



TEKNILLINEN TIEDEKUNTA

Barkhausen-kohinamittaus ja hiontapalamiset

Mio-Ilari Säkkinen

TUTKINTO-OHJELMA

Kandidaatintyö

maaliskuu 2023

TIIVISTELMÄ

Barkhausen-kohinamittaus ja hiontapalamiset

Mio-Ilari Säkkinen

Oulun yliopisto, Prosessitekniikan kandidaatin tutkinto-ohjelma

Kandidaatintyö 2023, 39 s.

Työn ohjaaja yliopistolla: Aki Sorsa

Hiontapalaminen on teollisuudessa merkittävä ongelma. Hiontapalamisessa kappaleen pinnassa vaikuttavat jännitykset kääntyvät kappaletta vahvistavista puristavista jännityksistä vetojännityksiksi. Tämän lisäksi kappaleen mikrokovuus alenee. Hiontapalamista voidaan mitata monella tapaa. Näistä yksi yleisesti käytössä oleva menetelmä on Barkhausen-kohinamittaus.

Tässä kandidaatintyössä käydään läpi Barkhausen-kohinamittauksen hyödyntämistä hiontapalamisten havaitsemisessa, arvioinnissa ja luokittelussa. Tämän lisäksi luotiin kolmeen luokkaan jaetun BN-mittausdatan pohjalta luokittelumalli sekä päätöksentekopuun että logistisen regression avulla. Tällä pyrittiin vastaamaan siihen, toimiiko tässä tilanteessa kaksivaiheinen luokittelu paremmin kuin yhtäaikainen luokittelu. Mallien toimintaa arvioitiin sekaannusmatriisien avulla käyttäen holdout-ristivalidointia. Tämän lisäksi luotiin esimerkkimalli koko dataa käyttäen.

Mallit suoriutuivat luokittelusta hyvin. Päätöksentekopuumallin keskimääräiset tarkkuudet opetusdatalle ja testausdatalle olivat 97,40 % ja 89,82 %. Merkittäviä eroja tässä työssä muodostettujen mallien ja kirjallisuudessa esitetyn mallin välillä ei ollut. Kumpikaan malli ei luokitellut testausdatan luokkaa 3 kovin hyvin. Mallien käyttäytymisestä huomattiin, että luokkien 1 ja 2 erottelussa mallit käyttivät lähinnä BN-mittauksen RMS-arvon muutosta. Luokan 2 ja 3 erotus taas tapahtui piikin sijainnin avulla. Mallit todettiin melko toimiviksi ja luotettaviksi. Näin osoitettiin taas eri asteisten hiontapalamisten luokittelun onnistuvan BN:n piirteiden avulla.

Asiasanat: Barkhausen-kohina, Hiontapalaminen, Luokittelumalli

ABSTRACT

Barkhausen Noise Measurement and Grinding Burns

Mio-Ilari Säkkinen

University of Oulu, Bachelor's Degree of Process Engineering

Bachelor's thesis 2023, 39 pp.

Supervisor at the university: Aki Sorsa

Grinding burn is major problem in industry. In grinding burn, residual stresses in surface region of the object, turn from reinforcing compressive stresses to tensile stresses. In addition, surfaces micro hardness decreases. Grinding burns can be measured in many ways. One of those methods is a nondestructive method that uses magnetic Barkhausen noise (BN), Barkhausen noise measurement.

In this bachelor's thesis Barkhausen noise measurement usage for detection, validation and classification of grinding burns was investigated. Grinding burn classification models were created with logistic regression and with decision tree for BN data separated into 3 categories. Models were made to answer if two phase classification works better in this situation than simultaneous classification.

Classification models performed well. For example, decision trees average performance for teaching data and validation data was 97,40% and 89,82%. Big differences between the models and model of Santa-Aho et al. (2023) were not found. No model could predict testing data's class 3 well. This was probably because of the small number of class 3 data points. Interesting behaviour of the models was found. The distinction between class 1 and class 2 was made almost completely using the RMS value and distinction between class 2 and class 3 was made almost completely using the peak position of Barkhausen profile. The models were quite good and reliable, so it was shown again that grinding burn classification can be done with Barkhausen noise features.

Keywords: Barkhausen Noise, Grinding Burn, Classification

SISÄLLYSLUETTELO

TIIVISTELMÄ	2
ABSTRACT	3
SISÄLLYSLUETTELO.....	4
MERKINNÄT JA LYHENTEET	5
1 Johdanto	5
2 Hiontapalamiset.....	6
2.1 Yleisesti	6
2.2 Materiaalin ominaisuudet ja hiontapalaminen.....	7
2.3 Hiontapalamisen määrittäminen	7
3 Barkhausen-kohinamittaus	9
3.1 Kappale muuttuvassa magneettikentässä	9
3.2 Barkhausen-kohina	10
3.3 Mittaus ja ominaisuudet	10
3.4 Barkhausen-kohinamittaus ja hiontapalamiset	13
4 Luokittelumallit.....	19
4.1 Yleisesti	19
4.2 Logistinen regressio.....	19
4.3 Päätöksentekopuu	20
4.4 Validointi ja datan jakaminen.....	21
5 Data ja mallinnus.....	23
5.1 Käytetty aineisto	23
5.2 Logistinen regression.....	23
5.3 Päätöksentekopuu	24
5.4 Mallinnustulosten arviointi.....	24
6 Tulokset.....	25
6.1 Logistinen regressio.....	25
6.2 Päätöksentekopuu	27
7 Tulosten tarkastelu	29
7.1 Mallien suorituskyky	29
7.2 Tulosten luotettavuus.....	32
8 Johtopäätökset	34
9 Yhteenvedo	36
LÄHDELUETTELO	37

MERKINNÄT JA LYHENTEET

BN	Barkhausen-kohina (engl. Barkhausen noise)
BP	Barkhausen-profiili
FWHM	full width at half maximum
RMS	Root mean square
RS	jäännösjännitys (engl. residual stress)

1 JOHDANTO

Kovien ja suurta dimensionaalista tarkkuutta vaativien teräskappaleiden kysyntää riittää erilaisiin hammaspyöriin ja laakereihin. Dimensionaalisen tarkkuuden ja oikean pintakarheuden saavuttamiseksi tulee kappaleet viimeistellä hiomalla. Hionnan epäonnistuessa voi syntyä hiontapalamista, joka heikentää kappaleen kriittisiä ominaisuuksia, kuten väsymisen kestoa. Jotta kovien teräskappaleiden laatuvaatimukset täyttyvät, hiontapalamista tulee pystyä mittaamaan ja arvioimaan, ja yksi tärkeä mittaamenetelmä on Barkhausen-kohinamittaus. Tämän työn tavoitteena on käydä läpi pieni osa viimeaikaista kirjallisuutta Barkhausen-kohinamittauksen hyödyntämisestä hiontapalamisten havaitsemisessa, arvioinnissa ja luokittelussa. Barkhausen-kohinan käyttöä yleisemmin ei käydä läpi. Tärkeimpänä osana työssä pyritään luomaan hiontapalamisdatan pohjalta kaksi erillistä luokittelumallia, jotka luokittelisivat hiontapalamisen vakavuutensa perusteella kolmeen luokkaan. Tarkoituksena on saada vahvistusta siihen, että voiko hiontapalamisen vakavuutta luokitella BN-mittauksen piirteiden perusteella. Lisäksi selvitetään, onko Santa-Ahon et al. (2023) jatkotutkimusta varten ehdottama luokittelu, jossa erotetaan ensin luokka 1 muista, ja sitten erotetaan luokat 2 ja 3 toisistaan, parempi lähestymistapa kuin Santa-Ahon yhtäaikainen luokittelu. Tässä työssä luodaan tätä varten luokittelumalli ensin 2-vaiheisena logistisen regression avulla ja sitten vertailua varten päätöksentekopuun avulla. Luokittelumallien tuloksia arvioidaan ja vertaillaan sekä keskenään että Santa-Ahon et al. (2023) tuloksiin.

2 HIONTAPALAMISET

2.1 Yleisesti

Hionta on mekaanista työstöä, jossa kappaleen dimensioita pienennetään hyödyntämällä hiottavaa materiaalia kovemmissa partikkeleista koostuvaa kuluttavaa pintaa eli hiomalaikkaa. Hiontaa pidetään yhtenä avainmetodeista, kun prosessoitavalle kappaleelle pyritään saavuttamaan oikea mittatarkkuus ja oikeanlainen pintakarheus (He et al., 2019). Hionnassa prosessoitavan pintakerroksen poiston ohella tuotetaan myös suuri määrä kitkavoimien aikaansaavaa lämpöä. Malkin & Guo:n (2007) mukaan perinteisillä hiomalaikalla tehtävässä pintahionnassa n. 60–85 % hiomiseen kuluva energiasta siirtyy hiottavaan kappaleeseen lämpönä.

Mietittäessä hionnan vaikutuksia kappaleeseen, täytyy huomioida prosessoitava materiaali. Esimerkiksi puuta hioessa voi tapahtua mustumista ja palamista, muovit voivat sulaa ja metalleille on omat vaikutuksensa. Tässä kandityössä keskitytäänkin ferromagneettisten karkaistujen terässeosten pintahiontaan.

Suurta kovuutta vaativia teräskappaleita tarvitaan vihreän siirtymän seurauksena esimerkiksi tuulivoimaloiden laakereissa (Neslušan et al. 2017) ja teollisuuden hammaspyörissä. Kyseisen teollisuuden yhteiskunnallisen kriittisyyden sekä suurten investointien vuoksi on erittäin tärkeää, että valmistettavien teräskappaleiden lujuusvaatimukset täyttyvät. Toisaalta tuottavuuden parantamiseksi prosessin hiontavaihe suoritetaan usein kappaleiden termisen kestävyuden rajalla (Sackmann et al. 2020).

Kun prosessoitavan kappaleen lämpötila, joka on vaikeasti ennustettava monien prosessimuuttujien vuoksi, kasvaa yli kappaleen päästölämpötilan (engl. tempering temperature), voi hionta-alueella esiintyä hiontapalamista. Tällöin kappaleen mikrorakenne muuttuu niin, että kappaleen ominaisuudet, kuten lujuus, muokattavuus, kovuus sekä lämpökäsittelyllä aikaansaadut puristusjäännösjännitykset heikkenevät (Santa-Aho et al. 2012). Hiontapalamiseen vaikuttavia hionnan parametreja ovat mm. materiaalin poistonopeus hionnassa (engl. material removal rate), hiottava materiaali, hiova materiaali eli hiomalaikka, hiomalaikan kuluminen ja tukkeutuminen sekä jäähdytysneste ja sen virtausnopeus.

2.2 Materiaalin ominaisuudet ja hiontapalaminen

Malkin & Guo (2007) käyvät artikkelissaan läpi muutamia hiontapalamisen vaikutuksia työstettävään kappaleeseen. Ilmeisimpänä on joskus silmämääräisessä tarkastelussa havaittava sinertävä/mustunut väri, joka kertoo kappaleen pinnan hapettumisesta. Pinnan värimuutoksilla on Malkinin ja Guon mukaan kuitenkin vaikeasti tulkittava yhteys kappaleen lujuusominaisuuksiin. Lämmön vaikutuksena kappaleen pinta voi alkaa myös päästymään (engl. tempering/softening) eli kappaleen pintakerrosten kovuus laskee. Päästyessään kappaleen kova hiilipitoinen martensiittinen faasi pehmenee. Lämpötilan kohotessa yhä alkaa karkenemislämpötilassa tapahtua myös pinnan uudelleen karkeneminen (engl. rehardening). Vaikka pintakerros kovenee eli sinne syntyy uusi martensiittirakenne faasimuutoksen takia, kappaleen pinnanalaiset (engl. sub-surface) osat ovat edelleen päästyneitä. Hiontapalamisen siis voi todeta olevan yhteydessä kappaleen kovuuden heikkenemiseen, ja rajussa hiontapalamisessa myös pintakerroksen uudelleenkarvenemiseen. (Malkin & Guo, 2007)

Malkin & Guo:n (2007) mukaan toinen hiontapalamisen aiheuttama tärkeä muutos kappaleessa on jäännösjännityksien (engl. residual stress) (RS) muutokset. Puristusjäännösjännitykset parantavat kappaleen väsymisominaisuuksia, mutta hiontapalamisen yhteydessä kappaleen pinnanalaisiin kerroksiin muodostuu vastakkaisuuntaisia vetojäännösjännityksiä, joilla on haitallinen vaikutus juuri esim. kappaleen väsymisominaisuuksiin. Heikentyneet jäännösjännitykset aiheutuvat hionnassa kappaleeseen muodostuvan lämpötilagradientin, lämpölaajenemisen sekä epähomogeenisen plastisen muodonmuutoksen (engl. non uniform plastic deformation) seurauksena. (Malkin & Guo, 2007)

2.3 Hiontapalamisen määrittäminen

Yllä mainitussa tuottavuuden ja laatuvaatimusten välisessä dilemmassa auttaa laadun valvonta ja mittaaminen. Käytännössä mitä tarkemmin tiedetään missä menee hiontapalamisen raja sitä lähemmäksi rajaa voidaan mennä, ja tätä kautta lisätä tehoja tuotannossa laadun kärsimättä. Teräskappaleiden ominaisuuksia, ja siten myös hiontapalamisen vakavuutta, voidaan mitata monella tapaa. He et al. (2019) kertovat, kuinka mittausmenetelmät voidaan jakaa kahteen luokkaan: ainetta rikkoviin

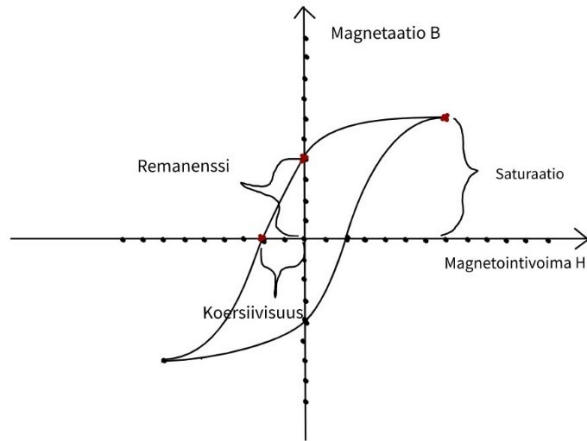
menetelmiin (engl. destructive detection methods) ja ainetta rikkomattomiin menetelmiin (engl. nondestructive detection methods). Ainetta rikkoviin menetelmiin kuuluu esimerkiksi Nital-etsaus-menetelmä (engl. Nital etching). Nital on typpihapon ja alkoholin seos, joka syövyttää teräksen eri faaseja ja mikrorakennetta eri tavalla. Tämä näkyy teräskappaleessa pinnan Nital-käsittelyn jälkeen eri väreinä. On olemassa ISO-standardi Nital-etsauksen hyödyntämiseen hiontapalamisen arvioinnissa. Siitä huolimatta menetelmänä se on hankalasti toteutettava, subjektiivinen, ja komponentteja ei voi ottaa käyttöön tarkastuksen jälkeen. Toisena ainetta rikkovana menetelmänä on pinnan mikrokovuusmittaukset (engl. surface microhardness testing). (He et al. 2019)

Ainetta rikkomattomiin menetelmiin taas kuuluu esimerkiksi paljon käytetyt röntgendifraktiomenetelmä (engl. x-ray diffraction) (XRD). XRD-mittauksessa kappaleen kidehilarakenne saadaan selville säteilyttämällä kappaletta röntgensäteillä eri kulmista, ja näin löydetään tietyille aallonpituudelle ja kulmille interferenssikuvio. Braggin lakia hyödyntäen saadaan selville, kuinka kaukana kidehilan eri atomitasot ovat toisistaan. Hiontapalamisen aiheuttamia jäännösjännityksiä arvioidaan yleisesti XRD-menetelmällä, sillä kidehilan rakenne ja kappaleeseen kohdistuvat jännitykset/jäännösjännitykset ovat suoraan yhteydessä toisiinsa (He et al. 2019). Tämän lisäksi XRD-kuvaajan diffraktiopiikin leveys piikin puolella välissä (XRD FWHM, engl. full width at half maximum) on todettu kasvavan materiaalin kovuuden kasvaessa (Santaho & yliopisto, 2012). XRD-menetelmässä käytetään röntgensäteitä, joihin liittyy tiettyjä turvallisuustekijöitä, jotka täytyy ottaa huomioon tehtaassa tehtävässä laadunvalvontatyössä. XRD-mittaus on lisäksi haastava monimutkaisille muodoille, kuten hammasrattaille. Siksi laadunarviointiin kehitetään myös muita menetelmiä. Eräs, tässä työssä tarkasteltava, ainetta rikkomaton menetelmä on Barkhausen-kohinanmittaus.

3 BARKHAUSEN-KOHINAMITTAUS

3.1 Kappale muuttuvassa magneettikentässä

Ferromagneettiset kappaleet koostuvat pienistä magneettisista alueista, joita kutsutaan magneettisiksi domeeneiksi (engl. magnetic domain). Tavallisessa magnetoitumattomassa kappaleessa magneettiset domeenit ovat kappaleen sisällä suuntautuneet esimerkiksi kiderakenteen vuoksi eri suuntiin niin, että kappaleen kokonaismagneettisuus on 0. Kun ferromagneettinen kappale saatetaan voimistuvaan ulkoiseen magneettikenttään, kappaleen sisällä olevat ulkoisen magneettikentän suuntaa mukailevat domeenit alkavat kasvaa huomomin suuntautuneiden domeenien kustannuksella. Ulkoisen magneettikentän voimakkuuden kasvaessa kappale saavuttaa lopulta saturaatiopisteensä, jossa kappaleen magneettiset domeenit ovat täysin ulkoisen magneettikentän mukaisia. Kun tästä lähdetään laskemaan ulkoisen magneettikentän voimakkuutta, ferromagneettiseen kappaleeseen jää vielä osa magneettisuudesta. Saturaatiopisteen jälkeen ilman ulkoista magneettikenttää kappaleeseen jäävää magneettisuutta kutsutaan remanenssiksi (engl. remanence). Kasvattamalla taas ulkoista magneettikenttää vastakkaiseen suuntaan saadaan jäännösmagneettisuus häviämään ja toisen suuntainen magneettisuus kasvamaan saturaatiopisteensä. Tarvittavaa ulkoisen magneettikentän voimakkuutta, jolla remanenssi saadaan häviämään kokonaan, kutsutaan koersiivisuudeksi (engl. coercivity). Kun magnetoidaan kappaletta vuoroin vastakkaisiin suuntiin, saadaan piirrettyä kuvaaja kappaleen magnetisaation ja ulkoisen magneettikentän voimakkuuden suhteen. Tätä kuvaajaa kutsutaan hystereesisilmukaksi (engl. hysteresis loop), Kuvassa 1 havainnollistetaan hystereesisilmukkaa, sekä remanenssia ja koersiivisuutta. (Santa-aho & yliopisto, 2012)



Kuva 1. Esimerkkikuvaaja hystereesisilmukasta.

3.2 Barkhausen-kohina

Ferromagneettisen kappaleen magnetisaatio ei ole tasaista, vaan se tapahtuu pienin hyppäyksin. Magnetoitumisen epätasaisuus johtuu esimerkiksi kappaleen kiderakenteen poikkeamista ja materiaalissa olevista epäpuhtauksista. Magneettisten domeenien väliseinät (engl. domain walls) tarttuvat rakenteen epäjatkuvuuksiin kiinni ja ”repeävät” irti vasta tietyn suuruisen ulkoisen magneettikentän vaikutuksesta. Tätä porrasmaista, äänenäkin usein havainnollistettua, magnetoitumista kutsutaan Barkhausen-kohinaksi (engl. Barkhausen noise) (BN). (Santa-aho & yliopisto, 2012)

3.3 Mittaus ja ominaisuudet


Barkhausen-kohinamittaus eli BN-mittaus tapahtuu kohdistamalla ferromagneettiseen kappaleeseen hallitusti tietyllä taajuudella muuttuva magneettikenttä, ja mittaamalla sensorilla kappaleen magneettisuuden vaihtelut. Nykyään lähinnä Stresstech Oy ja 3MA valmistavat BN:ää hyödyntäviä mittalaitteita. Mittaus tuottaa kuvan 2 mukaista signaalia, jossa nähdään useampi magnetointisykli. Yhden magnetointisyklin aikana syntyy kaksi amplitudipiikkiä, joista toinen tulee nousevalle ja toinen laskevalle magneettikentälle. BN-mittauksesta voidaan laskea paljon eri piirteitä. Esimerkiksi (Sorsa 2013) sai BN-signaalista 241 piirrettä, joista käytti piirteiden valinnan (engl. feature selection) alussa 72 eri piirrettä. Tässä kandidaatin työssä käydään läpi vain työssä käytettävissä olevat

BN-mittauksesta saadut piirteet, ja niiden laskeminen raakadatasta. Osa BN-tutkimuksessa hyödynnettävistä piirteistä saadaan suoraan kohinasignaalista, osa saadaan Barkhausen-hystereesisilmukasta, joka vastaa lähes täysin yllä kuvattua magnetoinnissa saatavaa hystereesisilmukkaa. Osa taas saadaan esille kohinasignaalin esikäsittelyllä. Ensimmäisenä BN-signaalista poistetaan osittaiset magnetointisyklit signaalin alusta ja lopusta (Sorsa et al. 2012). Yleisin BN-signaalista laskettava piirre on Barkhausen-kohinan aktiivisuutta kuvaava RMS-arvo (engl. root mean squared). RMS-arvo lasketaan kaavalla

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}, \quad (1)$$

missä n on yhteenlaskettavien signaaliarvojen lukumäärä ja x_i on signaaliarvojen amplitudi.

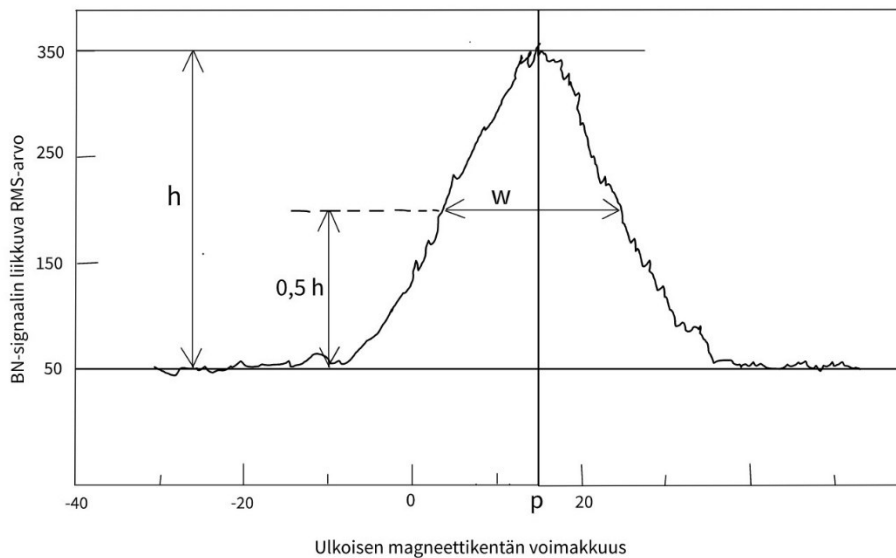
RMS-arvo lasketaan useammasta magnetointisyklistä keskiarvona, jotta magnetointisyklien välinen stokastinen vaihtelu olisi merkityksetön.



Kuva 2. Tyypillistä Barkhausen-kohinamittaussignaalia.

Liukuva RMS-arvo taas saadaan, kun lasketaan useampi RMS-arvo vastaamaan tiettyä ulkoisen magneettikentän voimakkuutta. Esimerkiksi Sorsa et al. (2012) laskivat liukuvan RMS-arvon kymmenen peräkkäisen BN-signaalin datapisteen amplitudien arvoista. Jotta liukuvasta RMS-arvosta saadaan ns. Barkhausen-profiili (engl. Barkhausen profile, BP), Sorsa et al. (2012) käyttivät esikäsittelyssään viisi kokonaista magnetointisykliä, eli

kymmentä erillistä RMS-profiilia, joista laskettiin jokaista magnetointivoimakkuutta vastaava keskiarvo. Vastakkaisuuntaiset magnetointisyklin osat tuli lisäksi kääntää samansuuntaisiksi. Esikäsittelyn lopputuloksena saatiin kuvan 3 mukainen Barkhausen-profiili, jossa y-akselilla on liukuva RMS-arvo ja x-akselilla ulkoisen magneettikentän voimakkuus.



Kuva 3. Esimerkki Barkhausen-profiilista. Mukailten (Sorsa et al. 2012).

BP:sta voidaan lukea useita ominaisuuksia. Piikin korkeus (engl. peak height) (h) nähdään BP:n maksimiarvon ja perustason arvon muutoksesta [mV]. Kuvassa 3 piikin korkeus on 300 mV. Piikin sijainti (engl. peak position) on ulkoisen magneettikentän arvo, jolla liukuva RMS-arvo on maksimissa. FWHM (engl. Full Width at Half Maximum) on BP:n leveys puoleessa välissä BP:n korkeutta.

BN-mittauksessa koersiivisuus ja remanenssi taas lasketaan Barkhausen-hystereesisilmukasta. Integraalin pinta-ala saadaan laskemalla nimensä mukaisesti BN-mittauksen integraalin pinta-ala. Pulssien määrä (engl. pulse count) lasketaan myös suoraan BN-mittaussignaalista, ja spektrin pinta-ala BN-mittauksen tehospektrin (engl. spectral density) pinta-alasta.

3.4 Barkhausen-kohinamittaus ja hiontapalamiset

Jo vuodelta 1987 löytyy mainintaa BN-mittauksen hyödyntämisestä hiontapalamisten arvioinnissa (Tiitto & Pro, 1987). Kuitenkin suurempi määrä aihetta käsitteleviä artikkeleita löytyy 2011 vuodesta lähtien. Tässä työssä käsitellään spesifisesti BN-mittauksen käyttöä hiontapalamisten arviointiin ja ennustamiseen ja siitäkin kirjallisuudesta läpi käydään vain osa.

Ceurter et al. (2002) vertailivat BN-mittausta ja Nital-etsausta toisiinsa menetelmänä hammaspyörrien hiontapalamisen arviointiin. BN-menetelmä oli silloin vielä verrattain uusi, mutta artikkelissa kerrottiin kuitenkin objektiivisesti todistettavasta yhteydestä BN:stä lasketun RMS-arvon sekä kovuuden ja jäännösjännitysten (RS) välillä. Kun RMS-arvo kasvoi, RS:t muuttuivat puristavista vetojännitysten suuntaan ja mikrokovuus laski. BN-mittausmenetelmä todettiin Nital-etsausta paremmaksi vaihtoehdoksi ympäristöystävällisyyden sekä teollisuuden säästämisen ajan ja rahan näkökulmasta. Siitä, missä hammaspyörän osassa RMS-arvot olivat koholla, voitiin päätellä myös jotain hiontapalamisen aiheuttajasta. Esimerkiksi jos RMS-arvo oli koholla vain hammaspyörän hampaitten toisella puolen, johtui hiontapalaminen epäonnistuneesta hammaspyörän hionnan kohdistuksesta eli hampaan molempia puolia ei hiottu tasaisesti.

Karpuschewski et al. (2011) taas tutkivat BN-mittauksen RMS-arvoa eri hionnan materiaalinpoistonopeuksilla. Tutkittavana materiaalina oli pintakarkaistuja 20 MnCr5 teräksestä valmistettuja planeettahammaspyörä. BN:stä laskettiin ainoastaan RMS-arvo. RS-arvoja mitattiin XRD-menetelmällä ja mikrokovuus määritettiin XRD-mittauksen martensiittiipikin FWHM-arvosta. Tutkimuksessa nähtiin sama selvä korrelaatio suurempien hionnan materiaalinpoistonopeuksien sekä RMS-arvon ja hiontapalamisen välillä. Lisäksi tehtiin Nital-etsaus, vertailtiin sitä BN-mittaukseen ja todettiin BN-mittauksen olevan sekä objektiivisempi, tarkempi että ympäristöystävällisempi menetelmä, jonka teollinen käyttöönotto tosin vaatii investointeja esimerkiksi eri referenssien luomiseksi.

Santa-Aho et al. (2012) tutkivat mahdollisuuksia luoda keinotekoisesti BN-mittaukseen kalibrointipalasia. Tutkittava teräs oli pintakarkaistua hammaspyöräterästä 18CrNiMo7-6 (EN 10084). Tutkittavat menetelmät olivat induktiokuumennus sekä kuumennus

laserilla. Kappaleista mitattiin BN:n RMS-arvon lisäksi myös Barkhausen-profiilin piikin korkeus sekä piikin sijainti. Mittaustaajuutena käytettiin 125 Hz ja magnetointijännitteenä 4,3 V (jännite piikistä piikkiin). Hiontapalamisen kanssa suuresti korreloivat RS:t sekä kovuudet taas mitattiin XRD-menetelmällä ja Duramin-300-kovuusmittarilla. Analyysissä nähtiin, että laserilla käsitellyissä kappaleissa saatiin hyvin näkymään piikin sijainnin korrelointi pinnan kovuuden kanssa sekä RS:n korrelointi RMS-arvojen kanssa. Tutkimuksessa todettiin laser-käsittelyn olevan parempi menetelmä keinotekoisien hiontapalamisten luomisessa, ja kyseiseen tilanteeseen optimaaliseksi laserkäsittelyn parametreiksi löydettiin 950–1000 W laserin voimakkuus ja 5–9 mm/s laserin kulkunopeus (engl. traverse rate), sillä näin voitiin välttää uudelleen karkeneminen sekä BN:n ja RS:n suhteen saturoituminen.

Sorsa et al. (2012) tutkivat RS:n ja kovuuden ennustamista BN-mittauksesta saatujen eri ominaisuuksien avulla. Tutkimus rakentui seuraavasti. Pintakarkaistusta teräksestä 18CrNiMo7-6 (EN 10084) valmistettuja tutkittavia kappaleita oli kahta joukkoa. Ensimmäinen joukko valmistettiin tavallisesti pintakarkaisemalla ja päästöllä (päästöaika vaihteli) ja toinen joukko oli (Santa-Aho et al., 2012) tutkimuksessa laserkäsittelyllä valmistettuja hiontapalamiskappaleita. BN-mittaus suoritettiin taajuudella 45 Hz ja magnetointijännitteellä 4,3 V. RS:t mitattiin XRD-menetelmällä ja kovuutta mitattiin Matsuzawa NMT-X7 kovuusmittauslaitteella. Aluksi BN:stä mitattiin suuri määrä ominaisuuksia, joista suoritettiin merkityksellisten piirteiden valinta (engl. feature selection) Ominaisuuksien valintaa validoitiin sekä testattiin. RS:n ennustaminen onnistui parhaiten viidellä muuttujalla, jotka olivat FWHM, koersiivisuus, crest-faktori, liikkuvan entropiaprofiilin piikin sijainti ja yksi BP:in sovitetun puolisuunnikasfunktion parametreista. Kovuutta ennusti parhaiten kolme muuttujaa: BP:n piikin sijainti, remanenssi ja yksi BP:in sovitetun puolisuunnikasfunktion parametri. Näillä muuttujilla saatiin RS:n ennusteelle 0,88 korrelaatio opetusdatan, ja jopa 0,94 korrelaatio testausdatan kanssa. Kovuutta ennustavalla käyrällä taas oli 0,96 korrelaatio opetusdatan ja 0,76 korrelaatio testausdatan kanssa. Tutkimuksessa osa tiedosta oli ristiriidassa kirjallisuuden kanssa, esim. koersiivisuudelle saatiin positiivinen korrelaatio RS:n kanssa, vaikka koersiivisuuden mainitaan kirjallisuuden mukaan pienenevän RS:n muuttuessa puristavista jännityksistä vetojännityksiin päin. Siitä huolimatta tutkimuksessa pystyttiin ennustamaan kohtuullisen hyvin sekä RS:n arvoa, että kovuutta BN-mittauksesta laskettujen piirteiden perusteella. (Sorsa et al. 2012)

Thanedar et al. (2017) tarkastelivat samoin hiontaparametrien vaikutusta ja merkityksellisyyttä BN-mittauksen RMS-arvoon. He totesivat RMS-arvon kasvavan RS:n muuttuessa puristusjännityksistä vetojännitysten suuntaan ja kovuuden heikentyessä.

Neslušán et al. (2017) ehdottivat tutkimuksessaan BN:n kalibrointia hiontapalamisten arviointiin RS:n sijasta kappaleen mikrorakenteesta. Tutkimuksessa näytteinä oli 18NiCrMo14-6 teräksisiä pintakarkaistuja laakerirenkaita. Hiontapalamisen suhteen erilaisia kappaleita saatiin hiomakiekon kulumisella ja kahdella eri jäähdytysnesteen virtausnopeudella. BN:n magnetointitaajuutena käytettiin 125 Hz ja jännitteenä 10 V. Lisäksi RS:n arvot mitattiin XRD-menetelmällä ja mikrokovuus Vickersin mikrokovuusmittalaitteella. Kappaleisiin tehtiin myös SEM-mittaus. Yllätyksenä BN-profiileissa huomattiin kaksi erillistä huippua. Tämän epäiltiin johtuvan karbidifaasin epähomogeenisesta jakautumisesta kappaleen pinnalla. Heterogeenisuus on seurausta lämpökäsittelyiden ja hionnan jonkinlaisesta yhdistelmästä. Kaksoispiikin mahdolliseksi syiksi mainittiin myös pinnassa olevan päästyneen osan ja sen alla olevan karkaistun osan eron, sekä karkaistun pinnan ja sen alla olevan bulkin eron. Tutkimuksessa arvioitiin myös lämpövaikutuskerroksen (engl. Heat affected zone, HAZ) paksuuden olevan RS:ää toimivampi RMS-arvon kalibroinnissa arvioitaessa hiontapalamista.

Sackmann et al. (2019) identifioivat eri menetelmin käsitellyistä hammaspyöristä neljä eri hiontapalamisen luokkaa sekä tutkivat eri BN-mittauksen (magnetointitaajuus 125 Hz) piirteiden käyttäytymistä luokkien välillä. Luokat identifioitiin Nital-etsauksella, sekä XRD-mittauksella (RS ja FWHM). Luokat olivat A (vahingoittumaton), B (lievää päästymistä), D (vahvaa päästymistä) sekä E (pinnan uudelleen karkeneminen). RMS-arvon nähtiin ensin kasvavan lähestyttäessä luokkaa B, jonka jälkeen arvo alkoi hieman laskea mentäessä luokkiin D ja E. Tutkimuksessa huomattiin piikin korkeuden, remanenssin, integraalin alan ja spektrin pinta-alan käyttäytyvän jokseenkin samoin kuin RMS-arvo. Vastaavasti piikin sijainnin nähtiin pysyvän ensin samana luokissa A ja B ja kasvavan sitten mentäessä luokkiin D ja E. Koersiivisuuden nähtiin käyttäytyvän saman suuntaisesti kuin piikin sijainnin. Lopuksi katsottiin vielä RMS-arvon ja koersiivisuuden arvon muuttumista eri luokilla, kun analysointitaajuutta muutettiin. Muutosta huomattiin, joten luotettavassa luokkien toisistaan erottamisessa tulisi ottaa huomioon myös analysointitaajuus.

Sackmann et al. (2020) selvittivät tutkimuksessaan optimaalisia magnetointitaajuuksia BN:n eri piirteiden mittaukseen, sekä pohjustivat luotettavaa hiontapalamisten tutkimusmenetelmää BN-mittauksella. Tutkimuskappaleiksi hiottiin sylinterimäisiä teräskappaleita eri nopeuksilla. Kappaleet olivat pintakarkaistua AISI 4820 terästä. Materiaalin hiomisnopeutta muutettiin $0,5 \text{ mm}^3/(\text{mm s})$ ja $24 \text{ mm}^3/(\text{mm s})$ välillä ja jokaiselle materiaalinpoistonopeudelle tehtiin kolme näytekappaletta. Näillä hiontanopeuksilla saavutettiin vaihtelu normaaleista näytteistä päästyneisiin kappaleisiin ja aina uudelleen karsuneeseen näytteeseen poistonopeudella $24 \text{ mm}^3/(\text{mm s})$. Kappaleiden RS:n arvot saatiin mitattua syvyyden suhteen XRD-menetelmällä. BN-mittaus taas suoritettiin useilla eri magnetointitaajuuksilla väliltä 50 Hz ja 500 Hz, sillä eri taajuudet ulottuvat kappaleessa eri syvyyksiin. BN:stä laskettiin RMS-arvot sekä koersiivisuudet ja BP:n piikin sijainnit. Tämän lisäksi tehtiin Nital-etsaukset, jotta tuloksia voitiin vertailla ISO 14104 -standardeihin. BN:n eri arvoja, sekä arvojen keskihajontaa tutkittiin magnetointitaajuuden ja poistonopeuden suhteen ja saatiin selville seuraavaa: materiaalin poistonopeus hionnassa kasvattaa RMS-arvoa ensin nopeasti, kunnes päästynyt alue (tempering zone) syntyy, ja RMS-arvo laskee hieman ja tasaantuu. RMS-arvon mittaukseen optimaalisen magnetointitaajuuden arvioitiin olevan yli 300 Hz, sillä taajuuden nostaminen paransi siihen asti herkkyyttä, eikä keskihajonta ollut riippuvainen magnetointitaajuudesta. Piikin sijainti materiaalinpoistonopeuden suhteen laskee ensin hieman, mutta lähtee sitten nousemaan. Magnetointitaajuudella ei todettu olevan vaikutusta piikin sijaintimittauksen herkkyyteen, mutta keskihajonta oli suurempi alle 150 Hz taajuuksilla, joten optimaaliseksi magnetointitaajuudeksi arvioitiin yli 150 Hz. Koersiivisuuden todettiin kasvavan suhteessa materiaalinpoistonopeuksiin ja sensitiivisyyden pienevän magnetointitaajuuden kasvaessa. Toisaalta keskihajonnan todettiin olevan suurin alle 100 Hz taajuuksilla, joten koersiivisuuden mittaukseen optimaaliseksi magnetointitaajuudeksi arveltiin 100 Hz taajuutta. Artikkelissa ehdotettiin myös samaa tutkimusprotokollaa muiden teräslaatuojen BN-mittauksen piirteiden optimaalisten magnetointitaajuuksien tutkimiseen.

Sorsa et al. (2023) artikkelissa tutkittiin, havaitaanko BN-mittauksen magnetointitaajuudella 125 Hz pinnanalaisia vetojännityksiä. Näytteinä oli todellisia teollisuuden näytteitä, joita oli hiottu ja hiontapalamista oli havaittu. Sylinterimäiset näytteet olivat matalaseosteista AISI/SAE L6 läpikarkaistua terästä. Yhteensä tutkittiin 42 hiontapalamisnäytettä. Näytteistä otettiin BN-mittaus 125 Hz taajuudella ja 8 V

magnetointijännitteellä. Tämän lisäksi Tehtiin XRD-mittaus, josta saatiin RS-arvot ja XRD FWHM arvo, joka on vahvasti yhteydessä kappaleen kovuuteen. Pintaa syövyttämällä päästiin XRD-mittaus tekemään myös pinnan alaisiin kerroksiin. BN-mittauksen osalta tutkittiin seuraavia piirteitä: RMS-arvo, piikin korkeus, piikin sijainti, piikin leveys (eli BP:n FWHM), koersiivisuus, remanenssi, integraalin ala, spektrin ala ja pulssien määrä. Ominaisuuksien yhteys BN:ään on selitetty aiemmin kappaleessa 3.3. Tutkimuksessa analysoitiin ominaisuuksien korrelaatiokertoimia sekä RS-arvoille että XRD FWHM -arvoille kappaleen pinnasta aina 100 mikrometrin syvyyteen asti. Lisäksi luotiin yksinkertaiset lineaariset regressiomallit eri syvyyksien RS-arvoille. Tutkimuksessa selvisi, että taajuudella 125 Hz mitatut BN:n ominaisuudet korreloivat huomommin kappaleen pintakerroksen kanssa ja paremmin pinnanalaisten kerrosten kanssa. Ominaisuuksista löydettiin kaksi ryhmää, jotka ovat merkittäviä, mutta ryhmän sisäiset termit korreloivat vahvasti keskenään. Ryhmät olivat samat kuin (Sackmann et al., 2019) suorittamassa tutkimuksessa. Ensimmäisessä ryhmässä on RMS-arvo, piikin korkeus, remanenssi, integraaliala ja spektrin ala (keskenään yli 0,85 korrelaatio). Toiseen ryhmään kuului piikin sijainti ja koersiivisuus (korrelaatio keskenään 0,81). Pulssien määrän todettiin olevan merkityksetön hiontapalamisten arvioinnissa ja piikin leveyden korrelaatio todettiin kohtuullisen pieneksi. Linearisista regressiomalleista BN:n ominaisuuksien ja RS:n välillä tuli kohtuulliset välille 10–50 mikrometriä, mikä kertoo BN-mittauksen kyvystä havaita myös pinnan alaisia jäännösjännityksiä. Lähteen (Sorsa et al. 2023) mukaan hiontapalamista arvioivaan malliin tulisi ottaa aina vähintään yksi ominaisuus kummastakin yllä mainitusta ryhmästä. Ainakin kyseiseen dataan toisen ryhmän kumpikin ominaisuus kannatti ottaa yhdessä, sillä niiden välillä epäiltiin olevan merkityksellisiä yhteisvaikutuksia. Lisäksi RS:n rinnalle tulee ottaa mikrokovuus huomioon, jotta mallista saataisiin tarkempi. Seuraavaksi tutkimuskohteeksi artikkelissa ehdotettiin luokittelumallin luomista, joka erottaa hiontapalamisen normaalista kappaleesta, ja edelleen, joka erottaa hiontapalamisen eri vakavuusasteet toisistaan.

Santa-Ahon et al. (2023) tutkimuksessa klusteroitiin lähteessä (Sorsa et al. 2023) oleva data hiontapalamisluokkiin 1, 2 ja 3, joista 1 edustaa lievintä hiontapalamista ja 3 vakavinta. Hiontapalamista oletettiin voivan analysoida RS- ja XRD FWHM -arvojen avulla. Klusterointi tehtiin k-means klusteroinnilla, ja paras tulos saatiin, kun käytettiin RS:n maksimiarvoa (RS:n syvyysprofiilista) ja XRD FWHM minimiarvoa. Luokittelumallia varten ominaisuudet valittiin käyttämällä mRMR-algoritmia (engl.

minimum redundancy maximum relevance). Luokittelumallin ominaisuuksiksi saatiin RMS-arvo sekä piikin sijainti. Ristivalidointia käytettiin siten, että 20 % datasta jätettiin validointidataksi kuitenkin niin, että sekä opetus- että testausdatassa oli dataa kaikista hiontapalamisluokista. Luokittelumallina käytettiin lineaarista diskriminanttiluokittelumallia, ja luokittelusta tuli kohtuullinen. Luokka 1 onnistuttiin luokittelemaan oikein hieman yli 96 % tarkkuudella sekä opetus- että testausdatalle. Luokka 2 luokiteltiin oikein n. 80 %:n tarkkuudella sekä opetus- että testausdatalle. Sen sijaan luokka 3 luokiteltiin oikein opetusdatalla 97 prosenttisesti, mutta testausdatalle vain 78 prosenttisesti. Tutkimuksessa ehdotettiin, että jatkotutkimuksessa luokittelu yritettäisiin tehdä yhden kolme luokkaa luokittelevan mallin sijasta kahden binäärisen luokittelumallin sarjana.

4 LUOKITTELUMALLIT

4.1 Yleisesti

Luokittelumallit (classification models) ovat malleja, jotka pyrkivät näytteiden tiettyjen piirteiden perusteella luokittelemaan näytteen johonkin valmiiksi määrättyyn luokkaan. Suuri osa koneoppimisesta, esimerkiksi käsin kirjoitetun tekstin tunnistusohjelmat, jotka osaavat tunnistaa käsin kirjoitetut kirjaimet niiden tiettyjen ominaispiirteiden avulla, ovat luokittelumalleja. Luokittelumalleja on sekä white-box-malleja, black-box-malleja että niiden välillä olevia grey-box-malleja. White-box-mallista voidaan tulkita käytettävien tulomuuttujien merkittävyyttä ja vaikutusta, kun taas black-box-mallin sisälle emme näe. Mallit vaativat aina tietyn opetusdatan, jossa näytteiden luokat on annettu valmiiksi. Black-box-mallit vaativat usein hyvin suuren määrän dataa, mutta pystyvät suorittamaan toimintoja, jotka ovat white-box-malleille liian monimutkaisia. Barros et al. (2015) mukaan white-box-mallit ovat black-box-malleja selkeämpiä, ne antavat lisätietoa luokittelun toiminnasta, ne mahdollistavat virheiden huomaamisen ja sitä kautta antavat luokittelumallin tekijälle myös varmuuden mallin luotettavuudesta. Esimerkkejä white-box-malleista ovat tässä kandidaatintyössä tarkemmin käsiteltävät päätöksentekopuu ja logistinen regressio. Hiontapalaminen, jota tässä työssä tutkitaan, on muuttujana kategorinen eikä jatkuva. Tämän vuoksi luokittelumallit sopivat tässä työssä datan analysointiin paremmin kuin esimerkiksi lineaarinen regressiomalli.

4.2 Logistinen regressio

Regressiomallit pyrkivät ennustamaan selitettävää muuttujaa yhden tai useamman toisistaan riippumattoman muuttujan avulla. Esimerkiksi yleisimmin käytettyä lineaarista regressiota voidaan käyttää, kun pyritään ennustamaan kappaleen RS:n arvoja BN:n yhdellä tai useammalla piirteellä (RMS- arvo, koersiivisuus jne.), kuten lähteessä (Sorsa et al. 2012) tehtiin. Logistinen regressio on paljolti samanlainen muiden regressiomallien kanssa. Erikoisuutena on kuitenkin se, että logistisessa regressiossa selitettävä muuttuja saa vain kahta arvoa. Esimerkkinä voidaan ennustaa, että saako kappale arvon 0 (Eihiontapalamista) vai arvon 1 (Hiontapalamista) yhden tai useamman BN:stä lasketun ominaisuuden avulla. Logistisen funktion käyrä, jonka muoto riippuu ennustavista muuttujista taas kuvaa todennäköisyyttä, jolla ennustettava arvo on 1. Jos todennäköisyys

on yli 0.5, luokittelee logistiseen regressioon perustuva malli datapisteen luokkaan 1. Jos halutaan, ettei esimerkiksi yhtään hiontapalamiskappaletta kappaletta luokitella kunnolliseksi kappaleeksi, voidaan tarvittaessa muuttaa jakopistettä (engl. cut off point), joka useimmiten on 0.5. (Osborne 2015; Kaakinen & Ellonen).

Logistisessa regressiomallissa identifioidaan yhtälö

$$t = \beta_0 + \beta_1 x_1 + \beta_2 x_2, \quad (2)$$

missä β_0 on vakiotermi, eli y-akselin leikkauspiste
 x_i on i:s muuttuja ja
 β_i on muuttujan kerroin.

Yhtälöstä (2) saatu t sijoitetaan logistisen funktion kaavaan

$$\sigma(t) = \frac{e^t}{e^t + 1}, \quad (3)$$

missä $\sigma(t)$ on logistinen funktio, joka voi saada arvoja nolasta yhteen.

4.3 Päätöksentekopuu

Päätöksentekopuu (engl. decision tree) on suosittu luokittelumenetelmä, josta on useita erilaisia versioita. Perinteinen päätöksentekopuu on kuitenkin ylhäältä alas käytävä induktio (engl. top down induction). Puu alkaa juuresta (engl. root), jossa mukana on vielä kaikki datapisteet. Algoritmi etsii aineiston muuttujista raja-arvot, joiden mukaan päätöksentekopuu alkaa jakamaan dataa. Kun data on jaettu osiin, siirrytään suoraan juuresta haarautuvista oksista eli 1. tasolta 2. tasolle. Jos jokin haara koostuu pelkästään yhdestä luokasta, kutsutaan sitä lehdeksi (engl. leaf). Tällöin kyseistä haaraa eli lehteä ei tarvitse enää luokitella tarkemmin, ja sitä ei jatketa seuraavalle tasolle. Jos taas haarassa olevat datapisteet ovat useampaa luokkaa, kutsutaan haaraa sisäiseksi solmukohdaksi (engl. internal node). Tasoja edetään niin pitkään, kunnes jäljellä ei ole muita kuin lehtiä. Rajauksen ja datapisteiden jakamisen hyvyttä voidaan mitata usealla eri tapaa, joista yksi on saadun informaation määrä (engl. information gain), joka perustuu Shannonin entropiaan. Entropia kuvaa oksien puhtautta. Jos oksan haarassa on ainoastaan yhtä luokkaa, eli haara on lehti, on entropian arvo 0. Jos taas haarassa on saman verran kaikkia luokkia, on entropian arvo 1. Rajauksista valitaan siis se, jonka entropia on

mahdollisimman pieni ja näin saatu informaatio on maksimissaan. Todellisuudessa haarojen lopettaminen ainoastaan täydelliseen luokkien jakoon ei ole järkevää ja johtaa usein mallin ylisovittamiseen. Siispä usein on määrätty jokin entropian raja-arvo, jota pienempiin arvoihin luokittelu päätetään, vaikka luokittelu ei olisikaan täydellinen. Kyseistä päätöksentekopuu-menetelmää kutsutaan ahneeksi, eli se valitsee aina kyseisessä vaiheessa tehtävän parhaan jaon, vaikka se ei kokonaisuuden kannalta olisi aina paras. Kuitenkin Barros et al. (2015) toteavat sen yksinkertaisuudessaan yhdeksi toimivimmista luokittelumalleista. (Barros et al. 2015)

4.4 Validointi ja datan jakaminen

Kun mallia luodaan datasta, mallista saadaan yleensä sitä tarkempi, mitä suurempi on datapisteiden määrä. Niinpä lähtökohtaisesti tarkin malli saadaan hyödyntämällä kaikkea saatavilla olevaa dataa. Tällöin kuitenkin tulee riski ylisovittamisesta. Ylisovitettu malli toimii todella hyvin juuri kyseiselle datajoukolle. Kuitenkin kun ylisovitettua mallia testataan datalla, jota ei ole käytetty mallin luomiseen, mallin huomataan toimivan huonosti. Niinpä mallista pyritään saamaan mahdollisimman toimiva niin, että se toimisi hyvin myös uusien datapisteiden mallinnuksessa ja ennustamisessa. Niinpä mallia validoidaan ja testataan.

Mallin validointia varten data jaetaan kolmeen osaan. Näitä kutsutaan opetus-, validointi- ja testausdatoiksi. Opetusdatalla luodaan malli, jota validoidaan validointidatalla. Usein tämä toistetaan useamman kerran eri opetusdata-validointidata-jaolla, joista lasketaan keskiarvotulokset. Näin voidaan pienentää sattuman aiheuttamia vaiheluita, ja täten saadaan paremmin todellisuutta vastaavia tuloksia. Jos malli toimii hyvin opetusdatalle, mutta huonosti validointidatalle, voidaan todeta kyseisen mallirakenteen soveltuvan huonosti yleisempään käyttöön, esimerkiksi mahdollisen ylisovittamisen vuoksi. Tällöin kokeillaan jotain muuta mallirakennetta. Kun malli on luotu, testauksessa mallin toiminnan hyvyttä testataan datalla, jota ei ole käytetty ollenkaan mallin luomiseen.

Jos tutkittava datajoukko on pieni, dataa on liian vähän staattiseen jakoon. Tällöin hyödynnetään ristivalidointimenetelmiä. Näitä ovat LOO (engl. leave one out), holdout-ristivalidointi ja k-fold. LOO-ristivalidoinnissa datajoukosta otetaan aina yksi datapiste validointi/testausdataan ja muuta data joukkoa käytetään opetusdatassa. Tätä toistetaan

niin, että jokainen datapiste käy kerran validointi/testausdatana, jonka jälkeen lasketaan saaduista opetusdatan tarkkuuksista ja validointi/testausdatan tarkkuuksista keskiarvot, joista nähdään ennustetta mallin toiminnan hyvyydestä mahdollisen uuden datan kanssa.

Hold-out-ristivalidoinnissa jätetään tietty kappalemäärä tai tietty prosenttiosuus datasta validointi/testausdataan. Esimerkiksi voidaan valita testausdataan kolme datapistettä satunnaisesti. Tätä datan jakoa täytyy toistaa, jotta datan valinta ei vaikuta mallin toiminnan arviointiin. Tämä menetelmä sopii, jos dataa on pieni määrä. Toistojen avulla halutaan saada mahdollisimman tarkka keskimääräinen tulos.

k-fold-ristivalidoinnissa data jaetaan k samansuuruiseen osaan satunnaisesti. Esimerkiksi jos $k = 10$, data jaetaan 10 osaan. Näistä osista yksi on aina vuorollaan testausdatana ja loput toimivat opetusdatana mallille. Koska datan jako on satunnainen, sitä täytyy toistaa ja käyttää keskimääräisiä tuloksia mallin validoinnissa.

Joskus voidaan myös jättää validointi kokonaan tekemättä, eli koko data käytetään mallin opetukseen. Tällöin mallilla on potentiaalia olla tarkin, mutta samaan aikaan mahdollista ylisovittumista ei tiedetä. (Sorsa, 2013)

5 DATA JA MALLINNUS

5.1 Käytetty aineisto

Tässä työssä data on sama kuin Santa-Ahon et al. (2023) tutkimuksessa. Aiemmassa tutkimuksessa (Sorsa et al. 2023) on mitattu BN:lle yhdeksän ominaisuutta 42 hiontapalamiskohdasta: RMS-arvo, piikin korkeus, piikin sijainti, FWHM (eli piikin leveys), koersiivisuus, remanenssi, integraalin ala, spektrin ala ja pulssien lukumäärä. Tämän lisäksi kappaleille oli tehty XRD-mittaus, josta saatiin näytteille RS- ja XRD FWHM -arvot. Nämä kaksi muuttujaa kuvaavat hyvin hiontapalamista, joten Santa-Aho et al. (2023) klusteroivat niiden perusteella datan kolmeen luokkaan hiontapalamisen vakavuuden perusteella. Luokka 1 kuvaa lievintä ja luokka 3 vakavinta hiontapalamista. Lähteessä (Santa-Ahon et al. 2023) suoritettiin piirteiden valinta mRMR algoritmilla ja sopiviksi piirteiksi todettiin RMS-arvo sekä piikin sijainti. Niinpä niitä käytettiin myös tässä työssä. Luokittelu suoritettiin Matlabissa, sekä sen Classification learner toolboxissa.

5.2 Logistinen regression

Koska logistinen regressio osaa jakaa dataa vain kahtia, sitä käytettäessä luokittelu täytyy suorittaa kaksivaiheisesti. Ensin erotetaan luokka 1 muista, joten asetetaan ensin kaikki 2 ja 3 luokkaan kuuluvat samaan luokkaan ja kutsutaan sitä luokaksi 23. Luokittelussa käytettiin RMS-arvoa ja piikin sijaintia. Toisessa vaiheessa käytettiin ensimmäisen mallin luokkaan 23 luokittelemia datapisteitä, jotka pyrittiin jakamaan luokkiin 2 ja 3. Luokittelusta jätettiin pois ne datapisteet, jotka todellisuudessa kuuluisivat luokkaan 2 tai 3, mutta vaiheessa 1 luokiteltiin luokkaan 1 kuuluviksi. Sen sijaan vaiheeseen 2 otettiin mukaan virheellisesti luokkaan 23 luokitellut datapisteet. Mallin muodostusta toistettiin 20 % hold-out-validoinnilla n. 1000 kertaa. Validoinnin satunnainen datan jako hyväksyttiin vain, jos vaiheen 1 opetus- ja testausdatassa oli kaikkia hiontapalamisluokkia. Tämän lisäksi tarkistettiin, että vaiheeseen 2 menee testausdataa. Tuloksena saatiin sekaannusmatriisi opetusdatalle ja testausdatalle luokittelun molemmista vaiheista. Tämän jälkeen luotiin kaksivaiheinen logistinen regressiomalli ilman validointia, jolloin sekaannusmatriisien lisäksi saatiin vaiheiden 1 ja 2 luokittelumallien parametrien arvot.

5.3 Päätöksentekopuu

Päätöksentekopuu-mallia luodessa jätettiin holdout-validoinnissa 20 % datasta testaukseen. Validoinnin datan jako hyväksyttiin vain, jos opetusdataan sekä testausdataan kumpaankin kuului datapisteitä kaikista luokista. Tämän jälkeen luotiin RMS-arvon ja piikin sijainnin mukaan malli. Mallin muodostusta toistettiin n. 1000 kertaa satunnaisella datan jaolla, jotta saatiin laskettua keskiarvotulokset. Mallin Matlab-koodi mukailee Santa-Ahon et al. (2023) käyttämää koodia. Keskiarvotulosten lisäksi luotiin yksi malli ilman validointia koko datajoukolla, ja saatiin sekaannusmatriisi sekä päätöksentekopuun rakenne.

5.4 Mallinnustulosten arviointi

Tuloksia vertailtiin keskenään sekä validointituloksiin. Vertailua tehtiin myös Santa-Ahon et al. (2023) tuloksiin. Vertailua tehtiin enimmäkseen sekaannusmatriisien, sekä mallien kokonaistarkkuuksien avulla. Tämän lisäksi tarkasteltiin mallien termien merkitsevyyttä, arvioitiin mallien hyvyttä ja luotettavuutta, sekä tarkasteltiin tuloksia kirjallisuuden havaintojen näkökulmasta.

6 TULOKSET

6.1 Logistinen regressio

Kaksivaiheisen logistisen regressiomallin keskiarvotulokset 20 % holdout-validoinnilla n. 1000 toistolla voidaan kiteyttää seuraavasti: luokittelun tarkkuus opetus ja testausdatan välillä ei juuri muuttunut luokille 1 ja 2, mutta luokka 3:n luokittelu muuttui opetusdatan 96,78 prosentista testausdatan 70,63 prosenttiin. Ensimmäisen vaiheen tulokset on esitetty taulukossa 1, ja toisen vaiheen tulokset taulukossa 2. Ensimmäisen vaiheen Kokonaistarkkuudeksi saatiin opetusdatalle 93,12 % ja testausdatalle 92,22 %. Toisen vaiheen kokonaistarkkuudeksi saatiin opetusdatalle 99,04 % ja testausdatalle 85,89 %.

Taulukko 1. Opetusdatan/testausdatan keskiarvotulokset kaksivaiheisen logistisen regressiomallin vaiheessa 1. (20 % holdout -ristivalidointi).

		Ennustettu luokka	
		1	23
Todellinen luokka	1	96,02 % / 95,83 %	3,98 % / 4,17 %
	23	13,21 % / 12,92 %	86,79 % / 87,08 %

Taulukko 2. Opetusdatan/testausdatan keskiarvotulokset kaksivaiheisen logistisen regressiomallin vaiheessa 2. (20 % holdout -ristivalidointi).

		Ennustettu luokka	
		2	3
Todellinen luokka	2	99,81 % / 96,06 %	0,19 % / 3,94 %
	3	3,09 % / 29,37 %	96,91 % / 70,63 %

Ilman validointia, koko dataa käyttäen, kaksivaiheisella logistisella regressiomallilla saatiin seuraavat tulokset: ensimmäisessä vaiheessa luokittelun kokonaistarkkuudeksi saatiin 92,9 %. sekaannusmatriisi on kuvattu taulukossa 3. Yksi luokkaan 1 kuuluva datapiste luokiteltiin luokkaan 23, kun taas kaksi luokkaan 23 kuuluvaa datapistettä luokiteltiin luokkaan 1 kuuluvaksi. Vaiheessa 2 luokittelun tarkkuudeksi saatiin 100 %.

Mukana oli yksi vaiheessa 1 väärin luokiteltu datapiste todellisesta luokasta 1, jonka malli luokitteli (vähemmän väärin) kuuluvaksi luokkaan 2.

Taulukko 3. Koko datajoukosta luodun kaksivaiheisen logistisen regressiomallin 1. vaiheen sekaannusmatriisi ja mallin kokonaistarkkuus.

		Ennustettu luokka	
		1	23
Todellinen luokka	1	96,40 %	3,60 %
	23	14,30 %	85,70 %

Sekaannusmatriisi kaikille kolmelle luokalle on kuvattu alla taulukossa 4. Siitä nähdään, että luokan 1 datapisteistä 96,43 % on oikein, ja 3,57 % on luokiteltu väärin luokkaan 2. Luokan 2 datapisteistä 80 % luokiteltiin oikein, kun taas 20 % luokiteltiin väärin luokkaan 1. Luokkaan 3 kuuluvat datapisteet luokiteltiin 100 % oikein. Koko datasta tehdyn kaksivaiheisen mallin kokonaistarkkuudeksi saadaan 92,9 %.

Taulukko 4. Koko datajoukosta luodun kaksivaiheisen logistisen regressiomallin yhdistetty sekaannusmatriisi.

		Ennustettu luokka		
		1	2	3
Todellinen luokka	1	96,43 %	3,57 %	0,00 %
	2	20,00 %	80,00 %	0,00 %
	3	0,00 %	0,00 %	100,00 %

Kaksivaiheisen luokittelun mallit muodostettiin kappaleiden 4.2 ja 5.2 mukaisesti. Luokittelumallien parametrien estimaatit on esitetty taulukoissa 5 ja 6. Estimaateista nähdään RMS-arvon olevan merkittävä vaiheessa 1 ja piikin sijainnin vaiheessa 2.

Taulukko 5. Koko datajoukosta muodostetun kaksivaiheisen logistisen regressiomallin vaiheen 1 mallin parametrien estimaatit.

	Estimaatti	Standardivirhe	t-testisuure	p-arvo
Vakio	-12,7375	13,23726	-0,96225	0,335924
RMS-arvo	0,280393	0,104092	2,693703	0,007066
Piikin sijainti	-0,27402	0,400438	-0,6843	0,493785

Taulukko 6. Koko datajoukosta muodostetun kaksivaiheisen logistisen regressiomallin vaiheen 2 mallin parametrien estimaatit.

	Estimaatti	Standardivirhe	t-testisuure	p-arvo
Vakio	-1248,5178	199857745,4	-6,25E-06	0,999995
RMS-arvo	-0,6103868	1788172,688	-3,41E-07	1
Piikin sijainti	39,655934	5213021,022	7,61E-06	0,999994

6.2 Päätöksentekopuu

Päätöksentekopuumallilla 20 % holdout-validoinnilla n. 1000 toiston keskiarvoksi saatiin taulukossa 7 esitetty sekaannusmatriisi. Malli osasi luokitella opetusdatan luokan 1 datasta 96,42 % oikein, 3,57 % luokiteltiin väärin luokkaan 2 ja 0,01 % luokiteltiin väärin luokkaan 3. Kaikki opetusdatan luokan 2 datapisteet malli luokitteli oikein. Opetusdatan luokan 3 datasta 98,12 % luokiteltiin oikein ja loput luokiteltiin väärin kuuluvaksi luokkaan 2. Testausdatan osalta nähdään, että luokan 1 datasta 92,94 % luokiteltiin oikein ja loput väärin luokkaan 2 kuuluviksi. Testausdatan luokan 2 luokittelutarkkuus laski 90,39 %:in, jossa 9,47 % luokiteltiin väärin luokkaan 1 ja 0,15 % luokiteltiin väärin luokkaan 3. Validoinnissa luokan 3 datapisteiden luokittelutarkkuus laski 77,29 %: in. Loput luokan 3 datasta luokiteltiin väärin luokkaan 2. Mallin kokonaistarkkuudeksi saatiin opetusdatan kohdalla 97,40 % ja testausdatan kohdalla 89,82 %.

Taulukko 7. Opetusdatalla/testausdatalla muodostettujen päätöksentekopuu-mallien sekaannusmatriisien keskiarvotulokset sekä mallin tarkkuus (20 % holdout-validointi).

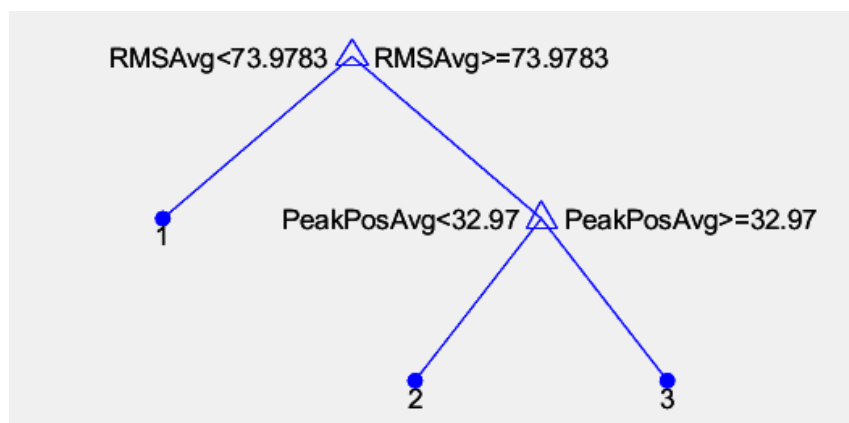
		Ennustettu luokka		
		1	2	3
Todellinen luokka	1	96,42 % / 92,94 %	3,57 % / 7,06 %	0,01 % / 0,00 %
	2	0,00 % / 9,47 %	100 % / 90,39 %	0,00 % / 0,15 %
	3	0,00 % / 0,00 %	1,88 % / 22,71 %	98,12 % / 77,29 %

Koko dataa käyttäen ilman validointia saatiin taulukossa 8 esitetty päätöksentekopuu-malli. Malli luokitteli muut 41 datapistettä oikein, mutta yksi luokan 1 datapiste luokiteltiin väärin luokkaan 2. Mallin kokonaistarkkuudeksi saatiin 97,62 %.

Taulukko 8. Päätöksentekopuu-mallin sekaannusmatriisi ilman validointia.

		Ennustettu luokka		
		1	2	3
Todellinen luokka	1	96,43 %	3,57 %	0,00 %
	2	0,00 %	100,00 %	0,00 %
	3	0,00 %	0,00 %	100,00 %

Yllä olevan päätöksentekopuu-luokittelumallin rakenne nähdään kuvassa 4. Päätöksentekopuun rakenne erottaa ensin luokan 1 muista hyödyntäen RMS-arvoa, jonka jälkeen se erottaa luokat 2 ja 3 toisistaan hyödyntäen piikin sijainnin arvoa.



Kuva 4. Päätöksentekopuun mallin rakenne koko datajoukolle.

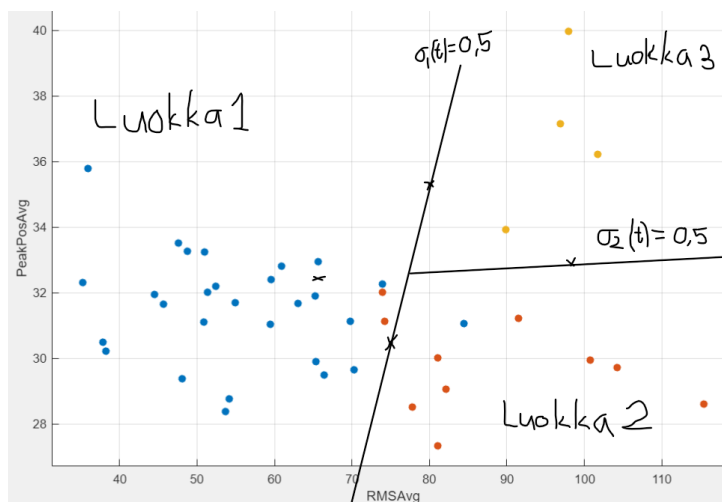
7 TULOSTEN TARKASTELU

7.1 Mallien suorituskyky

Logistisen regressiomallin opetusdatan ja testausdatan tuloksia on vaikea verrata suoraan muihin, tuloksiin, sillä kokonaisuudelle ei saada suoraan sekaannusmatriisia. Kuitenkin jos oletamme, ettei luokkien 1 ja 3 datapisteet menneet luokittelijalla keskenään sekaisin, voidaan sekaannusmatriisit kuvata yhdeksi yhtenäiseksi kolmen luokan sekaannusmatriisiksi. Tämä on kuvattu taulukossa 9. Logistisen regressiomallin kokonaisuuden sekaannusmatriisin kokonaistarkkuus oli opetusdatalle 92,83 % ja testausdatalle 86,83 %. Ilman validointia muodostetun logistisen regressiomallin luokittelurajat taas esitetään kuvassa 5.

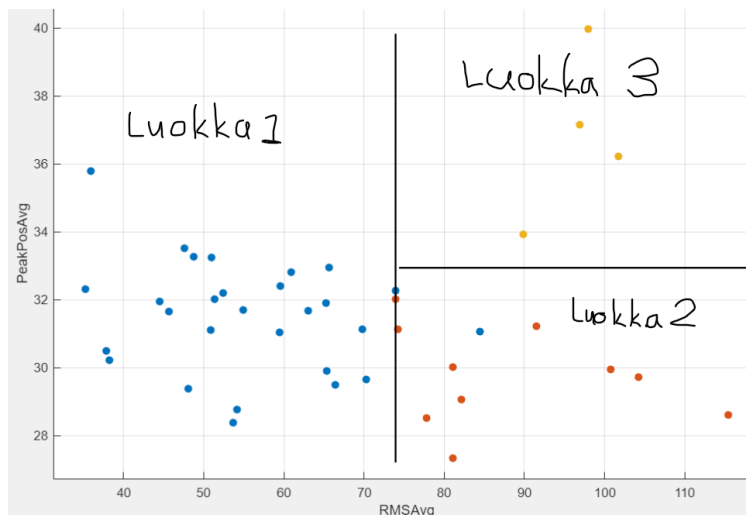
Taulukko 9. 2-vaiheisen logistisen regressiomallin kokonaisuuden sekaannusmatriisi opetusdatalle/testausdatalle (20 % hold-out validointi).

	Ennustettu luokka		
	1	2	3
Todellinen luokka 1	96,02 % / 95,83 %	3,98 % / 4,17 %	0,00 % / 0,00 %
2	17,72 % / 20,57 %	82,10 % / 75,93 %	0,17 % / 3,50 %
3	0,00 % / 0,00 %	3,09 % / 29,37 %	96,91 % / 70,63 %



Kuva 5. Logistisen regressiomallin luokittelurajat kuvattuna RMS - piikin sijainti - kuvaajalla.

Päätöksentekopuulla opetus- ja testausdatan välillä nähdään selvää laskua, erityisesti luokan 3 luokittelussa (98,12 % -> 77,29 %) Myös luokan 2 luokittelussa nähdään 10 % lasku (taulukko 6). Tämä selittyy sillä, että käytettävissä olevassa datassa oli vain 10 luokkaan 2 kuuluvaa datapistettä ja vain neljä luokkaan 3 kuuluvaa datapistettä. Näin pienellä datajoukolla tehdyn mallin ei voida olettaakaan ennustavan kovin hyvin uutta dataa. Esimerkiksi mallilla oli yleensä opetusdatassaan vain kolme datapistettä luokasta 3. Koska koko datasta tehdyllä mallilla oli neljä luokan 3 datapistettä opetusdatan kolmen pisteen sijaan, voitaisiin olettaa mallin ennustavan paremmin täysin samoin metodein hankittuja luokan 3 hiontapalamiskohtia, kuin opetusdatasta tehty malli ennustaa testausdataa. Eri asia on taas, jos uusi data hankitaan jotenkin eri tavalla. Onnistunutta päätöksentekopuumallissa on, että se ei lähes ollenkaan sekoittanut keskenään luokkia 1 ja 3. Lisäksi saatu päätöksentekopuun rakenne on erittäin selkeä ja helposti ymmärrettävä ja tarkasteltava. Päätöksentekopuun luokittelurajat esitetään kuvassa 6.



Kuva 6. päätöksentekopuu-mallin luokittelurajat kuvattuna RMS - piikin sijainti - kuvaajalla.

Taulukkoon 10 on koottu eri malien kokonaistarkkuudet. Sekä logistisella regressiomallilla että päätöksentekopuulla saatiin hyvin opetusdataa ennustavia malleja, joskin päätöksentekopuulla koko datajoukosta saatu malli toimii tämän mukaan kuitenkin huomattavasti paremmin 97,62 % tarkkuudella. Opetus- ja testausdatalla saatuja tuloksia

vertaillessa huomataan, että jokaisen mallin suoritus heikkenee käytettäessä testausdataa. Tämä kertoo siitä, että koko datasta luotujen mallien suorituksen voidaan olettaa laskevan myös täysin uutta dataa arvioidessa. Kuitenkin myös opetus- ja testausdatalle päätöksentekopuu toimi logistista regressiomallia paremmin. Logistisella regressiomallilla suorituskyvyn laskua ei tapahtunut niin paljon opetus- ja testausdatan välillä.

Taulukko 10. Eri luokittelumallien kokonaistarkkuudet.

Malli	Mallin tarkkuus			
	Opetusdata	Testausdata	Koko datajoukko	
Logistinen regressio:	vaihe 1	93,12 %	92,22 %	92,90 %
	vaihe 2	99,04 %	85,89 %	100 %
	Kokonaisuus	92,83 %	86,82 %	92,90 %
Päätöksentekopuu:	97,40 %	89,82 %	97,62 %	

Verrattaessa päätöksentekopuumallin opetus- ja testausdatan tuloksia logistisen regressiomallin luokittelutuloksiin, huomataan että logistinen regressiomalli toimii hieman paremmin ainoastaan luokan 1 testausdatan ennustamisessa. Kaikkialla muualla päätöksentekopuumalli toimii paremmin siitä huolimatta, että logistisen regressiomallin tulokset ovat hieman optimistisia. Esimerkiksi päätöksentekopuun luokittelutarkkuus testausdatan luokalle 2 on 90,39 %, kun logistiselle regressiomallille se on vain 75,93 %.

Verratessa päätöksentekopuumallin opetus- ja testausdatan tuloksia Santa-Ahon et al. (2023) luokittelutuloksiin, huomataan, että päätöksentekopuussa opetusdatan ennustaminen onnistuu kokonaisuudessaan paremmin, mutta suoritus myös heikkenee enemmän siirryttäessä testausdataan. Päätöksentekopuumalli suoriutui testausdatan osalta luokan 1 ennustamisessa n. 4 % huonommin, mutta luokan 2 osalta n. 10 % paremmin. Ikävä kyllä luokan 3 ennustamisessa päätöksentekopuu ei toiminut paremmin.

7.2 Tulosten luotettavuus

Taulukon 8 arvot logistiselle regressiolle eivät ole täysin luotettavia, vaan vain suuntaa antavia. Taulukossa on ensinnäkin oletettu, ettei luokittelija sekoita koskaan keskenään luokkia 1 ja 3. Todellisuudessa näin ei ole, joten taulukko on hieman optimistinen. Opetusdatan saamat arvot ovat muuten luotettavat. Sen sijaan testausdatan saamat arvot ovat todellisuutta optimistisemmät myös siksi, että keskiarvotuloksista on koodin toimivuuden vuoksi rajattu pois ne kerrat, jolloin 1. luokittelija on luokitellut testausdatan luokan 23 kaikki datapisteet väärin luokkaan 1. On siis rajattu pois huonoimmat luokittelutulokset. Tämän lisäksi tuloksia on skaalattu hieman, jotta ne olisivat vertailukelpoisia.

Logistisen regressiomallin luotettavuuden arvioiminen on vaikeaa. Ensinnäkin enemmän todellisuutta vastaava mallin rakenne, jossa vain luokkaan 23 luokiteltua dataa käytetään toisessa vaiheessa, aiheuttaa mallissa ongelmia, joiden takia kaikkein huonoimmat luokittelutulokset tuli rajata keskiarvotuloksista pois. Tämän lisäksi mallin toisen vaiheen estimaatteihin vakioarvolle, sekä piikin paikalle tuli erittäin suuria arvoja. Tämä tarkoittaa sitä, että logistinen funktio antaa suurimmaksi osaksi arvoja, jotka ovat hyvin lähellä nollaa tai ykköstä. Tämä johtuu siitä, että luokat 2 ja 3 on helppo erottaa toisistaan, ja siten malli on aina hyvin varma siitä, mihin luokkaan datapiste kuuluu. Luokat ovat osin myös sen takia helppo erottaa toisistaan, koska luokkiin kuuluvia datapisteitä on niin vähän. Toisaalta vaiheen 2 estimaattien p-arvot olivat kaikki noin 1. Vaikka vaiheen 2 parametrien estimaateissa on epämääräisyyttä, on estimaattien perusteella piirretyt luokittelurajat kuitenkin järkevät (kuva 5). Logistinen regressiomalli käytti luokan 1 erottamisessa lähes täysin RSM-arvoa, ja luokkien 2 ja 3 erottamisessa toisistaan lähes yksinomaan piikin sijaintia. Tämä noudattaa (Sackmann et al., 2019) tutkimuksessa havaittua RMS-arvon ja piikin sijainnin käyttäytymistä.

Päätöksentekopuun mallin luotettavuutta on helpompi arvioida kuin logistisen regressiomallin. Kuvasta 4 nähdään, että malli luokittelee pelkän RMS arvon perusteella lievään hiontapalamiseen, eli luokan 1. $RMS < 73,9783$. Tätä suuremman RMS arvon

omaavat pisteet taas luokiteltiin suoraa vakavammaksi hiontapalamiseksi, eli luokkiin 2 ja 3. Luokat 2 ja 3 päätöksentekopuu taas luokitteli ainoastaan piikin sijainnin perusteella. Jos piikin sijainnin arvo oli alle 32,97, luokiteltiin kappale luokkaan 2. Jos taas piikin sijainnin arvo oli yli tämän, luokiteltiin se vakavan hiontapalamisen luokkaan 3. Siis myös päätöksentekopuulla saatu malli noudattaa (Sackmann et al., 2019) tutkimuksessa havaittua RMS-arvon ja piikin sijainnin käyttäytymistä. Eli hiontapalamisen vakavuuden kasvaessa, ensin RMS arvo kasvaa, ja piikin sijainti pysyy samana, kunnes kappaleessa on havaittavissa lievää päästymistä. Tämän jälkeen RMS arvo lähtee hieman laskuun ja tasoittuu, kun taas piikin sijainti lähtee kasvuun. Tässä tutkimuksessa käytetyt luokat vastaavat Sackmannin ja muiden tutkimuksen luokkia käyttäytymiseltään jotakuinkin seuraavasti. Luokka 1 on luokan A (ei hiontapalamista) ja luokan B (lievää päästymistä) väliltä. Luokka 2 taas vastaa jokseenkin luokkaa B. Luokka 3 vastaa luokkia D (vahvaa päästymistä) ja E (uudelleen karkenemista).

8 JOHTOPÄÄTÖKSET

Hiontapalamisen vakavuuden arviointi ja luokittelu onnistui kohtuullisen hyvin sekä päätöksentekopuulla että kaksivaiheisella logistisella regressiomallilla. Työssä saatujen tulosten perusteella voitiin todeta päätöksentekopuun toimivan logistista regressiomallia paremmin sekä opetus- ja testausdatalle että koko datasta tehtynä mallina. Vertailtaessa päätöksentekopuun tuloksia Santa-Ahon et al. (2023) saamiin tuloksiin nähdään, että päätöksentekopuu luokitteli n. 10 % paremmin luokan 2 mutta n. 4 % huonommin luokan 1. Saavutettiin siis parempia luokan 2 luokittelutuloksia, mikä voi johtua päätöksentekopuurakenteen kaksivaiheisuudesta. Logistinen regressiomalli ei luokitellut luokkaa 2 Santa-Ahon mallia paremmin.

Muuten kumpikin tutkimuksessa luodusta mallista luokitteli kohtuullisen onnistuneesti, mutta luokan 3 testausdatan luokittelutulokset laskivat huomattavasti opetusdatan tuloksiin nähden samoin kuin Santa-Ahon et al. (2023) artikkelissa. Artikkelissa luokittelutuloksen parantamiseksi ehdotettiin sekä luokan 3 datapisteiden lisäämistä että 2-vaiheista luokittelumallia yhtäaikaisen luokittelun sijasta. Voidaan todeta, että luokan 3 muita huonompi tulos ei johdu yhtäaikaisesta luokittelusta, vaan juuri vähäisestä luokan 3 datasta. Tuloksista nähtiin selkeästi myös se, että luokkien 1 ja 2 erotus perustui malleissa suurimmaksi osaksi tai kokonaan RMS-arvon kasvuun, kun taas luokkien 2 ja 3 erotus perustui piikin sijainnin arvon kasvuun. Tämä mukaillee jo aiemmin kirjallisuudessa huomattua BN:n käytöstä. Tulokset osoittivat, että hiontapalamisten eri vakavuusasteet on mahdollista erottaa toisistaan vähintäänkin kohtuullisesti hyödyntäen Barkhausen-kohinamittauksen eri piirteitä. Tulokset myös vahvistavat, että luokittelun onnistuminen edellyttää pelkän RMS-arvon käytön lisäksi vähintäänkin piikin sijainnin (tai mahdollisesti vaihtoehtoisesti koersiivisuuden) käyttämistä.

Päätöksentekopuumalli suoriutui jonkin verran paremmin sekä testausdatan ennustamisessa että koko datasta muodostettuna mallina kuin logistinen regressiomalli. Päätöksentekopuun rakenteesta nähtiin, että se toteuttaa luokittelun samoin kaksivaiheisesti niin, että se erottaa ensin luokan 1 muista ja sitten luokat 2 ja 3 toisistaan. Tulosten luotettavuuden arvioinnissa todettiin päätöksentekopuun antamia tuloksia logistisen regressiomallin tuloksia luotettavampina. Niinpä jos luokittelurakenteen

halutaan olevan kaksivaiheinen, tässä työssä saatujen tulosten perusteella suositellaan käyttämään päätöksentekopuuta.

Toisaalta logistisen regressiomallin etuja on se, että sen avulla voi halutessaan ilmoittaa ennustetun luokan lisäksi ennustettua todennäköisyyttä, jolla piste kuuluu kyseiseen luokkaan. Tämä mahdollistaa sen, että jos esim. luokittelussa halutaan vähentää luokkaan 1 meneviä todellisen luokan 2 kappaleita, voidaan logistisen funktion luokittelurajaa siirtää 0,5:stä esimerkiksi arvoon 0,4.

Jatkotutkimusta suositellaan tekemään suuremmalla datajoukolla, joka sisältää eri asteisten hiontapalamiskohtien lisäksi näytteitä vaurioitumattomista kohdista. Tällöin kannattaa käyttää enemmän päätöksentekopuuta kuin logistista regressiota, sillä silloin luokittelu menisi jo kolmivaiheiseksi. Erittäin tärkeää olisi, että luokan 3 datapisteitä olisi enemmän, jotta luokittelusta saataisiin luotettavampi. Tuloksista nähtiin, kuinka luokittelun eri vaiheissa eri piirteet ovat merkittäviä. Niinpä seuraavalla kerralla, jos rakennetaan logistisella regressiolla 2-vaiheista luokittelumallia, tulee kummallekin vaiheelle tehdä oma piirteidenvalintaprosessi.

Myös mielenkiintoinen tutkimus olisi, jos hiontapalamisen kulkua mitattaisiin suoraan hiontaprosessista hiontapalamisen syntyessä. Tällöin saataisiin tietoa eri piirteiden käyttäytymisestä hiomisprosessin aikana. Hiontaprosessi voitaisiin suorittaa eri pisteisiin asti niin, että kappaleille voisi jälkeenpäin tehdä kovuus- ja jäännösjännitysmittaukset, sekä Nital-etsaus niin, että hiontapalamisen vakavuutta voitaisiin verrata tunnettuihin luokkiin/standardeihin.

9 YHTEENVETO

Tässä kandidaatin työssä perehdyttiin ferromagneettisten terästen hiontapalamisiin ja niiden arviointiin Barkhausen-kohinamittauksen avulla. Aiheeseen liittyvää kirjallisuutta käytiin läpi, jonka jälkeen muodostettiin Santa-Ahon et al. (2023) artikkelissa suositeltu kaksivaiheinen logistinen regressiomalli sekä päätöksentekopuu-malli, joilla kolmeen luokkaan jaettua hiontapalamisdataa pyrittiin luokittelemaan. Kummallekin mallille tehtiin ensin 20 % holdout-ristivalidoinnilla n. 1000 toistoa, joiden keskiarvotulokset kuvattiin sekaannusmatriiseihin. Tämän lisäksi tehtiin koko dataa käyttämällä logistinen regressiomalli sekä päätöksentekopuu-malli, joista saatiin esimerkkimallien rakenteet. Tutkimuksessa käytettiin Santa-Ahon et al. (2023) piirteiden valinnassa saatuja BN:n piirteitä, jotka olivat RMS-arvo ja piikin sijainti.

Muodostetut mallit onnistuivat luokittelussa kohtuullisen hyvin. Joskin, luultavimmin vähäisen datamäärän vuoksi, luokan 3 luokittelutulokset olivat testausdatalle selkeästi opetusdataa huonommat. Kokonaisuudessaan päätöksentekopuu onnistui luokittelussa paremmin sekä opetusdatalle (97,40 %), testausdatalle (89,82 %) että koko datasta tehtynä (97,62 %). Päätöksentekopuun rakenne on myös selkeämpi, ja mallin muodostuksessa oli vähemmän epävarmuutta, joten päätöksentekopuun antamaa mallia voidaan pitää parempana tähän tilanteeseen. Luokittelussa huomattiin kuinka luokat 1 ja 2 erottaa toisistaan kahdesta käytetystä BN-mittauksen piirteestä lähes täysin pelkkä RMS-arvon kasvu, kun taas luokat 2 ja 3 erottaa toisistaan lähinnä piikin sijainnin perusteella. Tämä käytös mukailee muun kirjallisuuden havaitsemaa RMS arvon ja piikin sijainnin käyttäytymistä.

Kokeellinen osio vahvisti sen, että eri hiontapalamisasteita voidaan erottaa toisistaan käyttämällä luokitteluun RMS-arvoa ja piikin sijaintia. Työssä todettiin päätöksentekopuun toimivan käytännössä kaksivaiheisesti, ja kaksivaiheisuuden mahdollisesti vaikuttaneen päätöksentekopuun kohdalla luokan 2 ennustustarkkuuteen positiivisesti.

LÄHDELUETTELO

- Barros, R. C., de Carvalho, A. C. P. L. F., & Freitas, A. A. (2015). *Automatic Design of Decision-Tree Induction Algorithms* (1st ed. 2015.). Springer International Publishing. <https://doi.org/10.1007/978-3-319-14231-9>
- Ceurter, J. S., Smith, C., & Ott, R. (2002). The barkhausen noise inspection method for detecting grinding damage in gears. *ICBM*, *19*, 26–31.
- He, B., Wei, C., Ding, S., & Shi, Z. (2019). A survey of methods for detecting metallic grinding burn. *Measurement*, *134*, 426–439. <https://doi.org/10.1016/J.MEASUREMENT.2018.10.093>
- Kaakinen M & Ellonen N. Logistinen regressio. Teoksessa Kvantitatiivisen tutkimuksen verkkokäsikirja. Tampere: Yhteiskuntatieteellinen tietokirjasto. Saatavissa: <https://www.fsd.tuni.fi/fi/palvelut/menetelmaopetus/kvanti/regressio/logistinen/> . [Viitattu 03.04.2023.]
- Karpuschewski, B., Bleicher, O., & Beutner, M. (2011). Surface Integrity Inspection on Gears Using Barkhausen Noise Analysis. *Procedia Engineering*, *19*, 162–171. <https://doi.org/10.1016/J.PROENG.2011.11.096>
- Malkin, S., & Guo, C. (2007). Thermal Analysis of Grinding. *CIRP Annals*, *56*(2), 760–782. <https://doi.org/10.1016/J.CIRP.2007.10.005>
- Neslušán, M., Čížek, J., Kolařík, K., Minárik, P., Čilliková, M., & Melikhova, O. (2017). Monitoring of grinding burn via Barkhausen noise emission in case-hardened steel in large-bearing production. *Journal of Materials Processing Technology*, *240*, 104–117. <https://doi.org/10.1016/J.JMATPROTEC.2016.09.015>
- Sackmann, D., Heinzl, J., & Karpuschewski, B. (2020). An approach for a reliable detection of grinding burn using the Barkhausen noise multi-parameter analysis. *Procedia CIRP*, *87*, 415–419. <https://doi.org/10.1016/J.PROCIR.2020.02.076>

- Sackmann, D., Karpuschewski, B., Epp, J., & Jedamski, R. (2019). Detection of surface damages in ground spur gears by non-destructive micromagnetic methods. *Forschung Im Ingenieurwesen*, 83(3), 563–570. <https://doi.org/10.1007/s10010-019-00368-z>
- Santa-Aho, S., Vippola, M., Sorsa, A., Latokartano, J., Lindgren, M., Leiviskä, K., & Lepistö, T. (2012). Development of Barkhausen noise calibration blocks for reliable grinding burn detection. *Journal of Materials Processing Technology*, 212(2), 408–416. <https://doi.org/10.1016/J.JMATPROTEC.2011.10.003>
- Santa-aho, S., Sorsa, A., Ruusunen, M., Vippola, M., Grinding burn classification with surface Barkhausen noise measurements, 13th European conference on Non-destructive testing (ECNDT), 3-7 July 2023, Lissabon, Portugal.
- Santa-aho, S., & yliopisto, T. teknillinen. (2012). *Barkhausen noise method for hardened steel surface characterization : the effect of heat treatments, thermal damages and stresses*. <http://URN.fi/URN:ISBN:978-952-15-2947-4>
- Sorsa, A. (2013). *Prediction of material properties based on non-destructive Barkhausen noise measurement*. <http://urn.fi/urn:isbn:9789526200682>
- Sorsa, A., Leiviskä, K., Santa-Aho, S., & Lepistö, T. (2012). Quantitative prediction of residual stress and hardness in case-hardened steel based on the Barkhausen noise measurement. *NDT & E International*, 46(1), 100–106. <https://doi.org/10.1016/J.NDTEINT.2011.11.008>
- Sorsa, A., Ruusunen, M., Santa-aho, S., & Vippola, M. (2023). Sub-Surface Analysis of Grinding Burns with Barkhausen Noise Measurements. *Materials*, 16(1). <https://doi.org/10.3390/ma16010159>
- Thanedar, A., Dongre, G. G., Singh, R., & Joshi, S. S. (2017). Surface integrity investigation including grinding burns using barkhausen noise (BNA). *Journal of Manufacturing Processes*, 30, 226–240. <https://doi.org/10.1016/J.JMAPRO.2017.09.026>

Tiitto, K. M., & Pro, R. J. (1987). Detection of Heat Treat Defects and Grinding Burns by Measurement of Barkhausen Noise. In J. F. Bussière, J.-P. Monchalin, C. O. Ruud, & R. E. Green (Eds.), *Nondestructive Characterization of Materials II* (pp. 481–489). Springer US. https://doi.org/10.1007/978-1-4684-5338-6_49