KÄYTTÄJÄKESKEINEN MELULÄHTEIDEN LUOKITTELU TYÖKONEISSA

Marko Antila, Jari Kataja, Lasse Lamula, Heikki Isomoisio ja Seppo Rantala

Teknologian tutkimuskeskus VTT Oy
PL 1300
33101 TAMPERE
etunimi.sukunimi@vtt.fi

Tiivistelmä

Olemme tutkineet tavanomaisen konemelun luokittelun laajennuksena käyttäjäkeskeistä melun luokittelua. Käyttäjäkeskeisessä melun luokittelussa on merkittävää sijainti, jossa melun vaikutusta arvioidaan. Lähestymistapaa on arvioitu tutkimalla kaivoksessa toimivan kallionjyrsintälaitteen melu- ja värähtelyominaisuuksia. Käyttäjäkeskeinen melulähteen luokitusmenetelmä laajentaa tavanomaisia melunluokitusmahdollisuuksia, koska se mahdollistaa yksityiskohtaisemman analyysin. Samoin on mahdollista erottaa merkittävimmät melulähteet automaattisesti. Käyttäjäkeskeinen melulähteiden luokittelu vaatii aikasarjojen käyttöä analyysissä. Saavutettavat hyödyt kompensoivat lisääntyneen tallennustilan tarpeen.

1 JOHDANTO JA TAVOITE

Koneiden tuottaman melun luokittelua (noise ranking) käytetään arvioitaessa sitä, mitkä koneen osat vaikuttavat eniten koneen tuottamaan kokonaismeluun [1]–[3]. Olemme tutkineet tällaisen tavanomaisen melun luokittelun laajennuksena käyttäjäkeskeistä melun luokittelua [4]–[6].

Tutkimuskohteina ovat olleet sekä melun psykoakustinen arviointi, että melulähteiden tunnistaminen niiden piirteiden perusteella. Tavanomaisen melunluokittelumenetelmän tapaan tunnistetaan merkittävimmät melulähteet ja arvioidaan niiden yhteisvaikutus. Merkittävyyttä arvioidaan äänen laadun perusteella [7].

Käyttäjäkeskeisessä melun luokittelussa on merkittävää myös sijainti, jossa melun vaikutusta arvioidaan. Sijainti tai sijainnit valitaan yleensä niiksi paikoiksi, joissa koneen käyttäjä tai muut melulle altistuvat työntekijät ovat.

© 2019 Marko Antila, Jari Kataja, Lasse Lamula, Heikki Isomoisio ja Seppo Rantala. 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. MX650 kovaa kiveä jyrsivä kaivoskone (valokuva Sandvik Itävalta).

2 TUTKIMUSKOHDE JA SEN TOIMINTA

Tutkimuskohteena on ollut scheeliittikaivoksessa (wolframimalmi) toimiva kiveä jyrsivä koekone MX650 (kuva 1). Koneen periaatteena on jyrsiä malmi suoraan malmisuonesta, ilman erillistä porausta, panostusta, räjäytystä ja kivimurskan poistoa. Toimintaperiaatteesta johtuen kone on erittäin meluinen, ja myös värähtelytasot nousevat korkeiksi.

Koneesta mitattiin sen tuottama melu sekä värähtely. Melu mitattiin yhtäaikaisesti useassa mittauspisteessä. Mittauspisteet valittiin siten, että ne ovat todennäköisimmissä paikoissa, joissa koneen käyttäjät altistuvat melulle. Mittausdata analysoitiin sekä tavallisin menetelmin, että käyttäen psykoakustisia menetelmiä, tässä tapauksessa äänekkyyttä.

Tyypilliset mittaukset ja niiden analyysi on esitetty kuvassa 2. Vaaka-akselilla on aika, ja pystyakseleilla spektrogrammi (ylempi kuva), äänekkyys- sekä huipputasot (keskimmäinen kuva), sekä värähtelyt (alin kuva). Spektrogrammi näyttää tasot värikarttana 4 kHz asti. Keskimmäinen kuva koostuu sekä äänekkyyskäyrästä [8] (sininen käyrä ja vasen asteikko) ja A-painotetusta fast-aikaikkunan äänitasokäyrästä (punainen käyrä ja oikea asteikko, $L_{p\mathrm{AF}}$). Tässä tapauksessa nämä kaksi eri käyrää eivät eroa merkittävästi toisistaan. Joissain tapauksissa erot voivat olla kuitenkin merkittäviä. Alin kuvaaja edustaa istuen tai seisten kehoon kohdistuvaa tärinää.

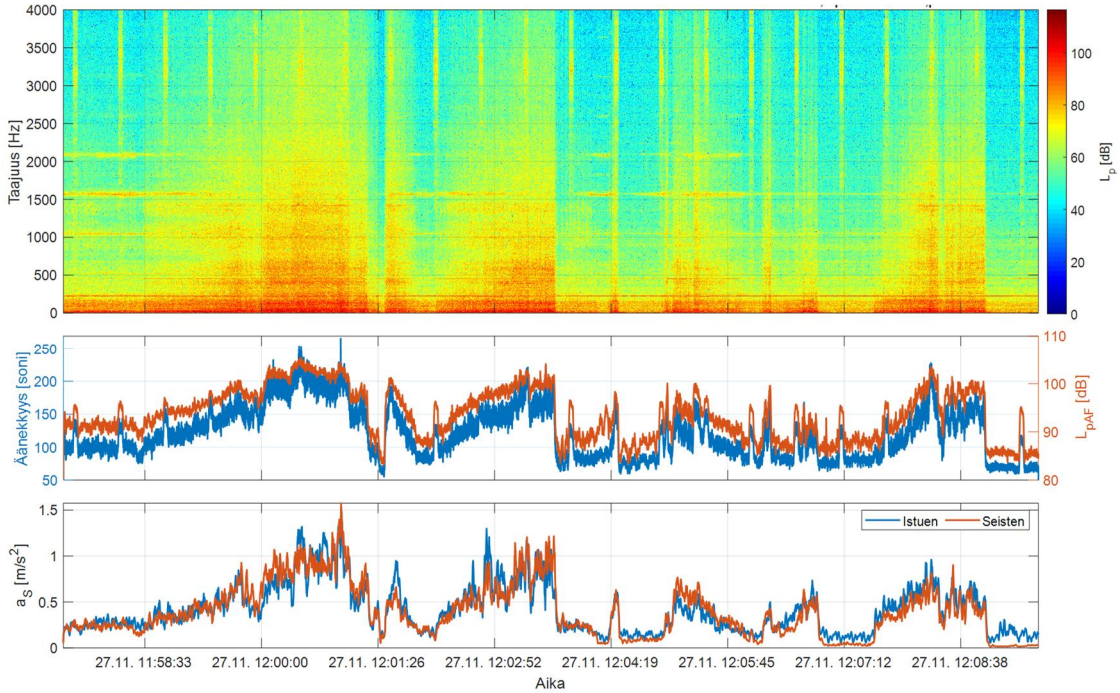

Kuva 2. Esimerkki MX650 tuottamasta äänestä ja värähtelystä yhdellä työtekijän pisteellä. Kuvassa ylimpänä spektrogrammi, keskellä äänekkyys soneina (sinisellä) ja äänitaso L_{pAF} (punaisella). Alimpana ovat värähtelytason sekä seisten että istuen. Äänekkäimmät osuudet edustavat jyrsintää.

3 MELUN LUOKITTELU

Kuten kuvasta 2 havaittiin, melu koostuu selvästi useasta erilaisesta osamelulähteestä. Jotta melun lähteitä pystyttäisiin tehokkaasti vaimentamaan, on tarpeen pystyä tunnistamaan ja luokittelemaan eri melulähteet. Melun lähteitä ei voi koneen toimiessa normaalisti eristää erillisiksi lähteiksi. Siksi tarvittiin erityisiä luokittelumenetelmiä, jotka pystyisivät tekemään luokittelun mitatusta yhdistelmämelusta. Luokittelumenetelmien opettamista varten tehtiin koneen joistakin erillisistä äänilähteistä mittaukset komponenteittain. Lisäksi, koska haluttiin arvioida melua nimenomaan psykoakustisista lähtökohdista, etsittiin menetelmiä, jotka toimisivat aikatason signaaleille.

On olemassa useita luokittelumenetelmiä, joita voidaan soveltaa myös kone- ja laitemeluun. Niihin kuuluvat Independent Component Analysis (ICA) [9], [10], Principal Component Analysis (PCA) [11], ja useita Deep Learning (DL) kategorioita [12]. ICA ja PCA kuuluvat Blind Source Separation (BSS) -menetelmiin. Se tarkoittaa, että niitä käytettäessä ei ole muuta aikaisempaa tietoa niiden lähteestä. Sekä lähteet että siirtofunktiot ovat tuntemattomia. Comon & Jutten ovat tehneet BSS-menetelmien laajan arvioinnin [13].

Jotta pystytään erottelemaan eri lähteiden vaikutus tilanteessa, jossa on useita äänilähteitä, mittauksiin sovitetaan malli. Mallilla luokittelemme signaalilähteet eri luokkiin. Tässä tutkimuksessa mallinnukseen on käytetty neuroverkon rakennetta, jossa on useita välikerroksia. Useimmiten kun puhutaan Deep Learning menetelmistä, niin silloin tarkoitetaan juuri sellaista rakennetta, jossa neuroverkon rakenteessa on useita välikerroksia. Käyttämässämme mallissa on sekä perinteisiä täysin kytkettyä että 2D konvoluutiokerroksia.

Tutkimuksen ensimmäisessä vaiheessa mitattiin erikseen eri äänilähteitä samanaikaisesti sekä binaural- että tarkkuusmikrofonilla. Taulukossa 1 on esitetty mitatut äänilähteet ja niiden indeksit, joita käytetään kuvissa 3 - 5.

Luokittelun syöttötietoina ovat edellä mainituista aikasarjoista estimoidut autoregressiiviset spektrit. Koska äänilähteet olivat epästationäärisiä ja koska halusimme saada luokitteluun riittävästi opetusainestoa, aikasarjat jaettiin 0,6 sekunnin lohkoihin, joiden kokonaismääräksi tuli 659 kappaletta. Koska käytössä oli kolme erillistä mittausta, jokaisesta lohkosta saatiin kolme spektriä. Mallin rakentaminen aloitetaan valitsemalla satunnaisesti opetusnäytteet.

Taulukko 1 Mitatut äänilähteet ja niiden indeksit.

Luokan indeksi	Pulttaajan paikka vasemmalla	Luokan indeksi	Pulttaajan paikka oikealla
1	Hydraulipumput (2 yksikköä)	7	Pumput (+jäähdytys)
2	Jyrsinterän moottorit	8	Jyrsinterän moottorit (+jäähdytys)
3	Hihnakuljetin ilman kiviä	9	Hihnakuljetin
4	Porauskompressori - akku täynnä	10	Kompressori
5	Pumput kuormitettuina	11	Pumput kuormitettuina
6	Pölynpoisto (kaukaa)		

Kuvassa 3 on opetusnäytteiden määrä 100 kappaletta. Verifioidessa mallia havaittiin, että luokittelun osuvuus oli 94%. Luokissa 3 ja 9 oli eniten vääriä tuloksia. Molemmat ovat aikasarjoja hihnakuljettimista, joiden spektreissä on vähän diskreettejä taajuuksia. Jos opetusmäärä tuplataan saadaan parempi tulos kuten kuvasta 4 nähdään.

Koska opetusaineiston määrä on suuri (~30%) kokonaismäärään suhteutettuna, voidaan epäillä, että malli on sovittanut liian hyvin opetusaineistoon eikä ole pystynyt yleistämään. Tällöin sen jatkokäyttö on hyödytöntä. Opetusnäytteiden määrää voidaan lisätä esimerkiksi laskemalla spektrit lomittamalla. Tästä esimerkkinä on kuvassa 5 esitetty tapaus, jossa lohkojen kokonaismäärä on 2625 ja opetusnäytteiden määrää on 400, joka tarkoittaa noin 15% opetusnäytettä kokonaisuudesta. Luokitus on erittäin hyvä. Ainoastaan muutama lohko on väärin. Nämäkin tapaukset ovat enimmäkseen hihnakuljettimista.

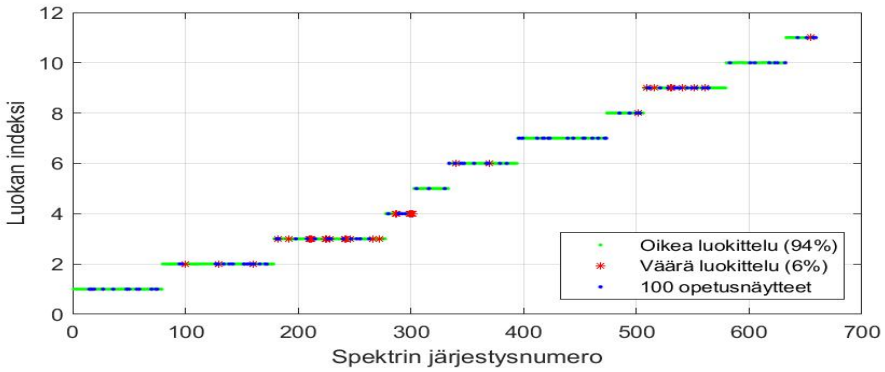

Kuva 3. Luokittelutulokset 100 opetusnäytteellä.

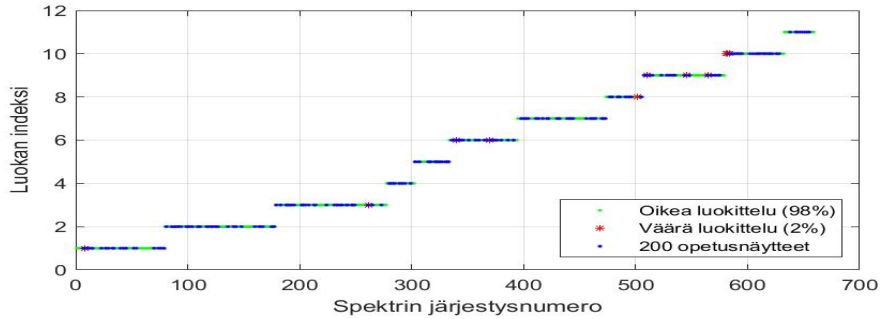

Kuva 4. Luokittelutulokset 200 opetusnäytteellä.

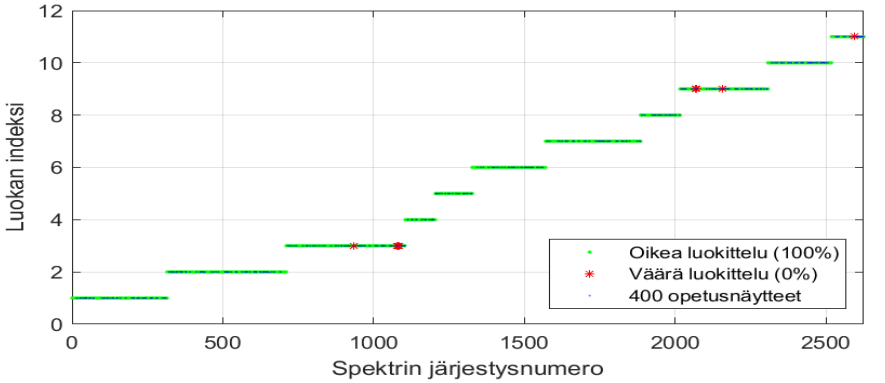

Kuva 5 . Luokittelutulokset 400 opetusnäytteellä 2625 lohkosta .

4 ÄÄNEN LAADUN ARVIOINTI

Kuvassa 6 on esitetty harhaton häiritsevyys (unbiased annoyance, UBA) ja A-painotetut ekvivalenttitasot. Analyysi on tehty kahdelle erilaiselle melutyypille, jyrsinnälle (punaiset pisteet) ja poraamiselle (vihreät pisteet). Myös ohjaamon sisällä tehdyt mittaukset ovat kuvassa (siniset pisteet). Mustat suorat edustavat referenssisignaaleja. Ne ovat häiritsevimmästä vähiten häiritsevään tasajakautunut peittoääni (uniform masking noise), valkoinen kohina ja 1 kHz äänes.

Jyrsintämelu ohjaamossa on jonkin verran suurempi kuin ohjaamon ulkopuolella. Tämä johtuu todennäköisesti impulssimaisista voimista, jotka aiheuttavat räminää ja kitinää ohjaamossa. Tämä taas nostaa vaihteluvoimakkuuden (fluctuation strength) tasoa. Ohjaamon ulkopuolella melutaso on korkeampi, mutta vaihteluvoimakkuus pienempi. Siksi UBA antaa tulokseksi pienemmän häiritsevyyden, kun tasot säädetään ekvivalenttitasoiksi.

Vaikka jyrsintä aiheuttaakin lähtökohtaisesti impulssimaista melua kalliota leikkaavien jyrsinterien rakenteen takia, niin häiritsevyys lisääntyy UBA:n mukaan ainoastaan noin1 dB äänitasossa arvioituna. Ohjaamon sisällä korjaus on 2 dB tai hieman yli.

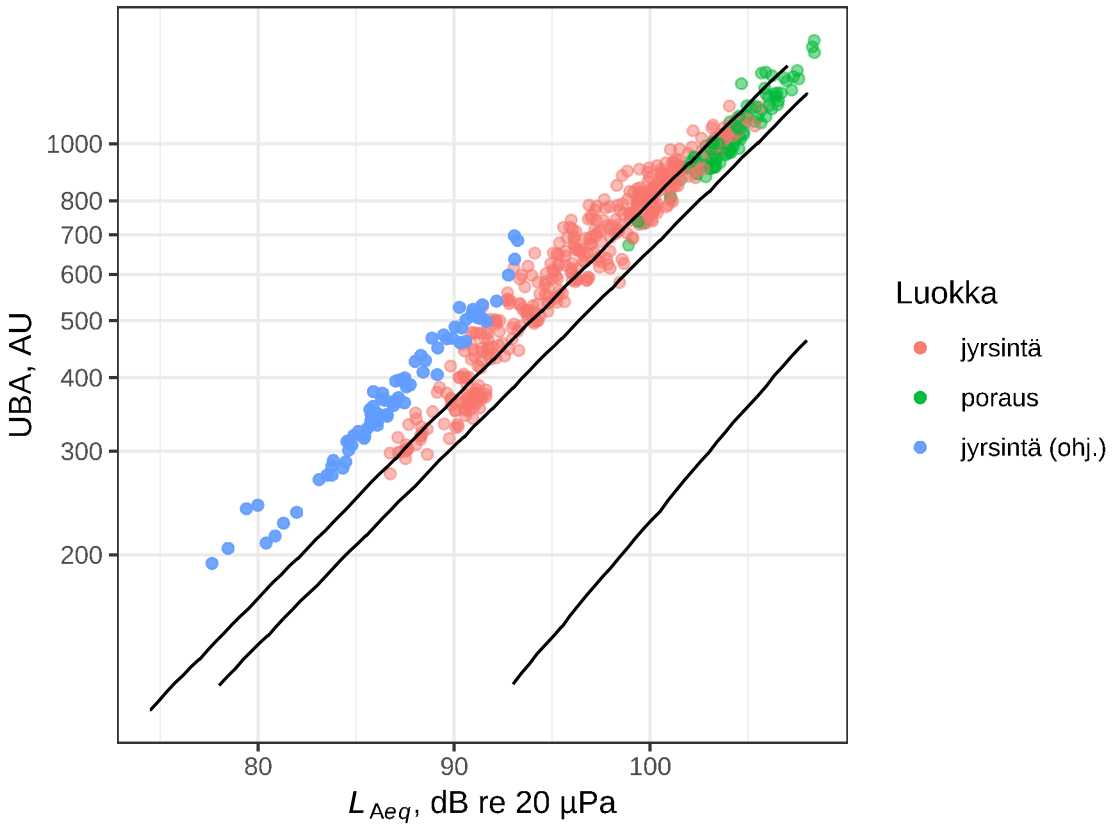

Kuva 6. Kolmen melukategorian harhaton häiritsevyys (unbiased annoyance).

5 YHTEENVETO

Käyttäjäkeskeistä melun luokittelua on arvioitu tutkimalla kaivoksessa toimivan kallionjyrsintälaitteen melu- ja värähtelyominaisuuksia. Tuloksena on ollut, että käyttäjäkeskeinen melulähteen luokitusmenetelmä laajentaa tavanomaisia melunluokitusmahdollisuuksia, koska se mahdollistaa yksityiskohtaisemman analyysin. Samoin on mahdollista erottaa merkittävimmät melulähteet automaattisesti. Toisaalta käyttäjäkeskeinen melulähteiden luokittelu rajoittaa käytettäviä analysointimenetelmiä. Käytetyt psykoakustiset analyysimenetelmät vaativat äänenpaineen hankkimisen aikasarjana. Tämä luo uusia vaatimuksia tiedonkeruu- ja analyysimenetelmille. Nykytekniikka mahdollistaa kuitenkin pitkienkin aikasarjojen tallennuksien, ja saavutettavat hyödyt kompensoivat lisääntyneen tallennustilan tarpeen.

KIITOKSET

Kiitokset RockVader EIT Raw Materials -hankkeelle (RockVader - Smart Hard Rock Mining System project, EIT RM projekti 16136) työn rahoituksesta, sekä erityiskiitos Sandvik Itävallalle.

VIITTEET

[1]J. W. Verheij, “Inverse and Reciprocity Methods for Machinery Noise Source Characterization and Sound Path Quantification Part 1: Sources,” *Int. J. Acoust. Vib.*, vol. 2, no. 1, pp. 11–20, 1997.

[2]G. Shu and X. Liang, “Mechanical Systems and Signal Processing Identification of complex diesel engine noise sources based on coherent power spectrum analysis,” *Mech. Syst. Signal Process.*, vol. 21, pp. 405–416, 2007.

[3]D. Fernandez Comesana, A. Grosso, H.-E. De Bree, J. Wind, and K. Holland, “Further Development of Velocity-based Airborne TPA: Scan & Paint TPA as a Fast Tool for Sound Source Ranking,” SAE, Jun. 2012.

[4]M. Antila, L. Lamula, J. Kataja, H. Isomoisio, and S. Rantala, “User centric noise source ranking,” in *Euronoise 2018*, 2018, pp. 869–876.

[5]M. Antila *et al.*, “Machinery noise source identification with deep learning,” in *Proceedings of Internoise 2019*, 2019.

[6]M. Antila, H. Isomoisio, J. Kataja, and J. Heikkilä, “Psychoacoustic Evaluation of Rock Crushing Plant Noise,” in *Proc. of Euronoise 2015*, 2015.

[7]E. Carletti and F. Pedrielli, “From Noise Levels to Sound Quality: The Successful Approach to Improve the Acoustic Comfort,” .

[8]K. H. Lee, “Perception of tones in machinery noise and its influence on annoyance,” 2006.

[9]A. Hyvärinen and E. Oja, “Independent Component Analysis: Algorithms and Applications,” *Neural Netw.*, vol. 13, no. 4–5, pp. 411–430, May 2000.

[10]G. R. Naik, “An overview of independent component analysis and its applications,” *Inform.*, vol. 35, no. 1, pp. 63–81, 2011.

[11]J. Shlens, “A Tutorial on Principal Component Analysis,” Apr. 2014.

[12]Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015.

[13]P. Comon and C. Jutten, *Handbook of Blind Source Separation Independent Component Analysis and Applications*. Elsevier, 2010.