

MOI Hub – vAI:lla tuottavuutta: Pilotointi Skaala IFN Oy:n tuotannossa

Sahanterän kunnonvalvonnan kokeilu matalakustannuksisella IoT- ja analytiikkaratkaisulla

Raportin laatija:

Antti Martikkala, Tampereen yliopisto (MOI Hub)

Teemu Virtanen, Seinäjoen ammattikorkeakoulu (vAI:lla tuottavuutta)

Osallistuvat hankkeet:

- **MOI Hub – Seinäjoki Multidisciplinary Open IoT Hub**
(Tampereen yliopisto, Etelä-Pohjanmaan EAKR-alue)
- **vAI:lla tuottavuutta – Älykkäiden teknologioiden hyödyntäminen pk-yrityksissä**
(SeAMK, Euroopan aluekehitysrahasto)

Kohdeyritys:

Skaala IFN Oy

Y-tunnus: 2656258-9

Toteutusaika:

2.12.2024 – 14.3.2025

Dokumentin päivämäärä:

15.5.2025

Yhteenveto:

Tässä pilotissa kehitettiin ja testattiin matalakustannuksinen IoT-järjestelmä ja koneoppimiseen perustuva analytiikkaratkaisu sahanterän kunnonvalvontaan. Tavoitteena oli tutkia, voidaanko tärinäsignaalista ennakoida terän kulumista tuotantoympäristössä ja rakentaa pohjaa tulevalle kunnossapidon digitalisaatiolle.



**Euroopan unionin
osarahoittama**



Seinäjoki

innokaupungit

1. Tausta ja tavoitteet

Tuotantokoneiden kunnonvalvonta perustuu monissa teollisuusympäristöissä yhä pitkälti henkilöstön kokemukseen, havaintoihin ja arvioon. Esimerkiksi sahanterän kulumista arvioidaan kuulon ja leikkuujäljen perusteella. Tällainen subjektiivinen arviointi toimii kokeneiden työntekijöiden käsissä, mutta siihen liittyy vaihtelua, epämääräisyyttä, sekä riski liian myöhään tai varmuuden vuoksi tehtyihin huoltotoimiin.

Tässä pilotissa tavoitteena oli kehittää ja testata sahanterän kunnonvalvontaan soveltuvaa matalakustannuksista IoT-ratkaisua käytännön tuotantoympäristössä. Kohdeyritys Skaala IFN Oy oli kiinnostunut mahdollisuudesta tunnistaa automaattisesti terän vaihtokunnon lähestyminen, mikä mahdollistaisi kunnossapidon suunnittelun aiempaa tarkemmin ja resurssitehokkaammin.

Pilotissa yhdistettiin kaksi alueellista kehityshanketta:

- **MOI Hub:** keskittyi anturipohjaiseen datankeruuseen ja tekniseen toteutukseen,
- **vAl:lla tuottavuutta:** vastasi kerätyn datan analysoinnista ja koneoppimisen hyödyntämisestä.

Yhteistyön tavoitteena oli selvittää, voidaanko sahan toiminnasta kerättävän tärinätiedon perusteella ennakoida terän kulumista ja löytää mittaustietoon perustuva vaihtokriteeri. Tämä loisi perustan myöhemmälle jatkokehitykselle, jossa terän kunnonvalvonta voitaisiin automatisoida osaksi tuotantolinjaa.

MOI Hub -projektin näkökulmasta pilotin tavoitteena oli tuoda matalakustannuksinen IoT-teknologia osaksi käytännön teollista ympäristöä ja testata sen soveltuvuutta konekunnan etämittaamiseen. Erityistä painoarvoa annettiin laiteratkaisun kustannustehokkuudelle, asennettavuudelle ja mahdollisuudelle hyödyntää avoimia alustoja (esim. Node-RED, InfluxDB). Lisäksi projektissa haluttiin testata pilvipohjaista infrastruktuuria datan keruuseen ja tarkasteluun siten, että se on toistettavissa ja sovellettavissa myös muissa tuotantopisteissä.

vAl:lla tuottavuutta -projektin tavoitteena oli puolestaan hyödyntää tekoälypohjaisia analyysimenetelmiä, jotka tukevat pk-yrityksiä tuotantonsa tehokkuuden kehittämisessä. Tässä tapauksessa pyrittiin selvittämään, voidaanko sahanterän tärinätiedosta tunnistaa kulumisen merkkejä ja rakentaa tietoon perustuva päätöksenteon tuki terän vaihtotarpeen arviointiin. Tarkoituksena ei ollut luoda valmista järjestelmää, vaan tunnistaa potentiaali ja mallintaa ensimmäinen analyysiputki tulevaa kehitystä varten.

Roolijako

Pilotin toteutuksessa vastuut jaettiin selkeästi kahden projektin kesken, siten että kumpikin osapuoli keskittyi omaan osaamisalueeseensa. MOI Hub vastasi teknisestä toteutuksesta, mukaan lukien anturilaitteiston suunnittelu, asentaminen ja datan kerääminen tuotantoympäristöstä. Lisäksi MOI Hub ylläpiti pilvipohjaista infrastruktuuria, joka mahdollisti datan siirron, tallennuksen ja visualisoinnin reaaliaikaisesti.

vAl:lla tuottavuutta -hankkeen rooli painottui datan analyysiin ja tulkintaan. Hanke vastaanotti MOI Hubin tuottaman mittausedatan, yhdisti siihen manuaalisesti kerätyn metadatan (terän vaihtotiedot) ja toteutti analyysin, jossa pyrittiin tunnistamaan yhteyksiä koneen värinäprofiiliin ja terän kunnan välillä. Tavoitteena oli tuottaa analyysituloksia, joiden perusteella voidaan jatkossa arvioida terän vaihtotarve objektiivisesti mittausedatan perusteella.

Yhteistyö toteutettiin siten, että ratkaisut olivat toistettavissa ja sovellettavissa myös muissa vastaavissa käyttökohteissa. Roolijaon ansiosta eri näkökulmat – tekninen toteutus ja datalähtöinen analyysi – saatiin yhdistettyä yhtenäiseksi kokeiluksi.

2. Tekninen toteutus: Sensorointi ja datankeruu (MOI Hub)

Sahanterän kunnonvalvontaa varten toteutettiin matalakustannuksinen sensoriratkaisu, joka perustui kolmiakseliseen kiihtyvyyssanturiin. Anturiyksikkö oli kotelossa, joka mahdollisti laitteen kiinnittämisen tuotantokäytössä olevan sahan kylkeen. Kotelointi mahdollisti mekaanisesti vakaan mittauspisteen joka pystyy keräämään sahan rungosta tärinää.

Mittaus toteutettiin laitteistolla, joka keräsi kiihtyvyyssdataa 400 Hz:n näytteenottotaajuudella. Mittauslogiikka perustui liukuvaan puskuriin (ring buffer), jonka avulla anturidataa kerättiin 30 sekunnin ajan kerrallaan. Tämän jälkeen data pakattiin JSON-muotoon ja lähetettiin HTTP POST -pyynnöllä langattoman verkon kautta MOI Hubin pilvipalvelimeen. Laitteisto siirtyi tämän jälkeen 10 minuutin lepotilaan, minkä jälkeen seuraava mittausjakso käynnistyi automaattisesti.


Datan vastaanotto tapahtui MOI Hubin pilvi-infrastruktuurissa, joka koostui Node-RED-alustasta, InfluxDB-aikajonotietokannasta ja Grafana-visualisointityökalusta. Data tallennettiin tietokantaan yksittäisinä riveinä, sisältäen aikaleiman ja kolmiakselisen kiihtyvyyden arvot (x, y, z). Sensorilta, jonka tunniste oli 94ff, kerättiin mittausdataa noin neljän viikon ajan ajanjaksolla **17.2.2025–14.3.2025**. Yksittäinen mittausjakso tuotti keskimäärin noin 12 000 riviä kiihtyvyyssdataa per akseli (yhteensä n. 36 000 arvoa per jakso).

Aikaleimat tallentuivat tietokantaan millisekunnin tarkkuudella, mikä ei riitä erottamaan 400 Hz:n mittausjakson yksittäisiä näytteitä (~2,5 ms välein). Tämän seurauksena aikaleimat pyörivät ja osa näytteistä saa väärän kellonajan, mikä näkyy ns. ajoituksellisena jitterinä(huojuntana). Itse mittausprosessi on tasainen, mutta tallennusresoluution vuoksi näytteenottovälit näyttäytyvät hieman epätasaisina. Tästä huolimatta data oli analyysitarkoituksiin riittävän laadukasta. Mutta tämä on syytä huomioida tulevaisuuden toteutuksissa.

Mittausdataan yhdistettiin manuaalisesti kirjattua metadataa sahan terän vaihtotapahtumista, jotka sisälsivät päivämäärän ja kellonajan. Tämä yhdistetty aineisto vietiin analyysiä varten CSV-muodossa vAl:lla tuottavuutta -hankkeen käyttöön. Alkuvaiheessa tiedostot tuotettiin Grafana-ympäristön ja InfluxDB:n Chronograf-käyttöliittymän avulla, mutta myöhemmin päädyttiin käyttämään erillistä Python-skriptiä, jolla aineisto voitiin tuottaa hallitummin ja tarkemmin.

Alustava data-analyysi ja tulkinta

Ensimmäinen vaihe analyysissä oli visuaalinen tarkastelu (Kuva 1) mittausdatan aikakäyttäytymisestä. Erityisesti **Y-akselin kiihtyvyyssdatassa** havaittiin selkeästi sinimuotoista värähtelyä. Värähtely ei ollut yksittäinen tasajaksoinen siniaalto, vaan signaalissa oli havaittavissa **modulointua käyttäytymistä**, jossa korkeamman taajuuden värähtely (n. 100 Hz) esiintyi vaihtelevan amplitudin sisällä. Tämä viittaa siihen, että signaaliin vaikuttaa samanaikaisesti useita eri taajuuksia tuottavia mekaanisia tai prosessilähtöisiä tekijöitä.



Kuva 1. Esimerkki kerätystä aikatason jaksosta.


Tarkennettu visualisointi osoitti, että yksittäisen mittausjakson aikana esiintyi nopeaa sinimuotoista värähtelyä, mutta sen **amplitudi vaihteli jaksollisesti** muutaman sekunnin jaksoissa. Nämä hitaammat vaihtelut eivät välttämättä muodosta itsenäistä matalataajuisia värähtelyä vaan vastaavat **amplitudimodulaatiota**, jossa koneen toiminnasta johtuvat kuormitusvaihtelut muokkaavat värähtelyn voimakkuutta ajassa. Tällaista käyttäytymistä voi aiheuttaa esimerkiksi **nivelakselin epätasapaino, syöttömekanismin rytminen toiminta** tai leikkuuprosessin vaihtelu.

Tuotantoympäristössä käytössä olevan sahan voimansiirtoon kuuluu nivelakseli, jonka mekaaniset ominaisuudet – kuten väly, kohdistus tai kuluminen – voivat aiheuttaa jaksottaista värähtelyä, joka näkyisi mittausdatassa nimenomaan modulaationa, ei itsenäisenä sinimuotoisena komponenttina.

Signaalista suoritettiin myös Fourier-muunnos (FFT), jonka tulokset vahvistivat visuaaliset havainnot. Taajuusspektrissä (Kuva 2) oli nähtävissä useita piikkejä, joista merkittävimmät sijaitsivat noin:

- **~50 Hz:** mahdollinen sähköverkkokomponentti tai moottorin pyörimisnopeuteen liittyvä aliääni.
- **~100 Hz:** todennäköinen päävärähtelykomponentti, joka liittyy sahan pyöriin osiin, kuten teriin tai voimansiirtoon.
- **~150 Hz ja ~200 Hz:** mahdollisia harmonisia komponentteja tai toisen terän aiheuttamia taajuuksia, mikäli ylä- ja alaterä pyörivät hieman eri nopeudella.
- **alle 2 Hz:** matalataajuisia piirteitä, jotka todennäköisesti kuvastavat amplitudimodulaatiota tai kahden taajuuden välistä interferenssiä (ns. taajuuslyönti-ilmiö).

Huomio 50 Hz -komponentista: 50 Hz on Euroopassa standardi sähköverkon taajuus, ja se voi esiintyä mittausdatan taajuusspektrissä sähköverkkohäiriönä tai verkkosähkön aiheuttamana induktiona. Toisaalta 50 Hz voi myös liittyä mekaanisiin ilmiöihin, kuten moottorin pyörimisnopeuteen tai jonkin muun koneen osan, kuten toisen sahanterän, toimintaan – etenkin jos eri terät pyörivät hieman eri nopeuksilla. Ilman lisämittauksia tai referenssitaajuuksia ei voida varmuudella osoittaa, onko kyseessä häiriö vai mekaaninen lähde, minkä vuoksi 50 Hz -komponentti tulkitaan tässä alustavasti avoimesti.



Kuva 2. Fourier-muunnos yhdestä mittausjaksosta (sensorin Y-akseli).

Datan perusteella voidaan todeta, että mitattu signaali sisältää rakenteellisesti jaksollisia piirteitä, jotka toistuvat eri mittausjaksoissa. **Tämä viittaa siihen, että mittausjärjestelmä kykenee havaitsemaan mekaanisia muutoksia koneen toiminnassa.** Tarkempi analyysi viittaa lisäksi siihen, että signaalissa saattaa esiintyä kaksi lähekkäistä sinimuotoista komponenttia, joiden välinen vaihe vaihtelee ajan myötä. Tämä ilmiö voi johtua kahdesta erillisestä värähtelylähteestä – esimerkiksi sahan ylä- ja alaterästä, jos ne pyörivät hieman eri nopeuksilla – tai yhdestä leveäkaistaisesta lähteestä, jonka spektri jakautuu eri taajuusalueille analyysissa. Nykyisen aineiston perusteella ilmiön tarkkaa alkuperää ei voida yksiselitteisesti vahvistaa, mutta se tarjoaa jatkotutkimukselle kiinnostavan lähtökohdan.

Vaikka tässä vaiheessa ei ole tehty koneoppimiseen perustuvaa luokittelua tai tilastollista mallinnusta, voidaan alustavasti arvioida seuraavaa:

- signaalin rakenne on monimuotoinen ja potentiaalisesti informatiivinen.
- taajuuskomponenttien muutoksia (amplitudi, sijainti, leveys) voidaan hyödyntää koneen kunnon arviointiin.
- data sisältää piirteitä, joiden perusteella terän kulumista voitaisiin arvioida jatkokehityksen avulla.

Jatkoanalyysissä tullaan yhdistämään värähtelysignaalin aikataso- ja taajuuspiirteet manuaalisesti kirjattuihin terän vaihtotapahtumiin. Tämän avulla pyritään testaamaan hypoteesia, jonka mukaan värähtelysignaalin rakenteessa esiintyisi systemaattisia muutoksia terän kulumisen tai vaurion lähestyessä.

3. Data-analyysi ja tulkinta (vAI:lla tuottavuutta)

3.1 Analyysin tavoite ja lähtökohdat

Analyysin tavoitteena oli selvittää, voidaanko sahan toimintaa kuvaavasta värähtelydatasta päätellä terän kunnon heikkenemistä ennen varsinaista vaihtoa. Tällä hetkellä teränvaihto perustuu pääosin käyttäjän aistinvaraiseen arvioon leikkuujäljestä ja kuormitusäänestä, mikä voi johtaa joko liian aikaisiin tai myöhäisiin toimenpiteisiin. Automaattisesti mitattavan ja tulkittavan datan hyödyntäminen voisi tukea päätöksentekoa tarjoamalla objektiivista lisätietoa kunnossapidon ajoitukseen.

Lähtökohtana oli MOI Hub -projektin toteuttama anturiperusteinen värähtelydatan keräys, joka kattoi usean viikon mittausjakson tuotantokäytössä olevan koneen rungosta. Datan mittaustaajuus oli noin 400 Hz, ja mittaukset toteutettiin 30 sekunnin jaksoina noin 10 minuutin välein. Aineisto sisälsi myös manuaalisesti kirjatut teränvaihtotapahtumat, jotka mahdollistivat mallin opettamisen tunnistamaan käyttötilanteet, joissa terän kuluminen oli edennyt vaihtoa vaativaksi.

Analyysi toteutettiin osana vAI:lla tuottavuutta -projektia. Tavoitteena ei ollut kehittää valmista päätöksenteon työkalua, vaan rakentaa ensimmäinen mallinnusketju ja testata koneoppimisen soveltuvuutta värähtelydatan tulkintaan. Tärkeänä tavoitteena oli myös arvioida, kuinka luotettavaa ja informatiivista nykyinen mittausdata on, ja mitkä ovat keskeiset kehityskohdat jatkoa ajatellen.

3.2 Analyysin toteutusvaiheet

Analyysissa hyödynnettiin MOI Hub -projektin tuottamaa kiihtyvyydataa, joka oli kerätty kolmessa suunnassa (X, Y, Z) sahan rungosta. Data jaettiin minuutin mittaisiin jaksoihin, joista muodostettiin koneoppimismallin tarvitsemat syöteominaisuudet. Yksi mittausjakso sisälsi useita tällaisia minuutin alijaksoja, joiden avulla signaalin ajallinen kehittyminen saatiin kuvattua vaiheittain.

Jokaisesta minuutin ikkunasta laskettiin seuraavat ominaisuudet erikseen kullekin mittaussuunnalle:

- **Keskiarvo, keskihajonta, minimi- ja maksimiarvo**
- **Havaintojen lukumäärä**, jolla varmistettiin mittausjakson luotettavuus

Näiden perusominaisuuksien lisäksi muodostettiin ns. **viivepiirteitä**, jotka kuvasivat aiempien aikajaksojen arvoja, sekä **muutosnopeuksia**, joiden avulla voitiin tunnistaa signaalin dynamiikkaa. Lisäksi käytettiin **aikapiirteitä**, kuten kellonaikaa ja viikonpäivää, jotka voivat selittää tuotantoon liittyvää rytmiä.

Koneoppimisen kohdeluokka (target) muodostettiin manuaalisesti kirjatusta **teränvaihtotapahtumista**, jotka kohdistettiin aikatasolle minuutin tarkkuudella. Näiden avulla luotiin binäärinen tavoitemuuttuja, jossa 1 merkitsi “terä vaihdettu lähiaikoina” ja 0 “ei vaihtoa”.

Varsinaisena mallina käytettiin **Random Forest Classifier** -algoritmia. Se valittiin analyysiin sen vakiintuneen käytön ja tulkittavuuden vuoksi. Malli koulutettiin erikseen valitulla opetusjaksolla ja testattiin erillisellä, myöhemmällä ajanjaksolla. Ennusteet tuotettiin todennäköisyyksinä, ja tulkintaa varten määritettiin kiinteä kynnsarvo, jonka ylittyessä mallin katsottiin ennustavan vaihtotarpeen.

3.3 Tulokset ja mallin toiminta

Koulutettu malli testattiin erillisellä datajaksolla, johon sisältyi useita todellisia teränvaihtoja. Ennusteet tuotettiin minuuttitasolla siten, että jokaiselle aikajaksolle laskettiin todennäköisyys sille, että teränvaihtotarve on lähellä. Kun ennustettu todennäköisyys ylitti ennalta asetetun kynnsarvon, tilanne tulkittiin varoitukseksi tai ehdotukseksi vaihtotarpeesta.

Testijaksolla malli kykeni tunnistamaan noin kolmanneksen todellisista teränvaihtoista. Samalla se antoi useita ylimääräisiä signaaleja tilanteissa, joissa vaihtoa ei ollut kirjattu. Tämä viittaa

siihen, että malli tunnisti tiettyjä signaalipiirteitä johdonmukaisesti, mutta tarkkuus ei vielä riittänyt luotettavaan käyttöön yksinään.

Suorituskykyä arvioitiin seuraavien mittarien avulla:


- **Herkkyys (Recall): 0.36**
→ Malli tunnisti 36 % todellisista vaihtotapahtumista
- **Tarkkuus (Precision): 0.31**
→ Ennusteista 31 % osui todelliseen vaihtotapahtumaan
- **F1-score: 0.33**
→ Yhdistää recallin ja precisionin yhteen mittariin

Tämä suorituskyky on odotettu ottaen huomioon rajallinen määrä teränvaihtotapahtumia ja mahdollinen epävarmuus vaihtojen ajoituksessa. Tulokset osoittavat kuitenkin, että mallin tuottamat signaalit eivät ole satunnaisia, vaan ne seuraavat selvästi mitattavissa olevia piirteitä tärinädatassa.

Seuraavassa osiossa tarkastellaan mallin toimintaa yksityiskohtaisemmin visuaalisella tasolla.

3.4 Visualisointi ja mallin käyttäytyminen

Mallin käyttäytymistä tarkasteltiin myös visuaalisesti, jotta voitiin arvioida, missä määrin ennusteet asettuivat loogisesti suhteessa värähtelysignaaliin ja toteutuneisiin teränvaihtoihin. Alla olevassa kuvassa (Kuva 3) on esitetty kolmen kiihtyvyyssakselin keskihajonta (vasen asteikko) sekä mallin tuottama vaihtotodennäköisyys (violetti viiva, oikea asteikko) testijakson ajalta.



Kuva 3. Kiihtyvyyden keskihajonta (XYZ), mallin ennustama vaihtotodennäköisyys, sekä toteutuneet (punaiset katkoviivat) ja ennustetut (mustat viivat) teränvaihdot.

Kuvasta havaitaan, että mallin ennusteet kasautuvat ajankohtiin, joissa Y-akselin tärinän keskihajonta kasvaa selvästi. Joissain tapauksissa mallin antama todennäköisyys alkaa nousta

useita minuutteja ennen todellista vaihtoa, mikä tukee oletusta siitä, että koneen tärinän rakenne muuttuu jo ennen kuin vaihtotarve havaitaan käyttäjän toimesta.

Samalla nähdään, että mallilla esiintyy ennusteita myös ajanjaksoina, jolloin vaihtoa ei tapahtunut. Näiden “väärien positiivisten” taustalla voi olla kaksi mahdollista selitystä:

1. **Mittaustietoon perustuva varhainen merkki**, joka ei vielä johtanut vaihtopäätökseen.
2. **Kohdeluokan epävarmuus**, eli vaihtotapahtuman ajoitus ei ole kirjautunut tarkasti suhteessa mittausjaksoihin.

Visuaalinen tarkastelu vahvistaa käsitystä siitä, että signaalissa on toistuvaa rakennetta, jonka perusteella malli kykenee reagoimaan. Erityisesti Y-akselin tärinä on osoittautunut diagnostisesti merkittäväksi komponentiksi, ja sen vaihtelun liittäminen muihin mittareihin voisi parantaa tarkkuutta jatkossa.

4. Yhteenveto ja jatkokehityksen mahdollisuudet

Pilotin tavoitteena oli testata matalakustannuksisen IoT-teknologian ja tekoälypohjaisen analyysin yhdistämistä teollisessa tuotantoympäristössä. Kohdeyrityksenä toimineella Skaala IFN Oy:llä oli tarve kehittää teränvaihtojen ajoitusta kohti mitattuun tietoon perustuvaa toimintamallia. Tällä hetkellä vaihtopäätökset perustuvat pääosin käyttäjien kokemukseen ja aistinvaraisiin havaintoihin, mikä altistaa prosessin vaihtelulle ja voi johtaa joko liian aikaisiin tai viivästyneisiin toimenpiteisiin.

MOI Hub -projektin osuudessa toteutettiin anturiperusteinen datankeruujärjestelmä, joka osoitti kykenevänsä tuottamaan analyysiin soveltuvaa värähtelydataa tuotantoympäristöstä. Kerätty data kattoi usean viikon mittausjakson, ja siihen yhdistettiin manuaalisesti kirjatut teränvaihtotiedot.

vAI:lla tuottavuutta -projektissa testattiin koneoppimismenetelmää (Random Forest), jonka tavoitteena oli tunnistaa tärinädatan perusteella vaihtotarpeen ennusmerkkejä. Vaikka mallin suorituskyky ei vielä ollut tuotantokäyttöön riittävä, se kykeni tunnistamaan osan vaihtotapahtumista ennakoivasti. Analyysi osoitti, että erityisesti tärinän keskihajonta sisältää toistuvaa rakennetta, jonka yhteys terän kulumiseen vaikuttaa lupaavalta – mutta ei vielä varmistetulta.

Keskeiset havainnot voidaan tiivistää seuraavasti:

- Sensoridata sisältää toistuvia, mahdollisesti diagnostisia piirteitä, mutta sen riittävyys terän kunnan arviointiin edellyttää jatkovalidointia.
- Alustava koneoppimismalli osoitti suuntaa-antavaa ennustekykä, mutta vaatii lisäaineistoa ja tarkempia kohdetietoja kehittyäkseen käyttökelpoiseksi työkaluksi.
- Manuaalinen metadata (teränvaihdot) on kriittinen osa mallin koulutusta ja vaatii jatkossa tarkempaa ja ajallisesti täsmällisempää kirjaamista.

Jatkokehityksen kannalta keskeisiä toimenpiteitä ovat:

- Mittausaikajakson laajentaminen ja vaihtotapahtumien systemaattinen kirjaaminen.

- Mallin yhdistäminen muihin tuotantodatan lähteisiin (esim. kuormitus, tehonkulutus, tuotantonopeus).
- Mahdollisuus siirtyä reaaliaikaiseen analytiikkaan ja varoitusjärjestelmään.
- Soveltuvuuden arviointi muihin konetyyppeihin tai tuotantopisteisiin.

Pilotin tulokset osoittavat, että tärinään perustuva konekunnan seuranta on teknisesti mahdollista, ja sen analysointi koneoppimisen avulla tarjoaa potentiaalin kehittää objektiivista tukitietoa kunnossapitoon. Kuitenkin – ennen käyttöönottoa – tarvitaan lisää validointia ja ymmärrystä siitä, mitä signaalissa todella mitataan ja kuinka yksikäsitteisesti se liittyy terän kulumiseen.