhisi.20211001.0a26>
- Dwivedi, R. K., Rai, A. K., & Kumar, R. (2020a). Outlier Detection in Wireless Sensor Networks using Machine Learning Techniques: A Survey. *2020 International Conference on Electrical and Electronics Engineering (ICE3)*, 316–321. <https://doi.org/10.1109/ice348803.2020.9122865>
- Dwivedi, R. K., Rai, A. K., & Kumar, R. (2020b). A Study on Machine Learning Based Anomaly Detection Approaches in Wireless Sensor Network. *2020 10th International Conference on Cloud Computing, Data Science amp; Engineering (Confluence)*, 194–199. <https://doi.org/10.1109/confluence47617.2020.9058311>
- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, 226–231.
- Fahim, M., & Sillitti, A. (2019). Anomaly Detection, Analysis and Prediction Techniques in IoT Environment: A Systematic Literature Review. *IEEE Access*, *7*, 81664–81681. <https://doi.org/10.1109/access.2019.2921912>
- Gaddam, A., Wilkin, T., Angelova, M., & Gaddam, J. (2020). Detecting Sensor Faults, Anomalies and Outliers in the Internet of Things: A Survey on the

- Challenges and Solutions. *Electronics*, 9(3), 511. <https://doi.org/10.3390/electronics9030511>
- Gultekin, E., & Aktas, M. S. (2022). A Business Workflow Architecture for Predictive Maintenance using Real-Time Anomaly Prediction On Streaming IoT Data. *2022 IEEE International Conference on Big Data (Big Data)*, 4568–4575. <https://doi.org/10.1109/bigdata55660.2022.10020384>
- Hawkins, D. M. (1980). Introduction. Teoksessa *Identification of Outliers* (s. 1–12). Springer Netherlands. [https://doi.org/10.1007/978-94-015-3994-4\\_1](https://doi.org/10.1007/978-94-015-3994-4_1)
- Huang, Z., & Wu, Y. (2022). A Survey on Explainable Anomaly Detection for Industrial Internet of Things. *2022 IEEE Conference on Dependable and Secure Computing (DSC)*, 1–9. <https://doi.org/10.1109/dsc54232.2022.9888874>
- Jan, B., Farman, H., Khan, M., Imran, M., Islam, I. U., Ahmad, A., Ali, S., & Jeon, G. (2019). Deep learning in big data Analytics: A comparative study. *Computers amp; Electrical Engineering*, 75, 275–287. <https://doi.org/10.1016/j.compeleceng.2017.12.009>
- Jiang, J., Han, G., liu, L., Shu, L., & Guizani, M. (2020). Outlier Detection Approaches Based on Machine Learning in the Internet-of-Things. *IEEE Wireless Communications*, 27(3), 53–59. <https://doi.org/10.1109/mwc.001.1900410>
- Mosallam, B. E., & Ahmed, S. H. (2023). Exploring Effective Outlier Detection in IoT: A Systematic Survey of Techniques and Applications. *2023 Intelligent Methods, Systems, and Applications (IMSA)*, 375–380. <https://doi.org/10.1109/imsa58542.2023.10255071>
- Saneja, B., & Rani, R. (2018). A Hybrid Approach for Outlier Detection in Weather Sensor Data. *2018 IEEE 8th International Advance Computing Conference (IACC)*, 321–326. <https://doi.org/10.1109/iadcc.2018.8692127>
- Shah, G., & Tiwari, A. (2018). Anomaly detection in IIoT: a case study using machine learning. *Proceedings of the ACM India Joint International Conference*



- on Data Science and Management of Data*, 295–300. <https://doi.org/10.1145/3152494.3156816>
- Shahid, Z. K., Saguna, S., & Åhlund, C. (2023). Outlier Detection in IoT data for Elderly Care in Smart Homes. *2023 IEEE 20th Consumer Communications & Networking Conference (CCNC)*, 1066–1073. <https://doi.org/10.1109/ccnc51644.2023.10060085>
- Singhal, D., Ahuja, L., & Seth, A. (2022). Anomaly Detection in Smart Meters: Analytical Study. *2022 2nd International Conference on Power Electronics & IoT Applications in Renewable Energy and its Control (PARC)*, 1–5. <https://doi.org/10.1109/parc52418.2022.9726670>
- Tang, S., Gu, Z., Yang, Q., & Fu, S. (2019). Smart Home IoT Anomaly Detection based on Ensemble Model Learning From Heterogeneous Data. *2019 IEEE International Conference on Big Data (Big Data)*, 4185–4190. <https://doi.org/10.1109/bigdata47090.2019.9006249>
- Ta-Shma, P., Akbar, A., Gerson-Golan, G., Hadash, G., Carrez, F., & Moessner, K. (2018). An Ingestion and Analytics Architecture for IoT Applied to Smart City Use Cases. *IEEE Internet of Things Journal*, 5(2), 765–774. <https://doi.org/10.1109/jiot.2017.2722378>
- Wu, Y., Dai, H.-N., & Tang, H. (2022). Graph Neural Networks for Anomaly Detection in Industrial Internet of Things. *IEEE Internet of Things Journal*, 9(12), 9214–9231. <https://doi.org/10.1109/jiot.2021.3094295>
- Ye, J., Stevenson, G., & Dobson, S. (2016). Detecting abnormal events on binary sensors in smart home environments. *Pervasive and Mobile Computing*, 33, 32–49. <https://doi.org/10.1016/j.pmcj.2016.06.012>
- Zhou, L., Pan, S., Wang, J., & Vasilakos, A. V. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing*, 237, 350–361. <https://doi.org/10.1016/j.neucom.2017.01.026>