YMPÄRISTÖMELUN MITTAAMINEN KÄYTTÄEN AUTOMAATTISTA LÄHTEIDEN TUNNISTUSTA

Panu Maijala[1], **Toni Heittola**[2] **ja Tuomas Virtanen**[2]

[1] VTT
Visiokatu 4, 33720 Tampere
etunimi.sukunimi@vtt.fi

[2] Tampereen yliopisto
Audio research group
Korkeakoulunkatu 7, 33720 Tampere
etunimi.sukunimi@tuni.fi

Tiivistelmä

Jatkuvatoimisen ympäristömelun mittaamisen suuri haaste on ollut eri äänilähteiden osuuksien erottelu mittauksen aikana vallinneesta kokonaisäänitasosta. Yleensä mittaus suoritetaan selkeästi osoitettavissa olevan melulähteen vuoksi ja lopputuloksesta pyritään poistamaan muiden melulähteiden vaikutus. Ajallisesti lyhyessä mittaustapahtumassa mittaaja voi todentaa tilanteen joko kuuntelemalla mittaushetkellä tai tallennetusta äänestä jälkikäteen. Olemme toteuttaneet hahmontunnistukseen perustuvan luokittelualgoritmin äänitasomittariin ja testanneet sitä useissa eri kohteissa. Tässä paperissa kerromme uudesta äänitasomittarikonseptista, siihen toteutetusta opetetusta luokittelijasta ja luokittelijan suorituskyvystä pilottitutkimuksemme aikana. Lisäksi kerromme kohtaamistamme haasteista ja ratkaisuista niihin.

1 JOHDANTO

Ympäristömelua syntyy monista ihmisen toimista, työssä ja vapaa-aikana. Tyypillisiä ympäristömelulähteitä ovat lentokentät, ampumaradat, satamat ja kivenmurskaamot. Ääni saattaa kuulua sopivissa olosuhteissa jopa kymmenien kilometrien päähän näistä melulähteistä. Sää vaikuttaa merkittävästi melun leviämiseen [1] ja sään vaikutuksen aiheuttaman äänitasojen vaihtelun selvittämiseksi melua tulee seurata riittävän pitkään [2], tai käyttää statistiikkaan perustuvaa ympäristömelumallia, jolla keskiäänitason lisäksi myös vaihtelun suuruusluokka voidaan arvioida [3, 4].

Melun pitkäaikaisessa seurannassa on useita ongelmia: arvokkaita mittalaitteita ei voi sitoa yhteen kohteeseen pitkäksi aikaa ja yksittäinen mittauspiste ei useinkaan ole hyvä edustamaan koko naapuruston äänitasojen vaihtelua. Yksi haastavimmista ongelmista

Copyrigth ©2019 Panu Maijala, Toni Heittola ja Tuomas Virtanen. Tämä on avoimesti julkaistu teos, joka noudattaa Creative Commons NIMEÄ 4.0 Kansainvälinen –lisenssiä (CC BY 4.0). Teosta saa kopioida, levittää, näyttää ja esittää julkisesti ja siitä saa luoda johdannaisteoksia, kunhan tekijän nimi ja lähde mainitaan asianmukaisesti.

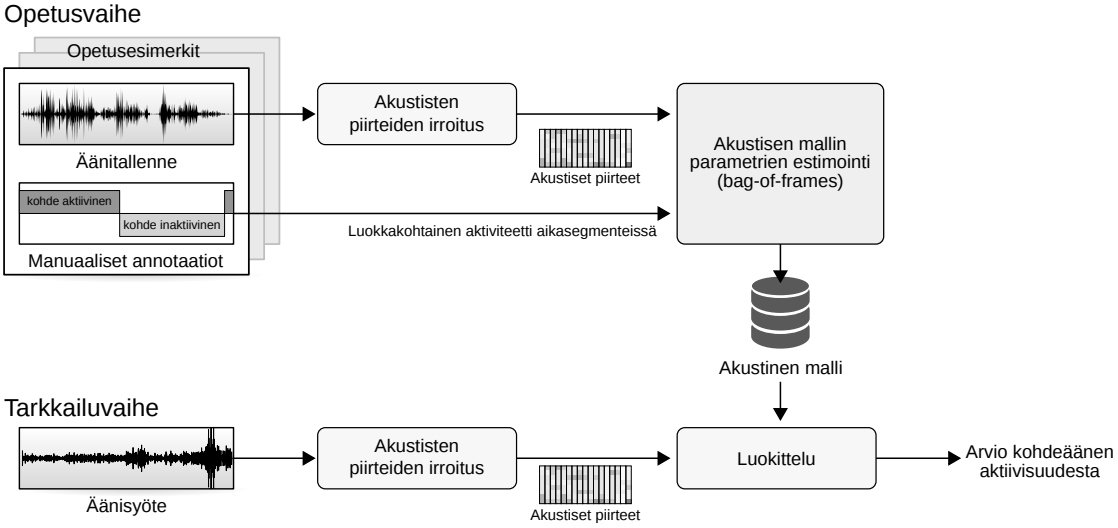

Kuva 1: Kohteen automaattisen äänitunnistamisen lohkokaavio.

on kuitenkin, miten erottaa mittausdatan joukosta ne äänitasolukemat, jotka eivät ole peräisin seurattavasta melulähteestä. Jos seurattava melulähde tuottaa merkittävästi muuta ympäristömelua suurempia äänitasoja, on äänitasoon perustuva luokittelu aivan riittävä. Asuinympäristössä syntyy usein ihmisen harrastetoiminnastakin (ruohonleikkurit, moottorisahat, painepesurit, lehtipuhaltimet) hetkellisesti suuria äänitasoja, jotka voivat vaikuttaa mittaustulokseen. Yhtenä ratkaisuna on käytetty äänisignaalin tallentamista äänitasojen tallentamisen lisäksi, jolloin mittauksista voidaan jälkikäteen kuuntelemalla todentaa, mitkä ajanhetket edustavat kohdetta. Äänilähteiden luokittelu ajallisesti pitkistä äänitallenteista kuuntelemalla on kuitenkin erittäin työlästä ja esitämme tässä paperissa konseptin, joka perustuu opetettuun luokittelualgoritmiin. Algoritmi erottelee mittaussignaalista seurattavan melulähteen aiheuttamat äänitasot muista ympäristömelulähteistä. Menetelmän yksityiskohtaisempi kuvaus löytyy julkaisusta Maijala et al. 2018 [5]. Lisäksi kerromme, minkälaisia haasteita olemme kokeneet tämän uuden mittauskonseptin pilotoinnissa ja miten olemme onnistuneet niitä ratkomaan.

2 METODI

Tässä kohteiden automaattiseksi tunnistamiseksi ehdottamassamme menetelmässä melulähteet jaetaan kahteen luokkaan. Tarkasteltavan melulähteen äänet kuuluvat luokkaan *kohdemelu* ja muut äänisignaaliin summautuvat äänet kuuluvat luokkaan *taustamelu*. Kohdemeluun voi kuulua useita, hyvinkin erityyppisiä herätteitä, kuten moottoriääniä, prosessiääniä ja hälytysääniä. Taustameluun kuuluvat ihmisen tuottamien herätteiden, kuten liikenne, lisäksi luonnonäänet: tuuli, sade, ukkonen ja linnut.

Kohteen herätteiden aktiivisuus analysoidaan jatkuvasta äänisignaalista tekemällä binäärinen luokittelu taustamelun ja kohdemelun välillä. Samasta äänisignaalista lasketaan myös melua karakterisoivat suureet, kuten A-painotettu ekvivalenttiäänitaso.

Tunnistusmenetelmässä on kaksi vaihetta: opetusvaihe ja seurantavaihe (katso kuva 1). Opetusvaiheessa akustiset mallit opetetaan manuaalisesti annotoitujen ääninäytteiden

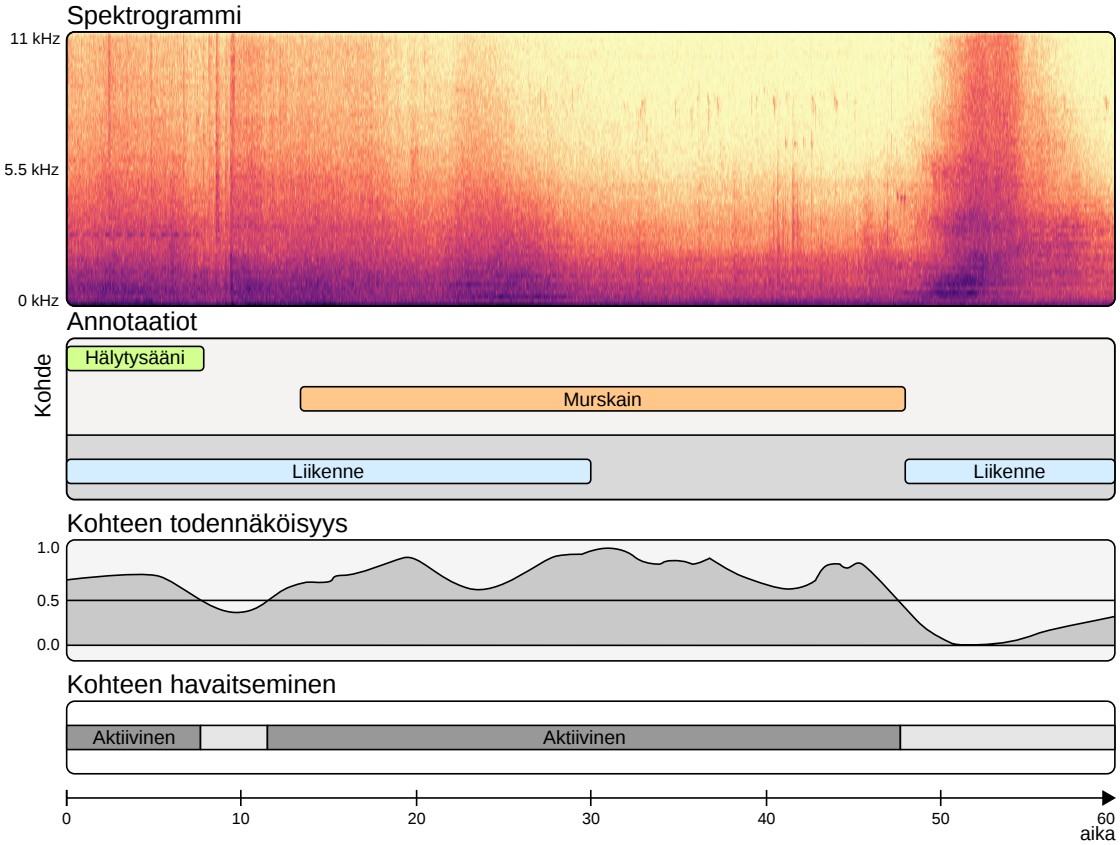

Kuva 2: Esimerkki kohteen tunnistamisesta luokittelijalla. Ylimmässä osiossa spektrogrammi ja seuraavassa vastaava annotointi. Liikenne kuuluu luokkaan *taustamelu*, kun taas murskain- ja hälytinäänet kuuluvat luokkaan *kohde*. Kolmas osio havainnollistaa kohteen tunnistamistodennäköisyyden ja näyttää päätöskynnyksen. Alimmassa on järjestelmän tunnistustulos.

avulla. Seurantavaiheessa opetettuja akustisia malleja käytetään tunnistamaan kohdemelu. Kuvassa 2 on esimerkki kohteen tunnistamisesta. Opetusalgoritmi tarvitsee ainoastaan kohdemelun annotoinnin, mutta kuvassa on annotoitu myös taustamelu (liikenne), jotta järjestelmän toiminta olisi helpommin ymmärrettävissä.

2.1 Akustinen piirreanalyysi

Akustinen piirreanalyysi muuttaa äänisignaalin redusoituun esitysmuotoon joka soveltuu paremmin akustisen mallin opettamiseen. Ehdottamassamme menetelmässä käytämme piirteinä joko meli-kepstrikertoimia (MFCC) [6] tai niiden dekorreloimatonta muotoa, log-mel –energiaspektriä. MFCC-piirreanalyysimenetelmä on alunperin kehitetty puheentunnistukseen [7], mutta se on osoittautunut hyvin toimivaksi menetelmäksi myös muissakin äänenkäsittelyyn liittyvissä sovelluksissa kuten yleisessä äänitapahtumien tunnistuksessa [8]. Menetelmässä äänisignaali analysoidaan lyhyissä laskentakehyksissä (esimerkiksi 100 ms) siten, että perättäiset kehykset peittävät toisensa 50 %. Laskentakehykset ikkunoidaan Hamming-ikkunalla ja kehyksen äänelle lasketaan spektri käyttäen diskreettiä Fourier-muunnosta. Saatu spektri skaalataan käyttäen logaritmista

meli-asteikkoa, joka mukailee ihmisen kykyä havainnoida äänenkorkeutta taajuuden funktiona. Spektrin logaritmi-arvot muutetaan diskreetillä kosinimuunnoksella (DCT) meli-kepstriksi, jonka kertoimia yleisesti kutsutaan MFCC-piirteiksi. Signaalienergia mallintuu ensimmäiseen kertoimeen tässä esitysmuodossa, joten tämä kerroin tiputetaan menetelmässämme pois piirrevektorista, jotta järjestelmä olisi invariantti havaittavien äänilähteiden etäisyyden suhteen. Piirteiden ajallinen muutos otettiin huomioon laskemalla ensimmäisen ja toisen kertaluvun delta-kertoimet.

2.2 Ohjattu oppiminen

Tutkimme kahden tyyppisiä ohjattuja luokittelijoita: normaalijakaumiin perustuvaa sekoitemallia (Gaussian Mixture Model, GMM), joka edustaa generatiivista luokittelijaa ja keinotekoista neuroverkkoa (artificial neural network, ANN), joka edustaa erottelevaa luokittelijaa. Opetusvaiheessa ohjattu oppiminen vaatii manuaalisesti annotoituja opetusesimerkkejä. Tarkkailuvaiheessa tunnistus tehdään yhden sekunnin segmenteissä käyttäen aikaisemmin opetettua luokittelijaa.

GMM-pohjainen luokittelija mallintaa luokan piirrevektorien jakaumaa usean normaalijakauman painotettuna summana [9]. Jokaiselle luokalle estimoidaan opetusmateriaalin perusteella oma GMM-malli opetusvaiheessa iteratiivisesti odotusarvon maksimoivalla EM-algoritmilla. Tarkkailuvaiheessa luokitus tehdään suurimman uskottavuuden estimaattorilla: äänisyötteen akustisille piirteille lasketaan luokkakohtainen uskottavuus ja luokittelu tehdään luokkaan, joka antoi suurimman uskottavuuden.

ANN-luokittelija estimoi funktiota, joka antaa halutun luokittelu-tuloksen tietyllä syötteenä käytettävällä piirrevektorilla [10]. Tutkimme kahta erityyppistä neuroverkkorakennetta: yksinkertaista monikerroksista perseptroniverkkoa (MLP) ja hieman monimutkaisempaa konvoluutioneuroverkkoa (CNN). MLP-verkkorakenne koostuu useampaan kerrokseen sijoitetuista keinotekoisista neuroneista, jotka on yhdistetty toisiinsa täysin. CNN-verkkorakenne puolestaan koostuu eteenpäin kytketyistä konvoluutiokerroksista, jotka ovat erikoistuneet kaksiulotteisten muotojen tunnistamiseen spektrogrammista. Luokittimen parametrit opetetaan käyttäen opetusesimerkkejä, jotka sisältävät syötteenä käytettävän piirrevektorin ja halutun binäärisen tulosvektorin, jossa aktiivinen luokka on indikoitu. Opetuksessa verkon parametreja optimoidaan iteratiivisesti minimoimalla virhefunktio halutun tulosvektorin ja verkon todellisen tulostiedon välillä. Tarkkailuvaiheessa luokitus tehdään syöttämällä äänisyötteen akustiset piirteet verkolle ja valitsemalla suurimman aktivaatiotuloksen tuottava luokka.

3 TULOKSET

Ensimmäinen pilottitestimme kohteena olivat Eurajoella sijaitsevan kivenmurskaamon melulähteet: kivenmurskaamon liikkuvat työkoneet ja murskaimien melu. Kivenmurskaamosta lähimmän asuinrakennuksen etäisyydelle sijoitettu sensori tallensi kivenmurskaamomelun lisäksi läheisen vilkasliikenteisen tien liikennemelua, joka luokiteltiin taustameluksi (katso kuva 2).

Toinen evaluointikohteemme oli musiikkimelu. Hangon huvivenesataman eli itäisen sataman alueella on useita ravintoloita, joissa kesäaikana soi musiikki. Alueella on myös asumiskäytössä olevia rakennuksia. Pilottitestissämme arvioimme n. 50 metrin päässä lähimmästä ravintolasta sijaitsevan sensorimme suorituskykyä kohdemeluna musiikki. Ravintolan ja yksityisasunnon seinään asennetun sensorin välissä on autotie ja erityisesti kesäisin suosittu ulkoilualue.

3.1 Kivenmurskaamomelu

Kohteessa tallennettiin ääntä kolme minuuttia kymmenen minuutin välein ja kahden päivän mittausdata (432 min) annotoitiin manuaalisesti evaluointioa varten. Evaluointi tehtiin käyttäen ristiinvalidointia siten, että vuorollaan kumpikin päivä oli opetusmateriaalina ja testimateriaalina. Kohdeäänenä oli kaikki kivenmurskaamon tuottama melu. Pääasiallisia melulähteitä murskaamossa olivat kiinteät ja siirreltävät kivenmurskaimet, sekä erilaiset maansiirtokoneet.

Järjestelmän komponentteja arvioitiin yksittäin piirteiden ja luokittelijoiden valitsemiseksi. Aluksi testasimme parametrejä MFCC-piirteille ja tämän jälkeen arvioimme kahden luokittimen (GMM ja MLP) suorituskykyä. Tulokset on esitetty taulukossa 1, valitut arvot lihavoituna ja piirteiden irrotuksen laskennalliset vaatimukset suhteena reaaliaikalaskentaan. Tunnistustehokkuuden lisäksi on esitetty arvioitu laskenta-aika (piirteiden irrotusaika) suhteessa sensorin raudan reaaliaikalaskentakapasiteettiin. Kepstrikertoimien lukumäärää vaihtelemalla saatiin pieni vaikutus luokittelijan suorituskykyyn.

Taulukko 1: Tulokset akustisen piirreanalyysin evaluoinnista.

Tarkasteltava muuttuja	Muuttujan arvo	F-arvo	Piirteiden irrotusaika
Kertoimien lukumäärä	8	92.6	0.51x
	13	**92.7**	0.51x
	20	92.7	0.51x
Aikatason dynamiikka	MFCC	92.7	0.51x
	MFCC+ Δ	**93.1**	0.51x
	MFCC+ Δ + $\Delta\Delta$	91.7	0.51x
Aikatason suodin	**Ilman suodinta**	**93.1**	0.51x
	Esikorostus	88.5	0.54x
	A-suodin	93.0	0.64x
Laskentakehyksen pituus	50 ms	89.8	0.99x
	100 ms	**93.1**	0.51x
	200 ms	91.4	0.27x

GMM-luokittelijaa käytettäessä keptrikertoimien määräksi valittiin 13, sillä tällä määrällä saadaan sama suorituskyky kuin 20 keptrikertoimella, mutta pienemmällä laskennallisella kuormalla. Paras suorituskyky tutkituissa aikatason piirreyhdistelmissä saadaan käyttämällä melikertoimia ensimmäisen kertaluvun delta-kertoimien kanssa. Toisen kertaluvun delta-kertoimet eivät lisänneet suorituskykyä, luultavasti koska laskentakehyksen pituus oli melko suuri (100 ms) ja ensimmäisen kertaluvun delta-kertoimet kattoivat

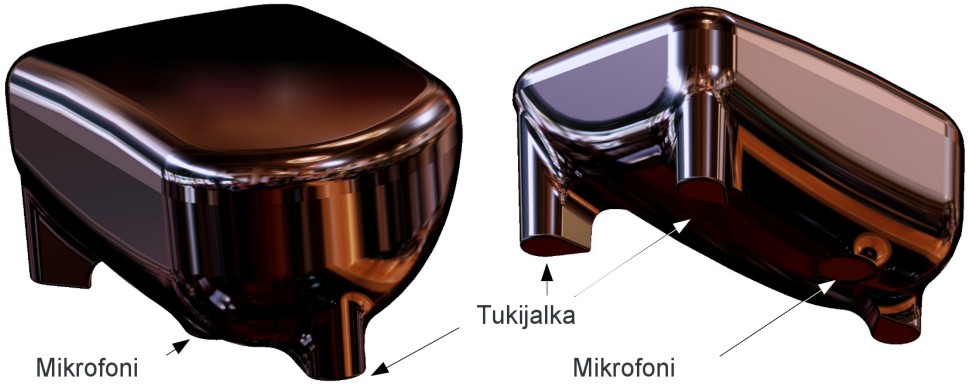

Kuva 3: *Sensorille suunniteltiin akustista BEM-mallinnusta hyödyntämällä kotelo, joka suojaa fyysisesti mikrofonin ja vääristää mahdollisimman vähän ääniaaltoa.*

aikatason dynamiikkaa jo 500 ms. Tulosten perusteella aikatason suodinten (A-painotus [11] ja esikorostus [9]) ei ole perusteltua. Laskentakehyksen pituus on selvästi tärkein laskenta-aikaan vaikuttava muuttuja. Paras luokittelukyky reaaliaikalaskennassa saadaan 100 ms:n laskentakehyksellä.

Taulukossa 2 on esitetty tulokset luokittelijoille erilaisilla parametreilla. Taulukossa parametri M on GMM-luokittelijassa käytettyjen normaalijakaumien lukumäärä ja MLP-luokittelijassa vastaavana muuttujana on $a \times b$, joka määrittää neuroverkon rakenteen niin että on b piilokerrosten lukumäärä ja a on neuronien määrä näissä piilokerroksissa.

Taulukko 2: Tulokset kivenmurskaamomelun luokittelijatestistä

Luokittelija	Parametrit	F-arvo	Luokitteluaika
GMM	$M = 1$	79.5	0.10×
	$M = 2$	87.0	0.10×
	$M = 4$	92.5	0.10×
	$M = 8$	92.8	0.11×
	$M = 16$	93.1	0.12×
	$M = 32$	93.4	0.14×
MLP	10×2	90.4	0.10×
	30×2	93.4	0.10×
	50×2	93.8	0.11×
	100×2	93.8	0.12×

MLP-luokittelijalla saadaan paras F-arvo ja sen laskenta on nopeinta. Ero MLP- ja GMM-luokittelijoiden välillä on kuitenkin melko pieni. Arvioitu luokitteluaika ei juurikaan riipu mallin parametreista. Tämä viittaa siihen, että suurin osa laskenta-ajasta menee yleisiin operaatioihin, kuten piirteiden kopiointiin, jos verrataan todennäköisyyksien laskentaan luokittelijalla. Laskenta-aikaa voitaisiin varmasti pienentää edelleen optimoimalla koodia, mutta tämän työn puitteissa se ei ollut tarpeen.

Kuva 4: *Sensori asennetaan standardin ISO1996-2:2007 mukaiselle tasaiselle pinnalle.*

3.2 Musiikkimelu

Musiikkimelun tapauksessa evaluaatio keskittyi menetelmän kehittelyyn vaihtelevissa melutilanteissa. Kohteessa oli mittausaikana käynnissä musiikkifestivaali, jossa soitettiin äänekästä ulkoilmamusiikkia ja tämä oli helppo havainnoida mittaussignaaleista. Normaalisti kohteessa kuului kuitenkin sataman ravintoloiden terasseilta hieman hiljaisempaa musiikkia, joka puolestaan oli haastavampaa tunnistaa, johtuen mm. muista ympäristöäänistä, sekä vaihtelevista tuuliolosuhteista. Nämä kaksi tilannetta otettiin erikseen myös huomioon evaluoinnissa. Kohteessa tehtiin mittauksia yhteensä 30 päivää ja tästä materiaalista valittiin manuaalisesti kuuntelemalla kumpaankin tapaukseen kuvaavat ääninäytteet. Evaluoinnissa käytettiin yhteensä 45 tuntia äänimateriaalia, josta 15 tuntia valittiin ajalta, jolloin ravintolamusiikki oli mahdollisesti aktiivinen ja 30 tuntia valittiin ajalta, jolloin musiikkifestivaali on käynnissä. Ääninäytteitä valittaessa pidettiin huoli siitä, että puolessa näytteistä oli musiikki kuultavissa.

Piirteinä käytimme 40 ms ikkunoissa laskettuja log-mel –energiaspektrejä (128 melikaistaa). Käyttämässämme CNN-luokittimessa on kaksi konvoloivaa kerrosta, jotka koostuivat konvoluutiokerroksista (32 ja 64 painokerrointa sekä 3×3 konvoluutiokerneli) ja kokoomakerroksesta (max-pooling), sekä yksi täysin kytketty luokitinkerros (MLP-verkko, 50 neuronia), joka tekee luokittelun konvoloivien kerrosten tiivistämän tiedon pohjalta [12]. Luokittelu ja evaluointi tehtiin 10 sekunnin segmenteissä.

Evaluointitulokset on nähtävissä taulukossa 3. Evaluoinnit tehtiin kahdella eri metriikalla: kohteeksi luokitellut kohdeherätteet (True positive rate, TPR), sekä tunnistustarkkuudella. TPR kuvaa miten suuri osa musiikkia sisältäviksi luokiteltujen 10 sekunnin segmenteistä sisältää oikeasti musiikkia. Tunnistustarkuus puolestaa kuvaa miten suuri osa segmenteistä luokiteltiin oikein (musiikki-ei musiikkia). Ravintolamusiikin luokittelu toimi odotetusti hieman huonommin kuin musiikkifestivaalin, mutta saavutettu suorituskyky oli silti melko hyvä. Kun kaikki data käsiteltiin yhdessä ja järjestelmä opetettiin, sekä testattiin kummankin tyyppisellä materiaalilla, suorituskyky oli hyvä. Kun segmentissä tunnistettiin aktiivista musiikkia, oli se lähes 90 % oikea luokittelutulos. Vastaavasti kaikista segmenteistä 86 % luokiteltiin oikein joko musiikkia tai pelkkää taustamelua sisältävaksi.

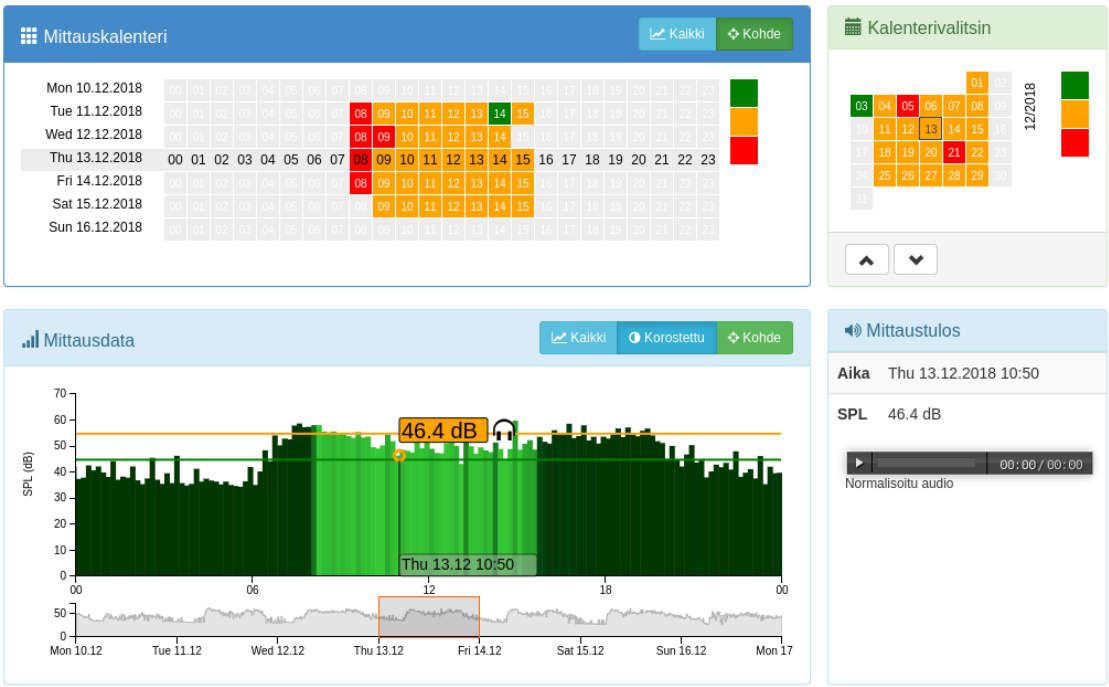

Kuva 5: Esimerkkinäkymä www-käyttöliittymästä. Oikealla, ylemmässä kuvassa on ajankohdan valintamahdollisuus. Vasemmalla ylhäällä näkyy kokonaistilanne kalenterinäkymässä: kunkin päivän ekvivalenttitaso värikoodattuna. Palkkinäyttössä vasemmalla alapuolella esitetään 10 minuutin ekvivalenttitasot siten, että värillä ilmaistaan, kuinka todennäköistä on kyseisen äänen kuuluminen valitulle melunseurantakohteelle. Lisäksi jokainen mittaus on kuunneltavissa (alhaalla oikealla).

Taulukko 3: Tulokset musiikkimelun luokittelijatestistä

Tilanteen kuvaus	TPR	Tunnistustarkkuus
Ravintolamusiikki	81.2	82.5
Musiikkifestivaali	94.0	88.5
Yhdistetty	89.5	86.4

4 DISKUSSIO

Julkiselle paikalle sijoitettu, ääntä tallentava mittalaite tuo mukanaan monia haasteita. EU:n yleinen tietosuoja-asetus 2016/679 (engl. General Data Protection Regulation, GDPR) edellyttää tämän kaltaiselta sovellukselta toiminnasta tiedottamista ja yksityisiltä henkilöiltä kirjallista lupaa heidän hallinnassaan olevalle alueelle sijoitettuna [13]. Julkisella paikalla mittalaitteet joutuvat helposti ilkivallan kohteeksi ja herkkä mikrofoni on vaikeimmin suojattavissa oleva komponentti, sillä kaikenlaiset suojarakenteet muuttavat myös sen vastetta. Pilottikoettamme varten suunnittelimme akustista BEM-mallinnusta hyödyntämällä kotelon, jossa mikrofoni on sijoitettu asennuspinnan lähelle, suojaan kotelon taakse (kuva 3). Mallinnus- ja myöhemmin mittaustulosten mukaan kotelo vääristää eri suunnista saapuvaa tasoaaltoa alle ±3 dB taajuuksilla 50–4000 Hz ja vasteen suoristaminen tehdään tulosten käsittelyn yhteydessä. Sensori asennetaan tasaiselle seinäpinnalle,

tai jos seinä ei ole yhtenäinen, mitoiltaan 0.5 m×0.7 m levyn pinnalle (kuva 4). Ympäristömelun mittausstandardin ISO1996-2:2007 mukaan seinäpinnan tulee olla tasainen (±5 cm) 1 metrin etäisyydelle mikrofonista [4].

Mittauspisteessä tallennetut äänitasolukemat voidaan suodattaa näyttämään ainoastaan valitun kohteen tuottamat äänitaso. Konseptiin kuuluu www-käyttöliittymä, jossa tulokset voidaan esittää lämpökarttakalenterina, graafeina ja taulukoiduin lukuarvoin. Yksi esimerkkinäkymä esitetään kuvassa 5.

Pilotoinnissa kohdatut haasteet liittyvät pääasiassa langattomaan verkkoyhteyteen. Langattomat modeemit, mokkulat, aiheuttavat dataa lähettäessään voimakkaan häiriösignaalin äänitallenteisiin ja koska etäisyydet pienen laitekotelon sisällä ovat millimetrejä, tulisi antenni ja analoginen osuus signaalitiestä suunnitella ja toteuttaa kokonaisuutena häiriöiden välttämiseksi, kuten matkapuhelimissa. Pilotissamme ratkaisimme ongelman rakentamalla modeemille virranohjauksen: modeemista katkaistaan virta pois mittausten ajaksi. Tämä sama ratkaisu auttoi toipumaan myös mobiiliverkon katkoksista, joiden jälkeen modeemi jää usein tilaan, josta se toipuu ainoastaan katkaisemalla virta hetkeksi.

5 YHTEENVETO

Tässä artikkelissa osoitimme, että ympäristömelun monitorointia saadaan helpotettua ja tehostettua käyttämällä automaattista lähteiden luokittelua ja että luokittelun voi siirtää melusensorin tehtäväksi. Kerroimme myös uudenlaisten melusensoreiden toteutuksesta ja niiden pilvipalvelukytkennästä. Melusensori on mahdollista toteuttaa edullisilla komponenteilla, mikä mahdollistaa myös niiden lukumäärän lisäämisen ja lopputuloksena on yksityiskohtaisempi melukartta.

Luottokortin kokoinen Raspberry Pi –tietokone osoittautui riittävän tehokkaaksi automaattiselle lähteiden luokittelulle. Esittelimme akustisen BEM-mallinnuksen avulla suunnitellun ja 3D-tulostetun kotelon, mutta olemme pilotoineet myös aurinkopaneeliversiota, joka mahdollistaa täysin langattoman mittaamisen [5].

Melulähteen aktiivisuus havaittiin binäärisellä luokittelijalla: taustamelu tai melulähde. Akustisina piirteinä käytettiin meli-kepstrikertoimia ja annotoitujen melutallenteiden perusteella opetettuja luokittelijoita olivat GMM sekä ANN-luokittelijat MLP ja CNN.

Testasimme menetelmämme suorituskykyä kohteina kivenmurskaamo- ja musiikkimelu. Suorituskyky osoittautui riittäväksi: kvantitatiivisesti arvioituna, yhden sekunnin aikaresoluutiolla, F-arvo oli parhaalla luokittelijalla kivenmurskaamomelulle 93.8. Järjestelmä toimi 50 päivän ajan kivenmurskaamon lähellä ja luokittelijan tulokset vastasivat oikein hyvin murskaamon päivärytmiä. Musiikkimelu osoittautui haastavammaksi ja paras tunnistustarkkuus, 89 %, saavutettiin musiikkifestivaalin aikaan, jolloin musiikin äänitaso oli merkittävästi muita ympäristön ääniä suurempi. Pilotointi musiikkimelun osalta on jatkunut yli vuoden ajan ja jatkuu edelleen.

Esittelimme myös toteuttamamme pilvipalvelun ja meluportaalin. Melusensorit lähettivät tulokset pilvipalveluun ja tulosten visualisointi, tilastollinen analyysi ja tietojen arkistointi tapahtuivat portaalissa. Tämä lähestymistapa mahdollistaa järjestelmän laajentamisen kokonaisvaltaiseen melunhallintaan ja yksittäisen sensorin edullisuuden vuoksi reaaliai-

kaisen melukartoituksen todellisella, mitatulla datalla. Tätä lähestymistapaa käyttäen, luotettavuus, validiteetti ja ympäristömelun kartoitusten kattavuus lisääntyvät merkittävästi.

VIITTEET

[1] Panu P. Maijala. Excess Attenuation and Meteorological Data in a Long Term Measurement. In *Proceedings of the International Conference on Noise Control Engineering, Tampere, Finland, 30 May – 1 June, (Euronoise 2006)*, number SS20-392 in euro-noise series, page 1–6, Tampere, Finland, May 2006. EAA.

[2] Panu P. Maijala. A Set-up for Long Term Sound Propagation Measurements. In *Proceedings of the International Congress on Noise Control Engineering, Tampere, Finland, 30 May – 1 June, (Euronoise 2006)*, number SS20-390 in euro-noise series, pages 1–6, Tampere, Finland, May 2006. EAA.

[3] Panu P. Maijala. *A Measurement-based Statistical Model to Evaluate Uncertainty in Long-range Noise Assessments*. Doctoral dissertation, Tampere University of Technology, P.O. Box 1000, FI-02044 VTT, Finland, 2013.

[4] ISO. Standard ISO 1996-2:2007. Acoustics — Description, Measurement and Assessment of Environmental Noise — Part 2: Determination of Environmental Noise Levels, 2007.

[5] Panu P. Maijala, Zhao Shuyang, Toni Heittola, and Tuomas Virtanen. Environmental Noise Monitoring Using Source Classification in Sensors. *Applied Acoustics*, 129 (1):258–267, 2018. ISSN 0003-682X. URL `https://doi.org/10.1016/j.apacoust.2017.08.006`.

[6] Michael Noll. Short-Time Spectrum and Cepstrum Techniques for Vocal-Pitch Detection. *"Journal of the Acoustical Society of America"*, pages 296–302, February 1964.

[7] Lawrence Rabiner and Biing-Hwang Juang. *Fundamentals of Speech Recognition*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 1993. ISBN 0-13-015157-2.

[8] Toni Heittola, Annamaria Mesaros, Antti Eronen, and Tuomas Virtanen. Context-dependent sound event detection. *EURASIP Journal on Audio, Speech and Music Processing*, 2013.

[9] Douglas A. Reynolds, Thomas F. Quatieri, and Robert B. Dunn. Speaker verification using adapted gaussian mixture models. In *Digital Signal Processing*, volume 10, pages 19 – 41, 2000.

[10] Simon Haykin. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edition, 1998. ISBN 0132733501.

[11] IEC. Standard IEC 61672-1:2002. Electroacoustics — Sound Level Meters — Part 1: Specifications, May 2002.

[12] Annamaria Mesaros, Toni Heittola, and Tuomas Virtanen. A multi-device dataset for urban acoustic scene classification. In *Proceedings of the Detection and Classi-*