



IoT-sensorointi tilakuormituksen ja liikkumisen seurannassa: passiivinen älylaitelaskenta ja kevyt data-alusta

1. Johdanto ja tavoite

Tässä dokumentissa kuvataan passiiviseen radiokuunteluun perustuvan älylaitelaskennan periaate sekä se, millaista käyttökelpoista seurantatietoa menetelmällä voidaan tuottaa nykyaikaisessa IoT-asetelmassa. Tarkastelun lähtökohtana on käytännön pilotointiympäristöissä kertynyt aikasarjadata, jota on kerätty useista mittauspisteistä erilaisissa toimintaympäristöissä. Tavoitteena ei ole raportoida yksittäisiä kohteita tunnistettavasti, vaan kuvata menetelmä ja sen tulkintakäytännöt yleisellä tasolla siten, että ratkaisu on monistettavissa muihin ympäristöihin.

Dokumentti on laadittu julkisen hankkeen käyttöön siten, että se ei sisällä henkilötietoja eikä yksilöiviä kohdekuvauksia. Käytännön toteutukset ja havainnot esitetään koontina: mitä ilmoitetaan aikasarjoissa tyypillisesti näkyy, millaisia rajoitteita tulkintaan liittyy ja millaisin käytännöin keruusta saadaan riittävän uskottavaa päätöksenteon tueksi.

2. Tausta: miksi passiivinen älylaitelaskenta on kiinnostavaa

Tilojen ja ympäristöjen käyttöasteen seuranta on monissa organisaatioissa kytkeytynyt palveluiden mitoittamiseen, resurssien kohdentamiseen sekä toiminnan kehittämiseen. Perinteiset ratkaisut, kuten kameraperusteinen laskenta, voivat olla kustannuksiltaan tai tietosuojavaatimuksiltaan hankalia tietyissä ympäristöissä. Passiivinen älylaitelaskenta tarjoaa vaihtoehdon, jossa mittaus perustuu ympäristössä havaittaviin langattomiin lähetyksiin (esimerkiksi Wi-Fi:n probe request -viestit tai Bluetooth Low Energy -mainoskehukset) ja niiden lukumäärän muutokseen ajan funktiona.

Kirjallisuudessa vastaavia lähestymistapoja on käytetty esimerkiksi kävijävirtojen ja väkijoukkojen seurannassa Wi-Fi-probe-havaintoihin perustuen. Menetelmän etuna on tyypillisesti asennettavuus ja kustannusrakenne, mutta samalla on tunnistettu, että modernien laitteiden yksityisyysominaisuudet (erityisesti MAC-osoitteiden randomisointi) vaikuttavat siihen, mitä voidaan arvioida luotettavasti ja millä tarkkuudella. ([Taylor & Francis Online](#))

Bluetooth-pohjaisissa asetelmissa on raportoitu käyttökelpoisia tuloksia esimerkiksi joukkoliikenteen ruuhka-asteen arvioinnissa BLE-havaintojen avulla, kun tavoitteena on tuottaa tilannekuvaa ilman yksilöivää seurantaa. ([MDPI](#))

3. Menetelmän periaate: mitä havaitaan ja mitä ei havaita

Passiivisessa älylaitelaskennassa vastaanotin kerää aikaleimattuja radiokehyksiä ja muodostaa niistä aggregoituja mittareita määrättyssä aikaikkunassa (esimerkiksi 1–10 minuutin jaksoissa). Tyypillisiä aggregaatteja ovat:

Havaittujen läheteiden määrä aikaikkunassa ja havaittujen lähteiden lukumäärä aikaikkunassa. Lisäksi usein tarkastellaan vastaanotetun signaalinvoimakkuuden jakaumia (RSSI) ja niiden muutosta, ei yksittäisiä arvoja. RSSI:tä voidaan käyttää karkeana indikaattorina siitä, tapahtuuko havainto vastaanottimen läheisyydessä vai todennäköisemmin etäämmällä, mutta tulkinta ei

perustu suoraan etäisyysmalliin. Signaaliin vaikuttavat ympäristön rakenteet, heijastukset ja ihmiskehon aiheuttamat vaimennukset.

On tärkeää määritellä, mitä menetelmällä ei mitata. Menetelmä ei mittaa ihmisiä suoraan, vaan laitteiden lähettämiä kehyksiä. Henkilömäärää koskevat päätelmät ovat johdettuja ja soveltuvat parhaiten suhteelliseen tarkasteluun: aikasarjan rytmeihin, muutoksiin ja poikkeamiin, ei absoluuttisiin kävijälukuihin. Tämä raja on keskeinen myös tietosuojan näkökulmasta, koska tavoitteena ei ole yksilöiden tunnistaminen eikä reittien seuranta.

4. Datan käsittely ja tulkinta: aikasarjat, luokittelu ja peruskuorman arviointi

Käytännön tulkinta rakentuu aikasarjojen tarkasteluun. Tyypillisiä tarkasteluja ovat vuorokausiprofiilit, viikonpäiväkohtaiset erot ja poikkeamien tunnistus. Kun mittaus on käynnissä riittävän pitkään, sarjoista voidaan erottaa:

1. toistuvat rytmit, jotka liittyvät normaalitoimintaan
2. poikkeamat, jotka liittyvät tapahtumiin, kampanjoihin tai tilapäisiin muutoksiin ympäristössä
3. tasosiirtymät, jotka voivat viitata mittausjärjestelyn muutokseen (esimerkiksi sijoitus, antennisuuntaus tai ympäristön rakenteellinen muutos)

Yksi käytännöllinen tulkintatapa on peruskuorman arviointi yöajalta. Monissa ympäristöissä yöajan minimitaso tarjoaa karkean estimaatin siitä, kuinka paljon havaintoja syntyy “kiinteästä taustasta”, kuten pysyvistä laitteista tai ympäristön läpi kantautuvasta radioliikenteestä. Tätä peruskuormaa voidaan käyttää vertailukelpoisuuden parantamiseen: kun sarjoja verrataan ajanjaksojen välillä, huomio siirtyy muutokseen peruskuorman yli.

RSSI-luokittelussa voidaan käyttää yksinkertaista tasoajattelua: analysoidaan erikseen vahvemmat ja heikommat havainnot, jolloin saadaan kaksi rinnakkaista aikasarjaa, joista toinen painottuu vastaanottimen lähiympäristöön ja toinen kuvaa laajempaa “taustakenttää”. Tällainen differoiva ajattelu on käytetty myös BLE-perusteisissa katutila-asetelmissä, joissa kahden sensorin RSSI-eroa hyödynnetään liikesuunnan tulkinnan tukena. ([Yuki Matsuda Portfolio](#))

5. Toteutusmalli: kevyt mittausketju ja data-alusta

Low-cost IoT -toteutuksessa mittausketju suunnitellaan siten, että reunalaitteessa tehdään vain välttämätön käsittely: havaintojen vastaanotto, aggregointi ja mittausjakson koonti. Varsinainen seuranta ja visualisointi toteutetaan keskitetysti data-alustalla. Käytännöllinen malli on seuraava:


Reunalaitteet tuottavat aikaikkunakohtaisia koonteja ja lähettävät ne eteenpäin yksinkertaisena sanomana. Sanoma vastaanotetaan palvelinpäässä, jossa datavirta ohjataan käsittelyyn ja tallennukseen. Tämäntyyppisessä ketjussa Node-RED soveltuu integraatiologian rooliin, InfluxDB aikasarjataltointiin ja Grafana visualisointiin. Kokonaisuuden etu on, että se on sekä opetettavissa että siirrettävissä eri kohteisiin ilman tapauskohtaista järjestelmäarkkitehtuuria. Samalla se tuottaa dokumentoitavan “yleisen mallin”, joka on julkisen hankkeen näkökulmasta olennainen: tulos ei ole yksittäinen pilotti, vaan monistettava toteutustapa.

Tässä dokumentissa kuvattu malli ei edellytä henkilötason tunnisteiden tallentamista. Jos tunnisteita käsitellään missään vaiheessa, niiden käsittely täytyy rajata tekniseen välttämättömyyteen ja varmistaa, että lopputulos on aidosti aggregoitu eikä mahdollista yksilöintiin johtavia päätelmiä.

6. Havaintoja eri ympäristöistä

Kerätyssä aineistossa toistuvat vuorokausi- ja viikonpäivärytmit toimivat ensisijaisena uskottavuustarkistuksena. Tyypillisesti yöajan taso on matalampi ja päiväaikaan sarja nousee ympäristön käyttötarkoituksen mukaisesti. Lisäksi viikonloppujen ja arkipäivien erot ovat monissa ympäristöissä selkeitä.

Vähittäiskaupan kaltaisessa ympäristössä aikasarjoissa on tyypillisesti havaittavissa paitsi viikonlopun korostuminen myös ajoittaiset poikkeamajaksot, jotka voivat liittyä kampanjoihin (Kuva 1) tai kausivaihteluun. Tulkinnan kannalta olennaista on, että poikkeama näkyy useissa rinnakkaisissa mittauspisteissä johdonmukaisesti tai ainakin niissä pisteissä, joiden oletetaan altistuvan ilmiölle.



Kuva 1. Myymälän tarjouskampanja erottuu selkeästi datasta.

Julkisessa liikennesolmussa tai muussa läpikulkuympäristössä aikasarjoihin syntyy usein lyhytkestoisia piikkejä (Kuva 2), jotka voivat liittyä saapumisaaltoihin ja lähtöaikoihin. Tällaisissa kohteissa korostuu mittausjakson valinta: liian pitkä aggregointi tasoittaa piikkejä, liian lyhyt kasvattaa kohinan merkitystä.


Seuraavassa kuvassa (Kuva 2) näkyy erityisen suuri piikki 21.9. Tämä johtuu todennäköisesti Robbie Williamsin keikasta Helsingissä 20.9 ja siihen liittyvästä paluuliikenteestä. Tiistaina 30.9 alkaen näkyy epätavallisen paljon liikennettä rautatieasemalle. Tämä todennäköisesti liittyy Tampereella järjestettyihin alihankintamessuihin.



Kuva 2. Asemakeskuksen dataa.

Liikkuvassa ympäristössä (Kuva 3) tulkinnan haasteet korostuvat, koska radiomaisema ja ympäristö muuttuvat jatkuvasti. Kirjallisuudessa BLE-havaintoja on kuitenkin onnistuneesti käytetty esimerkiksi bussin ruuhka-asteen arvioinnissa, kun tavoitteena on päätellä kuormitustaso eikä yksilöidä matkustajia. (MDPI) Tässä koontimallissa liikkuvan ympäristön

tärkein anti onkin reunaehtojen näkyväksi tekeminen: asennettavuus, datan jatkuvuus ja tulkinnan robustisuus.



Kuva 3. Julkisen liikenteen bussista kerättyä dataa.

7. Luotettavuus ja rajoitteet

Älylaitelaskennan keskeiset rajoitteet liittyvät peittoasteeseen, monilaitteisuuteen ja laitteiden yksityisyysominaisuuksiin.

Peittoaste vaihtelee: kaikilla ei ole Bluetooth tai Wi-Fi aktiivisena, ja mainostus- tai probe-käyttäytyminen riippuu laitteen käyttötilasta. Monilaitteisuus aiheuttaa sen, että yksi henkilö voi tuottaa useita havaittavia lähteitä (puhelin, älykello, kuulokkeet), jolloin absoluuttinen henkilömäärä ei ole suoraan johdettavissa havaintojen määrästä.

Wi-Fi-puolella MAC-osoitteiden randomisointi on merkittävä tekijä. Kirjallisuudessa on kuvattu, että randomisointi heikentää laiteyksilöiden yhdistettävyyttä ja siten rajoittaa erityisesti reittien ja toistuvuuden arviointia. Samalla on esitetty menetelmiä, joilla probe-havaintoja voidaan yhdistellä randomisoinnista huolimatta, mikä osoittaa, että yksityisyysriskejä pitää arvioida huolellisesti eikä ole turvallista olettaa, että “randomisointi tekee datasta automaattisesti anonymia”. ([ACM Digital Library](#))

Jos tavoitteena on vain aggregoitu kuormitusindikaattori, käytännöllinen ja tietosuojan kannalta turvallisempi linja on rajata käsittely siihen, että tunnisteita ei tallenneta, ja analyysi tehdään vain aikaikkunakohtaisista summista ja jakaumista.

8. Tietosuoja ja eettiset reunaehdot

Tämäntyyppinen mittaus sijoittuu tietosuojakeskustelussa usein “presence analytics” -tyyppiseen luokkaan: arvioidaan, kuinka paljon laitteita havaitaan alueella, ei missä yksittäinen

laite liikkuu. Tämä erottelu on kuvattu myös viranomaisohjeistuksissa Wi-Fi-seurantateknologioiden yhteydessä. ([AEPD](#))

Käytännön vaatimukset tiivistyvät kolmeen asiaan.

Ensinnäkin, Hankkeen toteutuksessa painotettiin teknistä tietosuojaa. Koska järjestelmä laskee havainnot suoraan reunalaitteella ja lähettää eteenpäin vain numeerisia summatietoja (ei MAC-osoitteita), yksittäisen henkilön seuranta tai tunnistaminen ei ole mahdollista. Tämä minimoi tietosuojariskit tilanteissa, joissa erillistä informointia ei ole mahdollista järjestää (esim. lyhytaikaiset mittausjaksot).

Toiseksi, minimointi ja käyttötarkoitussidonnaisuus. Jos hankkeen tavoitteena on tuottaa yleinen tilannekuva ja trendiseuranta, käsittely tulee rajata tähän. Kolmanneksi, anonymisoinnin käsitteen varovainen käyttö. EU:n Article 29 Working Party on korostanut, että anonymisoinnin arviointi liittyy uudelleentunnistamisen riskiin ja siihen, onko yksilöinti ”kohtuullisin keinoin” mahdollista. ([European Commission](#)) Tämän vuoksi on perusteltua kuvata lopputulos mieluummin aggregoituna seurantatietona kuin ”täysin anonymisoituna henkilödatan käsittelynä”, ellei anonymisointia ole arvioitu järjestelmällisesti.

9. Suositukset käytännön käyttöönottoon

Jotta menetelmä tuottaa päätöksenteon kannalta uskottavaa tietoa, käyttöönotossa kannattaa noudattaa kahta periaatetta: mittausjärjestelyjen pysyvyys ja tulkinnan kalibrointi.

Pysyvyys tarkoittaa sitä, että sensorin sijoitus ja suuntaus dokumentoidaan, ja muutokset kirjataan, koska muuten aikasarjoihin syntyy tasosiirtymiä, joita voidaan virheellisesti tulkita käyttäytymisen muutokseksi. Kalibrointi tarkoittaa sitä, että ensimmäiset viikot käytetään ”normaalitason” hahmottamiseen: millainen on yöminimi, millainen on tyypillinen viikonloppu, ja millaisia poikkeamia järjestelmä tunnistaa.

Lisäksi suositeltavaa on käyttää vähintään kahta mittauspistettä, jos ympäristö on laaja tai jos halutaan erottaa lähiympäristö ja taustakenttä. Tämä ei vaadi uutta arkkitehtuuria, vaan sama data-alusta palvelee useaa syöttöä.

10. Yhteys MOI Hubin tavoitteisiin ja yleinen hyödynnettävyys

MOI Hubin kaltaisessa low-cost IoT -hankkeessa keskeinen tulos ei ole yksittäinen asennus, vaan monistettava malli: miten IoT laitteilla tuotetaan seurattavaa aikasarjatietoa ja miten tämä tieto tuo ilmiöitä näkyväksi yleiskäyttöisellä data-alustalla. Tässä dokumentissa kuvattu älylaitelaskenta toimii esimerkkinä siitä, miten ”havainto -> koonti -> siirto -> tallennus -> visualisointi” -ketju toimii osana arvonluontia.

10.1 Mittausresoluutio ja jaksoitus

Passiivisessa seurannassa voidaan hyödyntää erilaisia mittausstrategioita, jotka valitaan tyypillisesti käytettävissä olevan laitekapasiteetin ja tavoitellun tarkkuuden perusteella. Keskeisimmät lähestymistavat voidaan jakaa jatkuvaan aggregointiin ja sykliseen otantaan, joista kumpikin palvelee eri analyysitarpeita.

Pääasiallisena menetelmänä käytettävässä jatkuvassa aggregoinnissa reunalaitte kuuntelee radioliikennettä keskeytyksettä koko mittausjakson, kuten viiden minuutin, ajan. Tässä mallissa laite kerää kaikki havaitut uniikit tunnisteet muistiinsa ja muodostaa niistä summan, joka lähetetään eteenpäin vasta jakson päättyessä. Menetelmä on erittäin luotettava erityisesti pitkän

aikavälin rytmien, kuten vuorokausiprofiilien ja viikonpäiväkohtaisten erojen seurantaan. Sen suurin etu on kyky minimoida nykyaikaisten älylaitteiden epäsäännöllisestä lähetyksrytmistä johtuva epävarmuus; jatkuva kuuntelu suodattaa tehokkaasti satunnaisvaihtelua ja varmistaa, että harvoin signaaleja lähettävät laitteet tulevat havaituksi mittausikkunan aikana.

Vaihtoehtoisena lähestymistapana on sykliseen otantaan perustuva laskenta, jossa mittaus koostuu toistuvista lyhyistä havaintojaksoista. Käytännössä tämä voi tarkoittaa esimerkiksi viiden sekunnin aktiivista skannausta kymmenen sekunnin välein, jolloin jokainen otos lähetetään välittömästi data-alustalle omana datapisteenään. Otosperusteinen malli mahdollistaa erittäin nopean reagoinnin äkillisiin kuormituspiikkeihin, kuten joukkoliikennevälineen saapumiseen laiturille, ja se säästää samalla reunalaitteen laskentaresursseja sekä radiokaistaa. Menetelmän rajoitteena on kuitenkin sen tilastollinen luonne. Koska modernit älypuhelimet saattavat lähettää radioviestejä vain 20–60 sekunnin välein, yksittäinen lyhyt otos sisältää merkittävästi kohinaa ja usein aliarvioi hetkellistä henkilömäärää. Tämän vuoksi luotettavan tilannekuvan muodostaminen otosdatasta vaatii tyypillisesti datan tasoittamista, kuten liukuvan keskiarvon laskentaa, palvelinpäässä.

Näitä kahta menetelmää voidaan pitää käytännöllisenä kompromissina eri seurantatarpeiden välillä. Siinä missä jatkuva viiden minuutin ikkuna antaa vakaan ja uskottavan pohjan pitkäkestoiselle päätöksenteolle, lyhyempi otosperusteinen seuranta mahdollistaa ilmiöiden tarkemman ajoituksen ja piikkien rakenteen yksityiskohtaisen tarkastelun, kunhan datan tilastollinen luonne huomioidaan analyysivaiheessa.

10.2 Mittausympäristöjen tyypit

Mittauksia tehtiin monityyppisissä ympäristöissä, jotta menetelmän käyttökelpoisuutta voidaan arvioida eri reunaehdoilla. Ympäristötyypit olivat:

- (1) vähittäiskaupan kaltainen asiointiympäristö,
- (2) liikennesolmu tai vastaava läpikulkuympäristö (esimerkiksi asema- tai terminaaliluonteinen),
- (3) julkinen asiointiaula (yleisluonteinen palveluympäristö), sekä
- (4) liikkuva ympäristö (paikallisliikenteen kaltaisessa kontekstissa).

Näiden ympäristöjen välillä erot korostuvat erityisesti radiopropagaation, kulkurytmien ja “taustalaitteiden” määrän suhteen. Siksi tulkinta perustui ensisijaisesti suhteellisiin muutoksiin ja vertailuihin saman mittauspisteen sisällä.

10.3 Datan keruu- ja käsittelyketju

Keruu- ja analyysiketju toteutettiin yhtenäisenä “data pipeline” -ratkaisuna, jossa keskeiset komponentit olivat Node-RED (datan vastaanotto ja jatkokäsittelyn orkestrointi), aikasarjatietokanta (kuten InfluxDB-tyyppinen ratkaisu) sekä Grafana (visualisointi ja seuranta). Tämä on raportoinnin kannalta olennainen: sama ketju on ollut hyödynnettävissä useissa piloteissa ja se tukee toistettavuutta, kun mittauspisteitä lisätään.

Esimerkki reunalaitteen logiikasta (Python): Alla oleva koodiesimerkki havainnollistaa, kuinka sensori kerää uniikkeja laitetunnisteita määritetyn aikaikkunan (esim. 300 s) ajan, laskee niiden summan ja lähettää vain aggregoidun tiedon eteenpäin. Tämä varmistaa, että yksilöiviä tunnisteita ei tallenneta pysyvästi tai siirretä verkossa tarpeettomasti.

```
1. import asyncio
2. import time
```

```

3. import requests
4. from bleak import BleakScanner
5.
6. # --- KONFIGURAATIO ---
7. # REST-rajapinnan osoite (esim. Node-RED tai InfluxDB-integraatio)
8. ENDPOINT_URL = "http://palvelin.paikka/api/mittaus"
9. # Mittausjakson pituus sekunteina (dokumentin suosittelema 5 min = 300s)
10. WINDOW_SIZE = 300
11. # Sensorin yksilöllinen tunnistus
12. SENSOR_ID = "sensori-aula-01"
13.
14. class DeviceCounter:
15.     def __init__(self):
16.         self.found_devices = set()
17.
18.     def callback(self, device, advertisement_data):
19.         """Käsitellään havaittu laite."""
20.         # Lisätään MAC-osoite set-rakenteeseen (tallentaa vain uniikit)
21.         self.found_devices.add(device.address)
22.
23.     async def run(self):
24.         print(f"Käynnistetään seuranta: {SENSOR_ID}")
25.
26.         while True:
27.             self.found_devices.clear()
28.             start_time = time.time()
29.
30.             # Aloitetaan passiivinen skannaus
31.             # Huom: 'active=False' on keskeinen passiivisen kuuntelun kannalta
32.             async with BleakScanner(self.callback, scanning_mode="passive") as scanner:
33.                 print(f"Mittaus sykli alkanut ({WINDOW_SIZE}s)...")
34.                 await asyncio.sleep(WINDOW_SIZE)
35.
36.             # Jakso päättyy, valmistellaan data
37.             count = len(self.found_devices)
38.             timestamp = time.strftime('%Y-%m-%dT%H:%M:%SZ', time.gmtime())
39.
40.             payload = {
41.                 "sensor_id": SENSOR_ID,
42.                 "timestamp": timestamp,
43.                 "device_count": count,
44.                 "duration_sec": WINDOW_SIZE
45.             }
46.
47.             # Lähetys REST-rajapintaan
48.             try:
49.                 # Käytetään timeoutia, jotta jumiutuva verkko ei pysäytä skannausta
50.                 response = requests.post(ENDPOINT_URL, json=payload, timeout=10)
51.                 print(f"Lähetetty: {count} laitetta. Status: {response.status_code}")
52.             except Exception as e:
53.                 print(f"Virhe lähetyksessä: {e}")
54.
55. if __name__ == "__main__":
56.     counter = DeviceCounter()
57.     try:
58.         asyncio.run(counter.run())
59.     except KeyboardInterrupt:
60.         print("Mittaus keskeytetty.")
61.

```

Datan vastaanotosta ja jatkokäsittelystä vastaa Node-RED, joka ohjaa tiedon InfluxDB-aikasarjatietokantaan visualisoitavaksi Grafana-näkymään. Tämä ketju tukee monistettavuutta: uuden sensorin lisääminen vaatii vain koodin konfiguroinnin (SENSOR_ID) ilman muutoksia taustajärjestelmään.

11. Päätelmät

Passiivinen älylaitelaskenta tuottaa käytännössä kuormitusindikaattorin, joka soveltuu parhaiten rytmien, trendien ja poikkeamien seurantaan. Menetelmä on käyttökelpoinen, kun tavoitteena on muodostaa tilannekuvaa matalilla kustannuksilla ja ilman yksilöivää seurantaa. Uskottavuus rakentuu siitä, että aikasarjat ovat johdonmukaisia, mittausjärjestelyt pysyvät vakioina ja tulkinta nojautuu muutoksiin peruskuorman yli.

Suurimmat riskit liittyvät ylitulkintaan: jos menetelmää käytetään absoluuttisten kävijämäärien arviointiin ilman kalibrointia tai jos käsittelyyn lipsahtaa tunnisteiden tallentamista, kokonaisuus muuttuu sekä teknisesti että tietosuojan näkökulmasta eri luokan järjestelmäksi. Siksi suositeltava toimintatapa on pitää käsittely aggregoituna ja dokumentoida selkeästi, mitä mitataan ja mihin sitä käytetään.

12. Lähteet

Soundararaj, B. et al. "Estimating real-time high-street footfall from Wi-Fi probe requests." ([Taylor & Francis Online](#))

Tan, J. ja Chan, S.-H. G. "Efficient Association of Wi-Fi Probe Requests under MAC Address Randomization." ([ACM Digital Library](#))

Mishra, A. K. et al. "From WiFi probe-request signatures to MAC association." ([ScienceDirect](#))
Information Commissioner's Office (ICO). "Wi-Fi Location Analytics Guidance." ([ICO](#))

AEPD. "Wi-Fi tracking technologies: guidance for data controllers." ([AEPD](#))

Article 29 Working Party. "Opinion 05/2014 on Anonymisation Techniques." ([European Commission](#))

Kanamitsu, Y. et al. "Estimating Congestion in a Fixed-Route Bus by Using BLE Signals." ([MDPI](#))

Goto, I. et al. "BLE based Street Sensing for People Counting and Flow." ([Yuki Matsuda Portfolio](#))

Determe, J. F. et al. "Monitoring Large Crowds With WiFi." ([arXiv](#))