

**Värähtelyanalyysi ennakoivassa kunnossapidossa ja
prosessin optimoinnissa servo-ohjatuilla
lääketeollisuuden laitteilla**

Kone- ja materiaalitekniikan laitos

Kandidaatintutkielma

Jenni Häihänen

15.5.2026

Turku

Kandidaatintutkielma

Oppiaine: Konetekniikka

Tekijä: Jenni Häihänen

Otsikko: Värähtelyanalyysi ennakoivassa kunnossapidossa ja prosessin optimoinnissa servo-ohjatuilla lääketieteellisuuden laitteilla

Ohjaaja: Atte Laiho

Sivumäärä: 33 sivua

Päivämäärä: 15.5.2026

Lääketieteellisyydessä laitteiden luotettavuus on tärkeää muun muassa laadun, turvallisuuden sekä kustannusten kannalta. Monilla muilla teollisuudenaloilla värähtelyanalyysiä käytetään ennakoivassa kunnossapidossa parantamaan näitä tekijöitä. Lääketieteellisyydessä on kuitenkin jääty jälkeen värähtelyanalyysin käytössä, mihin suurin syy on alaa koskeva tiukempi sääntely.

Tutkielmassa käsitellään lääketieteellisyydessä käytettävää johto- tai kuularuuvien ja servomootorin muodostamaa järjestelmää sekä sen värähtelyanalyysin roolia ennakoivassa kunnossapidossa ja prosessin optimoinnissa. Tarkoituksena on selvittää, onko värähtelyanalyysin hyödyntäminen mahdollista ja mitkä ovat soveltuvimpia värähtelyanalyysimenetelmiä järjestelmälle. Kirjallisuuskatsaus tarkastelee värähtelyanalyysin toteutuksen syitä ja rajoittavia tekijöitä, laitteen toimintaperiaatetta ja hajoamistapoja, värähtelyn teoriaa sekä värähtelyanalyysimenetelmiä.

Kirjallisuuskatsauksen perusteella värähtelyanalyysin käyttö on mahdollista tutkitulla järjestelmällä. Käyttöönotto ja käyttö sisältävät kuitenkin sääntelyiden vuoksi lukuisia haasteita. Esitellyistä värähtelyanalyysimenetelmistä jokainen soveltuu järjestelmälle, mutta tehokkaimpia järjestelmän vikatyypeille ovat kuitenkin diskreetti aallokemuunnos sekä verhoikäyräanalyysi. Koneoppimismenetelmät ovat todistetusti lisänneet analyysin tarkkuutta samankaltaisilla järjestelmillä ja niistä tehokkaita ovat olleet muun muassa gradient boosting ja decision tree. Luotettavien analyysitulosten saamiseksi, tulisi muutamia näistä menetelmistä käyttää samanaikaisesti.

Avainsanat: värähtelyanalyysi, ennakoiva kunnossapito, prosessin optimointi, lääketieteellisyys, servo-ohjaus

Sisällysluettelo

Symboli- ja lyhenneluettelo	4
1 Johdanto	6
2 Kirjallisuuskatsaus	8
2.1 Ennakoiva kunnossapito	8
2.2 Prosessin optimointi	9
2.3 Sääntely lääketeollisuudessa	9
2.4 Lineaarisen liikkeen tuottaminen servomoottorilla	10
2.5 Järjestelmän yleiset hajoamistavat	11
2.6 Värähtely	14
2.7 Värähtelyanalyysimenetelmät	17
2.7.1 Root mean square, crest factor ja kurtosis	18
2.7.2 Fourier-muunnos	19
2.7.3 Aallokemuunnos	20
2.7.4 Hilbert-muunnos	22
2.7.5 Verhokäyräanalyysi	23
2.8 Tekoäly- ja koneoppimismenetelmät	24
3 Tulokset	26
4 Pohdinta	29
Lähteet	31

Symboli- ja lyhenneluettelo

Symbolit

A	amplitudi	m
a	kiihtyvyys	m/s ²
CF	crest factor	
c	vaimennusvakio	Ns/m
F_0	ulkoinen voima	N
f	taajuus	Hz
f_s	näytteenottotaajuus	Hz
j	imaginaariyksikkö $\sqrt{-1}$	
K	jousivakio	N/m
Ku	kurtosis	
k	taajuusindeksi	
M	keskusmomentti	m ⁿ
m	massa	kg
N	mittausten määrä	
n	mittauksen järjestysluku	
p	mittauspisteiden määrä	
T	jaksonaika	s
T_s	näytteenottoväli	s
t	aika	s
v	nopeus	m/s
w	ikkunafunktio	
X	poikkeama, siirtymä	m
y	signaali	
y_i	yksittäisen signaalin arvo	
y_{peak}	signaalin huippuarvo	
y_{rms}	signaalin RMS-arvo	
\bar{y}	signaalin keskiarvo	
η	integroimismuuttuja	
τ	ikkunan aikamuuttuja	s
ϕ	vaihekulma	rad, °
ω	kulmataajuus	rad/s

Lyhenteet

AB	Adaboost
ANN	Artificial neural network
CWT	Jatkuva aallokemuunnos (continuous wavelet transform)
DFT	Diskreetti Fourier-muunnos (discrete Fourier transform)
DT	Decision tree
DWT	Diskreetti aallokemuunnos (discrete wavelet transform)
EA	Verhokäyräanalyysi (envelope analysis)
EMA	European Medicines Agency
FDA	Food and Drug Administration
FFT	Nopea Fourier-muunnos (fast Fourier transform)
GB	Gradient boosting
GMP	Good Manufacturing Practice
HT	Hilbert-muunnos (Hilbert transform)
RF	Random forest
RMS	Root mean square
STFT	Lyhytaikainen Fourier-muunnos (short-time Fourier transform)
SVM	Support vector machine
WPT	Aallopekettimuunnos (wavelet packet transform)

1 Johdanto

Lääketeollisuus on tiukasti säännelty teollisuudenala, jolla korostuu vaatimus erityisen tarkalle turvallisuuden takaamiselle, laadun varmistamiselle sekä määräysten noudattamiselle. Epäkunnossa oleva laitteisto voi heikentää tuotteiden laatua ja siten mahdollisesti vaarantaa potilasturvallisuutta. Laitteiden hajoamisista seuraavat tuotantokatkot taas voivat tarkoittaa ylimääräisiä kuluja ja johtaa mittaviin tappioihin. Laitteiden luotettavuus on siis erityisen tärkeää lääketeollisuudessa. Vaadittavan laitteiden toimintakunnon takaamiseksi ennakoiva kunnossapito onkin noussut alalla tärkeäksi menetelmäksi. Sen käyttö lääketeollisuudessa ei ole kuitenkaan vielä yhtä laajaa kuin muilla teollisuudenaloilla. [1]

Yksi ennakoivan kunnossapidon menetelmistä on tässä tutkielmassa tutkittu värähtelyanalyysi. Lähtökohtaisesti kaikille mekaanisille laitteille, jotka sisältävät pyöriviä tai liikkuvia osia, voidaan hyödyntää värähtelyanalyysiä. Tämä voi olla esimerkiksi osana jatkuvaa ennakoivaa kunnossapitoa, prosessin optimointia tai varmistamassa huoltojen ja kokoonpanojen onnistumisen. Värähtelyanalyysissä käynnissä olevan koneen värähtelyjä mittaamalla ja analysoimalla pyritään saamaan mahdollisimman paljon tietoa koneen todellisesta toimintakunnosta. Mitä kattavampaa tietoa saadaan, sitä paremmin voidaan ennakkoon suunnitella tulevia huoltotoimenpiteitä ja mahdollisesti estää suurempien vikojen syntyminen. Onnistuneesti toteutettuna värähtelyanalyysillä voidaan saavuttaa monia hyötyjä, kuten laadun varmistaminen, tuotannon ennakoitavuus ja kunnossapitokustannusten vähentäminen [2]. Tämän vuoksi värähtelyanalyysi onkin laajasti käytetty menetelmä ennakoivassa kunnossapidossa monilla eri teollisuudenaloilla [3].

Lääketeollisuuden järjestelmissä yleisiä komponentteja ovat servomootorit sekä johto- ja kuularuuvit. Tämän vuoksi tutkielmassa tutkitaan näiden komponenttien toimintaa, vikatyyppejä ja niille soveltuvia analyysimenetelmiä. Ennakoivalla kunnossapidolla voidaan perinteistä kunnossapitoa tehokkaammin valvoa komponenttien toimintakunnon muutoksia ja tuotannon vaatimusten täyttymistä. Aiheen tutkiminen on tärkeää, sillä ennakoivaa kunnossapitoa ja värähtelyanalyysiä hyödynnetään vasta

vähäisessä määrin lääketeknollisuudessa, eikä niiden hyödyistä ole saatavilla paljoa tutkittua tietoa [1].

Tutkielman avulla pyritään vastaamaan tutkimuskysymyksiin:

1. Onko värähtelyanalyysiä mahdollista hyödyntää ennakoivassa kunnossapidossa ja prosessin optimoinnissa servo-ohjatuilla lääketeknollisuuden laitteilla?
2. Mitkä värähtelyanalyysimenetelmät ovat soveltuvimpia servo-ohjatuille lääketeknollisuuden laitteille?

Kirjallisuuskatsauksessa esitellään oleelliset käsitteet ja lääketeknollisuutta rajoittavat tekijät, minkä jälkeen siirrytään tarkastelemaan tutkittavan järjestelmän toimintaperiaatetta ja yleisiä hajoamistapoja. Lopuksi värähtelyn teorian kautta siirrytään esittelemään järjestelmälle soveltuvien värähtelyanalyysimenetelmien toimintaa, hyötyjä ja rajoitteita.

Tutkielman tavoitteena on saada mahdollisimman laaja käsitys siitä, millaisia hyötyjä värähtelyanalyysillä voitaisiin saavuttaa sekä millaisilla menetelmillä analyysi olisi mahdollisimman tehokasta toteuttaa ennakoivan kunnossapidon ja prosessin optimoinnin kannalta. Tekoälyä on hyödynnetty tutkielmassa lähteiden kielen kääntämiseen sekä tiivistämiseen.

2 Kirjallisuuskatsaus

Kirjallisuuskatsauksessa käsitellään aluksi värähtelyanalyysin keskeisiä tavoitteita, eli ennakoivaa kunnossapitoa ja prosessin optimointia, sekä lääketieteellisuuden toimintaympäristöä rajoituksineen. Tämän jälkeen tarkastellaan tutkittavan laitteen toimintaperiaatetta sekä laitteen tyypillisiä vikoja, joita värähtelyjä mittaamalla pyritään havaitsemaan. Värähtelyn teorian kautta lopuksi siirrytään esittelemään laitteelle soveltuvia värähtelyanalyysimenetelmiä sekä tekoälyn ja koneoppimisen hyödyntämistä analyysin tekemisessä.

2.1 Ennakoiva kunnossapito

Kunnossapitokustannukset kattavat arviolta 15–60 prosenttia tuotteiden valmistuskustannuksista ja kolmasosan kunnossapitokustannuksista on arvioitu olevan turhia. Syynä kustannusten suuruuteen on usein huonosti tai tehottomasti toteutettu kunnossapito [2]. Huonosti järjestetty kunnossapito aiheuttaa ylimääräisiä kuluja, sekä usein myös vie ylimääräistä aikaa. Sillä on siten negatiivinen vaikutus esimerkiksi laatuun, tuottavuuteen, tuotantoaikoihin ja tehokkuuteen. Usein syynä on, ettei laitteiden korjaus- ja huoltotarpeista tiedetä tarpeeksi, minkä vuoksi niitä ei osata suunnitella etukäteen [2]. Konsultointiyritys Accenturen mukaan ennakoivalla kunnossapidolla voitaisiin välttää arviolta jopa 70 prosenttia laitteiden hajoamisista, säästää jopa 12 prosenttia suunniteltujen huoltojen kustannuksista ja vähentää kunnossapitokustannuksia jopa 30 prosenttia [4].

Ennakoivan kunnossapidon tarkoituksena on pysyä ajan tasalla laitteiden todellisesta kunnosta ja siten pystyä minimoimaan kunnossapitokustannukset sekä optimoimaan laitteiden toiminta-ajat. Mitä enemmän laitteiden kunnosta tiedetään, sitä aikaisemmin myös viat pystytään havaitsemaan. Usein havaitsemalla viat ajoissa voidaan estää suuremmat ongelmat korjaamalla ne ennen todellista hajoamista. Siten voidaan minimoida huolto- ja tuotantokatkojen kestot sekä kustannukset. Ennakoiva kunnossapito on siis pitkällä aikavälillä kannattavampaa niin kulujen kuin laitteiden elinkaartenkin kannalta. [2]

2.2 Prosessin optimointi

Prosessin optimoinnilla tavoitellaan parempaa suorituskykyä eli esimerkiksi tuotantokustannusten minimointia, tuotantomäärien maksimointia ja laadun parantamista [5]. Suorituskyvyn kasvattaminen pyritään toteuttamaan heikentämättä tuotteen laatua sekä nostamatta tuotanto- ja kunnossapitokustannuksia.

Värähtelyanalyysi on yksi prosessin optimoinnin menetelmä, sillä kerätyn datan pohjalta voi olla mahdollista lisätä laitteiden tuotantotehokkuutta. Jatkuvat oimimisissa ja integroiduissa järjestelmissä, kuten lääketeollisuuden tuotantojärjestelmissä, värähtelyanalyysi on keskeisessä roolissa prosessin optimoinnissa sen ollessa jatkuvasti riippuvainen komponenttien toiminnasta [6].


2.3 Sääntely lääketeollisuudessa

Lääketeollisuudessa ennakoivan kunnossapidon käyttö on vielä huomattavasti vähäisempää kuin muilla teollisuudenaloilla. Syynä tähän on muun muassa tiukempi sääntely, toteutuksen monimutkaisuus sekä kustannukset. Muilla teollisuudenaloilla ennakoivan kunnossapidon on todettu lyhentävän tuotantokatkoja, lisänneen järjestelmien luotettavuutta ja auttaneen toteuttamaan kunnossapito mahdollisimman optimaalisesti. Lääketeollisuudessa toteutettava perinteinen kunnossapito johtaa tarpeettomiin tuotantokatkoihin, ylimääräisiin kustannuksiin sekä vikojen suhteellisen myöhäiseen havaitsemiseen. Manchadi et al. (2025) arvioivat, että ennakoivalla kunnossapidolla pystytään edistämään lääketeollisuutta, eivätkä sen asettamat haasteet estä toteutusta. [1]

Lääketeollisuudessa tulee noudattaa erilaisia viranomaismääräyksiä ja standardeja tuotannosta riippuen. Tällaisia ovat esimerkiksi FDA:n (Food and Drug Administration) ja EMA:n (European Medicines Agency) vaatimukset sekä GMP:n (Good Manufacturing Practice) ohjeistukset, jotka asettavat rajoituksia myös ennakoivan kunnossapidon käyttöönotolle [1]. GMP-ohjeistus sisältää laadunhallintaan liittyviä määräyksiä, joiden tarkoituksena on taata laadukas lääketeollisuus. Tuotannon tulee tapahtua asianmukaisissa tuotantotiloissa ja materiaalien tulee olla lääketeollisuuteen soveltuvia [7].

2.4 Lineaarisen liikkeen tuottaminen servomoottorilla

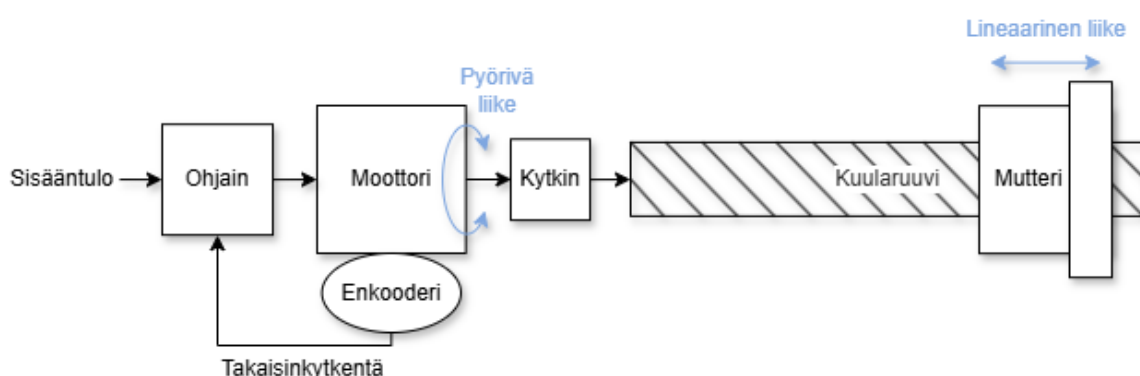
Lineaarista liikettä voidaan tuottaa muuntamalla pyörivä liike edestakaiseksi lineaarisiksi liikkeeksi. Tämä voidaan toteuttaa monella eri mekanismilla, mutta yleisin tapa on käyttää liikkeen tuottamiseen ruuvista ja mutterista koostuvaa johto- tai kuularuuvia. Lineaarinen liike muodostuu, kun ruuvia pyöritetään ja mutterin pyöriminen ruuvin ympäri estetään. Kitkan ja välyksen vähentämiseksi kuularuuveissa ruuvin ja mutterin välissä on kuulista muodostuva laakeri (kuva 1), jolla liike saadaan hyödyntämään vierintäkitkaa liukukitkan sijaan. [8]



Kuva 1: Kuulamutterin poikkileikkauskuva. Kuva käytetty luvalla lähteestä [9]. Tekijänoikeus 2025 Elsevier Ltd.

Servomootoreilla tarkoitetaan sähkömootoreita, jotka käyttävät suljetun silmukan ohjausta moottorin aseman, nopeuden tai vääntömomentin reaaliaikaiseen seurantaan. Servomootoreilla voidaan saavuttaa nopeita kiihdytyksiä ja suunnanvaihtoja, joita voisi olla hankala toteuttaa muun tyyppisillä moottoreilla [10]. Järjestelmä antaa esimerkiksi jatkuvasti tietoa moottorin reaaliaikaisesta asemasta, jonka tietoja voidaan verrata tavoitteena olleen aseman tietoihin. Siten saadaan selville, onko moottorin asema sama kuin tavoiteltu. Virheellinen asema aiheuttaa virhesignaalin, jonka myötä virhe havaitaan ja pystytään korjaamaan [11].

Kuva 2 esittää tutkitavan järjestelmän lohkokaaviota. Ohjausjärjestelmältä saapuu sisääntulolla ohjaimelle käsky, jonka ohjain välittää eteenpäin moottorille. Moottorin tuottama pyörivä liike välittyy kuularuuville kytkimen kautta, joka toimii yhdistävänä komponenttina moottorin ja kuularuuvien välillä. Kuularuuvien pyörivä liike muuntuu mutterin myötä lineaariseksi liikkeeksi. Servomoottoriin on asennettu enkooderi, jonka tehtävänä on seurata moottorin toimintaa ja välittää tietoa takaisinkytkennällä ohjaimelle. Muodostetun suljetun silmukan ansiosta ohjain saa moottorilta tietoa myös takaisin ja voi siten valvoa sen toimintaa.



Kuva 2: Tutkitun järjestelmän lohkokaavio.

2.5 Järjestelmän yleiset hajoamistavat


Tutkitavan järjestelmän komponentteja eli johto- ja kuularuuveja sekä servomoottoreita käytetään laajasti teollisuudessa ja ne ovat erittäin tärkeitä komponentteja tuotannon jatkuvuuden kannalta [3, 12]. Näiden komponenttien yleisimpien vikatyypien tunteminen on välttämätöntä värähtelyanalyysissä, jotta vikoja osataan tunnistaa ja paikantaa signaalista [13].

Kuularuuvien toiminnalla ja vikojen muodostumisella on merkittävä yhteys järjestelmän tarkkuuteen ja tehokkuuteen, minkä vuoksi värähtelyanalyysi onkin keskeisessä osassa niiden kunnonvalvonnassa. Kuularuuveissa esiintyvien vikojen taustalla on tyypillisesti niiden kulumisen ja väsymisen, joita vääränlainen huolto voi edistää entisestään. Viat ilmenevät yleisimmin väsymis- ja kulumismurtumina, esijännityksen häviämisenä,

välyksen muodostumisena ja jumittumisena [3]. Useimmiten kuularuuvien viat esiintyvät värähtelysignaalissa impulsseina, joiden amplitudi muuttuu nopeasti [14].

Etenkin suuria kuormia välittävillä kuularuuveilla väsymis- ja kulumismurtumat ovat yleisin vikojen syy. Vika voi alkaa esimerkiksi pienestä pistemäisestä lohkeamasta kuulamutterin kuulauran pinnassa. Lohkeamat muuttuvat kuitenkin nopeasti vakavammiksi vioiksi, sillä lohkeamat kasvavat eksponentiaalisesti toiminnassa olevassa kuularuuvissa. [3]

Esijännityksen häviämällä tarkoitetaan sitä, kun komponentit kuluvat käytössä ja niiden välillä vallitseva alkuperäinen puristusvoima häviää (kuva 3). Voiman häviäminen johtaa kuularuuvin tarkkuuden ja jäykkyyden menettämiseen sekä kuormankantokyvyn heikkenemiseen, jolloin kuularuuvi todennäköisemmin pettää käytössä. Kuluman edetessä tästä vielä eteenpäin, esijännitys katoaa täysin ja komponenttien välille muodostuu välystä. Silloin kuularuuvin tarkkuus laskee merkittävästi, sillä liikkeen alkuun ja suunnanvaihtoon muodostuu viivettä [3]. Lääketeollisuuden tarkoissa tuotantojärjestelmissä esijännityksen häviäminen ja välyksen muodostuminen vaikuttavat siten huomattavasti tuotannon laatuun.



Kuva 3: a) esijännitys ruuvin ja mutterin välillä b) esijännityksen häviäminen kuluman vuoksi. Muokattu tekijöiltä Gupta et al. [3]. Tekijänoikeus 2025 Elsevier Ltd.

Kuularuuvien jumittuessa kuulat eivät pääse vierimään kuulaurassa esimerkiksi plastisen muodonmuutoksen tai lian vuoksi. Siten kuulat alkavat liukumaan

kuulaurassa, mikä johtaa kitkan kasvamiseen, lämpötilan nousemiseen ja kuularuuvien hyötysuhteen laskemiseen arviolta jopa 45 prosentin verran. [3]

Vikojen muodostumiseen ja etenemiseen kuularuuveissa vaikuttavat esimerkiksi voitelu, lika, lämpötilojen vaihtelu, lämmönmuodostus ja kokoonpanovirheet.

Riittämätön tai liiallinen voitelu sekä lika lisäävät liikkeen kitkaa eli lisäävät kulumista ja laskevat järjestelmän tehokkuutta. Lämpötilaerojen aiheuttama laajeneminen ja supistuminen sekä kokoonpanovirheet taas aiheuttavat epätasaisuutta ja jännityksen jakautumista virheellisesti. [3]

Myös resonanssi voi olla syynä kuularuuvien vikoihin, jos järjestelmässä tapahtuvan impulssin taajuus on yhtä suuri järjestelmän resonanssitaajuuden kanssa. Tällöin impulssi toimii herätteenä järjestelmän resonanssille. Impulsseja syntyy esimerkiksi kuulien iskeytyessä urien seinämiin niiden suunnan ja nopeuden muutoksen vuoksi. Pahimmillaan resonanssi voi hajottaa mekanismin, minkä vuoksi on tärkeää seurata, että impulssien taajuus pysyy huomattavasti järjestelmän resonanssitaajuutta pienempänä. [15]

Pyörivien servomoottorien toimintakunnolla on vaikutusta järjestelmän tehokkuuteen ja turvallisuuteen, minkä vuoksi myös niille hyödynnetään usein tehokkaaksi todettua värähtelyanalyysiä [12,13]. Servomoottorien viat liittyvät tavallisesti viallisiin laakereihin tai hammaspyöriin, epätasapainoiseen roottoriin, linjausvirheisiin tai resonanssiin. Arviolta 40–90 prosenttia vioista on kuitenkin laakerivikoja, joita aiheuttavat esimerkiksi materiaalien väsyminen, kontaminaatio, kokoonpanovirheet ja vääränlainen voitelu [16]. Laakerivioilla voidaan tarkoittaa kuulissa, ulkokehällä, sisäkehällä tai pitimessä esiintyviä vikoja, kuten lohkeamia tai korroosiota [12]. Nämä voidaan tunnistaa signaalista jaksoittain toistuvasta kuviosta, joka syntyy pyörivän liikkeen seurauksena [16].

Linjausvirheillä tarkoitetaan komponenttien pyörimisakselien poikkeamista tavoitteena olleesta linjauksesta. Virhe vaikuttaa laitteen tehokkuuteen, vikojen muodostumiseen sekä laitteen luotettavuuteen. Tämän vuoksi linjausvirheitä diagnosoidaan usein esimerkiksi värähtelyanalyysin avulla. [12]

Servomoottorien käyttöolosuhteilla eli esimerkiksi kosteudella, lämpötilan vaihteluilla ja liialla on vaikutusta ilmeneviin vikoihin. Nämä voivat lisätä huoltojen määrää ja kustannuksia, lyhentää laitteen käyttöikää sekä heikentää hyötysuhdetta ja turvallisuutta. Esimerkiksi kosteus aiheuttaa korroosiota ja lisää kulumista, kun taas lämpötilan vaihtelu aiheuttaa lämpölaajenemista ja voiteluaineen viskositeettimuutoksia. Lisäksi lika nopeuttaa kulumista sekä lisää kitkaa. [12]

2.6 Värähtely

Värähtelyllä tarkoitetaan kappaleen liikettä tasapainoasemansa ympärillä.

Yksinkertaisimmillaan se voi olla esimerkiksi jaksollista sinimuotoista vapaata liikettä, jolloin se on muodoltaan

$$x(t) = X \cos(\omega t - \phi), \quad (1)$$

jossa liikkeeseen vaikuttavia tekijöitä ovat siirtymä X , kulmataajuus ω , aika t ja vaihekulma ϕ . [2]

Keskeisiä käsitteitä värähtelyyn liittyen ovat siirtymä X , amplitudi A , jaksonaika T , taajuus f , kulmataajuus ω ja vaihekulma ϕ . Siirtymä tai poikkeama X kuvaa liikkeen suuruutta tasapainoasemaansa nähden ja amplitudi A sen suurinta saavuttamaa arvoa. Jaksonajalla T taas kuvataan aikaa, joka kuluu yhteen värähdykseen. Sen käänteisluku eli taajuus f kertoo vastaavasti liikkeiden määrän tietyn ajan sisällä, kuten kaavassa 2 on esitetty.

$$f = \frac{1}{T} \quad [2] \quad (2)$$

Taajuus voidaan ilmoittaa myös kulmataajuutena. Silloin taajuuden yksikkö ei ole enää hertsi [Hz], vaan radiaanien suuruus sekuntia kohti [rad/s]. Kulmataajuus saadaan laskettua taajuudesta kaavalla

$$\omega = 2\pi f, \quad (3)$$

josta nähdään yhden värähdyksen olevan suuruudeltaan 2π radiaania. Siten kulmataajuudesta saadaan kiertokulman suuruus aikayksikköä kohti. Kaksi värähtelyä

voivat olla kulmataajuudeltaan yhtä suuria, mutta värähtelyjen vaiheet poikkeavat silti toisistaan. Silloin vaiheiden välinen ero voidaan ilmoittaa vaihekulmana ϕ . [2]

Värähtelyn voimakkuus voidaan ilmoittaa siirtymä-, nopeus- tai kiihtyvyyssamplitudina, riippuen mitattavista taajuuksista ja mittaustulosten käyttökohteista. Syynä tähän on näiden välinen yhteys, jonka mukaan siirtymän ensimmäinen derivaatta on nopeus ja toinen derivaatta kiihtyvyys. Kaavoissa 4 ja 5 esitetään, miten siirtymän derivointi vaikuttaa kaavan 1 mukaisen värähtelyn muotoon. Derivointi lisää siis taajuuden merkitystä, sillä ensimmäinen derivaatta kertoo funktion kulmataajuudella ja toinen derivaatta kulmataajuuden neliöllä.

$$v = \frac{dX}{dt} = -\omega X \sin(\omega t - \phi) \quad (4)$$

$$a = \frac{d^2X}{dt^2} = -\omega^2 X \cos(\omega t - \phi) \quad [2] \quad (5)$$

Värähtely voi olla vapaata tai pakotettua, mutta tässä tutkielmassa tarkastellaan laitteiden pakkovärähtelyä. Tällöin värähtelyn syynä on komponentteihin vaikuttavat ulkoiset voimat. Ne ylläpitävät jatkuvaa värähtelyä niin kauan, kuin voimat vaikuttavat komponentteihin. Vapaasta värähtelystä poiketen pakkovärähtely muuttuu silloin muotoon

$$x(t) = \frac{F_0}{\sqrt{(c\omega)^2 + (K - m\omega^2)^2}} \cos(\omega t - \phi), \quad (6)$$


jossa F_0 on ulkoinen voima, c vaimennusvakio, ω ulkoisen voiman kulmataajuus, K jousivakio ja m massa [2]. Kaavasta 6 on nähtävissä etenkin, miten värähtelyyn vaikuttaa nyt myös ulkoinen voima sekä vaimennus pelkän kaavan 1 siirtymän sijaan.

Jokaisella kappaleella on oma ominaistajuutensa, joka ilmenee toisen värähtelyn osuessa samalle taajuudelle ominaistajuuden kanssa. Tällöin toinen värähtely alkaa vahvistamaan kappaleen värähtelyä eli saa aikaan resonanssin. Toisen värähtelyn amplitudi voi olla erittäin pieni, mutta aiheuttaa silti suuren amplitudin nousun kappaleessa ja siten pahimmillaan hajottaa kappaleen. Laitteilla ominaistajuuksia voi olla useampia, mikä tekee resonanssista entistä haitallisemman ja vaikeamman ilmiön. [2]

Värähtelyn mittaamisessa vääränlainen näytteenottoväli T_s aiheuttaa vääristymiä mitattuun värähtelysignaaliin. Nyquist-Shannonin näytteenottoteoreeman mukaan näytteenottoväli tulee suhteuttaa signaalin jaksonaikaan T siten, että näytteenottoväli on vähemmän kuin jaksonajan puolikas. Koska jaksonaika on taajuuden f käänteisluku, voidaan näytteenottoteoreeman lause esittää myös taajuuden ja näytteenottotaajuuden f_s avulla muodossa

$$T_s < \frac{T}{2} \Rightarrow f_s > 2f. [17] \quad (7)$$


Jos näytteenotto ei noudata Nyquist-Shannonin esittämää kaavaa eli näytteenottotaajuus on liian harva, todellista signaalia ei pystytä muodostamaan saatujen näytteiden pohjalta laskostumisen vuoksi. Tällöin liian harva näytteenottotaajuus saa mitatun signaalin taajuuden näyttämään harvemmalta eli värähtelyn todellista hitaampana (kuva 4). [17]



Kuva 4: Näytteenottotaajuuden vaikutus signaalin muodostamiseen.

2.7 Värähtelyanalyysimenetelmät

Mittauksessa käytetyt parametrit määrittävät, minkälainen kuvaaja datan pohjalta voidaan muodostaa. Yleisimmin värähtelyn kuvaamiseen käytetään aika- tai taajuustasokuvaajia. Aikatasokuvaajassa kuvataan amplitudia ajan funktiona (kuva 5a), kun taas taajuustasokuvaajassa kuvataan amplitudia taajuuden funktiona (kuva 5b). Taajuustasokuvaajat ovat yleisempiä, koska niistä vikojen ja komponenttien havaitseminen on yksinkertaisempaa. Tämä johtuu siitä, että jokainen komponentti värähtelee tietyllä taajuusalueella ja taajuustasokuvaajasta taajuusalueet ovat selvästi eroteltavissa. Siten kuvaajaan muodostuvan vikakuvion taajuuden perusteella pystytään selvittämään vian lähde [13]. Aika- ja taajuustasojen lisäksi signaali pystytään esittämään näiden yhdistelmänä aika-taajuustasokuvaajassa. Yleensä kuvaaja näyttää silloin spektrogrammilta (kuva 5c), joka muodostuu tiettyjen matemaattisten muunnoksien seurauksena ja on aika- ja taajuustasokuvaajia informatiivisempi kuvaajamuotonsa vuoksi [16].



Kuva 5: Esimerkkisignaalin $f(t) = \sin(2\pi \cdot 50t) + 0,6(\sin(2\pi \cdot 120t))$ a) aikatasokuvaaja b) taajuustasokuvaaja FFT-muunnoksella c) aika-taajuustasokuvaaja (spektrogrammi).

Mittauksesta saatua värähtelysignaalia voidaan muokata, jotta se on selkeämmin luettavissa. Silloin signaalista voidaan esimerkiksi erottaa taajuuspiikkejä, vähentää kohinaa tai poistaa haluttuja taajuuksia. Hyödynnettävissä on monenlaisia, eri tilanteissa hyödyllisiä menetelmiä, sillä tietynlaiset viat aiheuttavat omanlaisensa kuvion värähtelysignaalissa. Mahdollisimman luotettavan analyysin tekemiseen tulisi käyttää jopa useampaa kuin yhtä analyysimenetelmää [13]. Jokaisella järjestelmän komponentilla on oma värähtelytaajuutensa, jonka amplitudi pysyy vakiona silloin, kun komponentin toimintakunto ei muutu [6]. Laitteen komponenttien ja niiden yleisten vikatyypin mukaan voidaan siis pohtia, miten komponenttien viat näkyvät signaalissa eli millaisiin asioihin tulisi kiinnittää huomiota. Siten voidaan valita järjestelmälle soveltuvin analyysimenetelmä, josta tällaiset vikatyypit ovat helpoimmin ja tehokkaimmin havaittavissa.

2.7.1 Root mean square, crest factor ja kurtosis

Amplitudien mittaaminen ja analysointi on tärkeää, sillä niiden muutokset kertovat usein muodostuvista vioista [6]. Aikatasokuvaajassa amplitudin suuruutta voidaan mitata joko nollakohdan ja amplitudin välisenä erotuksena (zero-to-peak), kahden amplitudin välisenä erotuksena (peak-to-peak) tai RMS-arvona (root mean square). Amplitudin suuruuden muutoksia taas voidaan havainnoida crest factorin CF ja kurtosiksen Ku avulla. RMS-arvo signaalille $y(t)$ lasketaan kaavalla

$$y_{rms} = \sqrt{\frac{\int_0^T y^2(t) dt}{T}}, \quad (8)$$

jossa t on aika ja T jaksonaika. Amplitudin huippuarvon y_{peak} ja RMS-arvon y_{rms} suhdetta kuvataan crest factorilla CF kaavan 9 mukaisesti [18].

$$CF = \frac{y_{peak}}{y_{rms}} \quad (9)$$

Amplitudin suuruuden vaihtelua voidaan havainnoida myös kurtosiksen Ku avulla kaavalla

$$Ku = \frac{M_4}{M_2^2} = \frac{\frac{1}{p} \sum_{i=1}^p (y_i - \bar{y})^4}{\left(\frac{1}{p} \sum_{i=1}^p (y_i - \bar{y})^2\right)^2}, \quad (10)$$

jossa M on keskusmomentti, p mittauspisteiden määrä, y_i yksittäisen signaalin arvo ja \bar{y} signaalin keskiarvo. Kurtosis on siis neljännen keskusmomentin suhde toisen keskusmomentin neliöön. Kurtosis voi olla erittäin tehokas menetelmä impulssimaisten vikojen havaitsemiseen, sillä usein sen arvo nousee huomattavasti impulssien kohdalla. Yleensä impulssit aiheuttavat myös crest factorin nousun ja RMS-arvon laskun. Muutokset ovat kuitenkin huomattavasti maltillisempia kurtosiksen muutokseen verrattuna [18]. Kuularuuvien viat esiintyvät useimmiten juuri tällaisina impulssimaisina vikakuvioina värähtelysignaalissa [14].

2.7.2 Fourier-muunnos

Fourier-muunnos on matemaattinen integraalimuunnos, jonka avulla aikatasosignaali pystytään muuntamaan taajuustasoon eli esittämään taajuuksien amplitudit.

Matemaattisesti aikatasofunktion $x(t)$ Fourier-muunnos on muodoltaan

$$F\{x(t)\} = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt, \quad (11)$$

jossa t on aika, j imaginaariyksikkö $\sqrt{-1}$ ja f taajuus. Fourier-muunnoksesta on kehitetty muutamia erilaisia muunnelmia, joita ovat esimerkiksi nopea Fourier-muunnos (FFT), lyhytaikainen Fourier-muunnos (STFT) ja diskreetti Fourier-muunnos (DFT). [19]

FFT on DFT:stä kehitetty laskennallisesti yksinkertaisempi ja nopeampi muunnos. FFT laskee tehokkaasti signaalin DFT:n ja käänteismuunnoksen stationaarille signaalille eli signaalille, jonka tilastolliset ominaisuudet eivät muutu ajan myötä. FFT:tä voidaan käyttää joko yksinään tai osana muuta analyysimenetelmää. Matemaattisesti FFT käsittelee signaalia parillisten ja parittomien osien summuna muodossa

$$X(k) = \sum_{n=0,2,4\dots}^{N-2} x(n)e^{-\frac{j2\pi nk}{N}} + \sum_{n=1,3,5\dots}^{N-1} x(n)e^{-\frac{j2\pi nk}{N}}, \quad (12)$$

jossa N mittauksen määrä, n mittauksen järjestysluku, k taajuusindeksi. Usein FFT:tä hyödynnetään, kun analyysimenetelmässä aikatasosignaali tulee muuntaa taajuustasoon tai toisinpäin. FFT:n heikkous on sen spektrivuoto, jossa energia leviää viereisille taajuuksille vääristäen muodostuvaa spektriä. [16]

STFT:ssä signaali jaotellaan ajallisesti samanpituisiin ikkunoihin, joihin jokaiseen tehdään Fourier-muunnos erikseen. Yhdessä ikkunat muodostavat muunnoksen tuloksena signaalille aika-taajuusspektrin. STFT signaalille $x(t)$ saadaan kaavalla

$$STFT\{x(t)\} = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j2\pi ft} dt, \quad (13)$$

jossa w on ikkunafunktio ja τ ikkunan aikamuuttuja [16]. Verrattaessa tavallisen Fourier-muunnoksen kaavaan (kaava 11), STFT:ssä on siis matemaattisesti erona vain lisäys ikkunafunktiosta.

STFT:n hyviä puolia ovat yksinkertaisuus ja helppo toteutettavuus sekä laskennallinen tehokkuus ja nopea signaalin käsittely [20]. STFT sopii laakerivikojen tunnistamiseen, mutta sen suurin heikkous on resoluutio. Jokaisessa osiossa ikkuna on samankokoinen, joten aika- ja taajuusresoluutiot ovat kiinteitä. Leveällä ikkunalla on siten korkea taajuusresoluutio, mutta matala aikaresoluutio, ja kapealla ikkunalla matala taajuusresoluutio ja korkea aikaresoluutio [21]. Toisaalta STFT:n taajuusresoluutiota on kuvattu myös tehokkaaksi [20].


2.7.3 Aallokemuunnos

Aallokemuunnos on Fourier-muunnosta monipuolisempi, sillä se sisältää useampia toteutustapoja ja pystyy esittämään signaalin sekä aika- että taajuustasossa. Muunnos toteutetaan skaalaamalla suodattimen kaistanleveyttä siten, että kaistanleveys levenee taajuuden pienentyessä ja kapenee taajuuden kasvaessa. Silloin korkeille taajuuksille aikaikkuna on kapea ja kaistanleveys leveä, joten voidaan havaita, millä ajanhetkellä signaali on saanut tietyn amplitudinsa. Matalille taajuuksille taas aikaikkuna on pitkä ja kaistanleveys kapea eli havaitaan tarkkaan, mikä taajuus on kyseessä. Aallokemuunnos voidaan jakaa osiin: diskreetti aallokemuunnos (DWT), jatkuva aallokemuunnos (CWT) ja aallokepakettimuunnos (WPT). [19]

Kuva 6 esittää esimerkkisignaalin aikatasokuvaajan ja siitä saatavan aallokemuunnoksen spektrogrammin. Aikatasokuvaajasta on havaittavissa, että amplitudi pysyy lähes vakiona ja signaalin taajuus kasvaa ajan funktiona.

Spektrogrammista voidaan todeta samat asiat, mutta sen lisäksi havaitaan amplitudin

taajuuden kasvun olevan lineaarista. Nämä asiat havaitaan tummimman alueen leveyden pysymisestä vakiona ja sen lineaarisesta kasvusta.



Kuva 6: Esimerkkisignaalin aikatasokuvaaja ja sen aallokemuunnoksen spektrogrammi.

DWT on erittäin käytännöllinen menetelmä kuularuuvien urien toimintakunnon valvonnassa, sillä vikojen havaitsemisen lisäksi sitä hyödyntämällä pystytään arvioimaan vian etenemistä. Menetelmä mahdollistaa samanaikaisesti vikataajuuksien havaitsemisen matalista taajuuksista, niiden etenemisen ennustamisen amplitudien avulla sekä korkeataajuuksisten vikasignaalien ajanhetken tunnistamisen. DWT erottelee signaalia siten, että siitä pystytään tunnistamaan säännöllisesti toistuvat värähdykset tietyllä taajuudella. Tämän jälkeen amplitudin suuruutta ja kasvua tarkkailemalla pystytään arvioimaan vian etenemistä, sillä yleensä taajuuden amplitudi kasvaa vian edetessä. Ajanhetken tunnistaminen on hyödyllistä esimerkiksi, jos ruuvin kuulaurassa on lohkeama. Silloin ajan avulla pystytään tarkasti paikantamaan lohkeama ruuvilla [14]. Lisäksi DWT:tä pystytään käyttämään kohinan poistamiseen ja signaalin pakkaamiseen [16]. DWT soveltuu hyvin pyörivien koneiden toimintakunnon analysointiin ja on laskennallisesti suhteellisen tehokas. Kuitenkin suurin heikkous on,

ettei signaalista pystytä esittämään informaatiota jatkuvasti CWT:n tapaan, sillä DWT ei laske muunnosta erikseen jokaiselle taajuudelle. [22].

CWT muuntaa myös signaalin aika-taajuustasoon, minkä vuoksi aikaa ja taajuutta on mahdollista tarkastella samanaikaisesti. Analyysin jatkuvuuden vuoksi CWT soveltuu kuitenkin paremmin signaalin vaihteluihin ja on tarkka äkillisten iskujen havaitsemisessa [20]. Nämä piirteet taajuuskomponenttien suodattamisen lisäksi tekevät CWT:stä hyvän menetelmän laakerien, roottorien sekä hammaspyörien kunnonvalvonnassa [16]. Käytännön toteutuksessa ilmenee kuitenkin CWT:n heikkous, joka on jatkuvasta skaalautuvuudesta johtuva laskennallinen hitaus sekä tehottomuus [22].

DWT:n laajennettu versio on WPT, jossa poikkeuksellisesti jokaisesta signaalin yksityiskohdasta muodostetaan approksimaatio- ja yksityiskohtasignaali. Siten signaali saadaan approksimoitua paremmin ja tuloksena signaalista saadaan tarkempi. Approksimaatiosignaali sisältää alipäästösuodattimella erotellut signaalin matalat taajuudet ja yksityiskohtasignaali ylipäästösuodattimella erotellut korkeat taajuudet [16]. WPT kompensoi DWT:n rajoitetta, joka on huono soveltuvuus korkeille taajuuksille. WPT:n soveltuessa korkeille taajuuksille, sen omaksi heikkoudeksi muodostuu huonompi soveltuvuus alkeille vioille sekä useammalle yhtäaikaiselle vialle. WPT:llä saadaan kuitenkin tehokkaasti tunnistettua pyörivien koneiden vikoja, kuten hammaspyörien tai laakerien toimintakunnon heikkeneminen [22].

2.7.4 Hilbert-muunnos


HT eli Hilbert-muunnos on integraalimuunnos, joka soveltuu Fourier-muunnosta monimutkaisemmille signaaleille. Tämä johtuu siitä, että Fourier-muunnos olettaa signaalin olevan siniaaltojen summa, kun taas HT olettaa signaalin koostuvan yhdestä vääristyneestä siniaallosta. Funktion $x(t)$ Hilbert-muunnos saadaan muodostettua kaavalla

$$H\{x(t)\} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\eta)}{t-\eta} d\eta, \quad (14)$$

jossa t on aika ja η ajasta riippuva integroimismuuttuja. HT on siis integraali signaalin arvon ja aikavälin erotuksen suhteesta. Kahden peräkkäisen HT:n avulla signaalin vaihetta voidaan siirtää π :n verran, ja neljällä peräkkäisellä HT:llä saadaan takaisin alkuperäinen signaali. HT:n avulla pystytään muodostamaan analyttinen signaali eli kompleksinen signaali, jonka reaaliosa on alkuperäinen signaali ja imaginaariosa HT. Aikatasokuvaaja voidaan muodostaa analyttisestä signaalista kahdella tavalla, riippuen halutaanko kuvaaja analyttisestä signaalista vai sen itseisarvosta. Varsinaisen analyttisen signaalin kuvaaja muodostuu reaali- ja imaginaariosan summasta, kun taas analyttisen signaalin itseisarvon kuvaaja eli signaalin verhokäyrä muodostuu reaali- ja imaginaariosan neliöiden summan neliöjuuresta. [23]

2.7.5 Verhokäyräanalyysi

Verhokäyräanalyysi (EA) hyödyntää Hilbert-muunnosta muodostaakseen kuvaajan, josta havaitaan signaalin suurimmat amplitudit tietyillä ajanhetkillä [23]. Signaalin ylä- ja alapuolelle pystytään muodostamaan verhokäyrä, joka seuraa signaalin hetkellisten amplitudien vaihtelua (kuva 7). Lisäksi aikatasokuvaajasta saataisiin muodostettua verhokäyrän spektri FFT:n avulla [21].



Kuva 7: Verhokäyrä esimerkksignaaliin $f(t) = 1 + 0,5 \cdot \sin(2\pi \cdot 50t)$ käyttäen Hilbert-muunnosta.

Suodattimia hyödyntäen signaalista voidaan rajata pois ylimääräistä kohinaa, jolloin vikataajuuksien amplitudipiikit erottuvat selkeämmin signaalista [13]. Menetelmä edistää iskujen ja muiden satunnaisten vikasignaalien amplitudien vaihtelun havaitsemista, soveltuen hyvin etenkin laakerivikojen havaitsemiseen. Muihin aika-taajuustasoa esittäviin analyysimenetelmiin verrattuna verhoikäyräanalyysi on tehokas, suoraviivainen ja helposti toteutettava. Menetelmä ei kuitenkaan ole optimaalisin alkavien vikojen tunnistamiseen [24].

Verhoikäyräanalyysin toteuttamista hankaloittaa, että ennen analyysiä tulisi tietää valmiiksi järjestelmän resonanssitaajuus sekä suodatettava taajuusalue.

Resonanssitaajuus tulee tietää ennakkoon, sillä kaistanpäästösuodattimen keskitaajuus tulee asettaa samalle taajuudelle resonanssitaajuuden kanssa [21]. Suodatettava taajuusalue on tärkeä määrittää huolellisesti ennen analyysiä, jotta suodattimet poistavat vain ylimääräisiä taajuuksia eivätkä kadota tärkeää dataa [13].

2.8 Tekoäly- ja koneoppimismenetelmät

Koneoppiminen on yksi tekoälyn osa-alue, jossa koneoppimismallit oppivat datan avulla parantamaan itse suorituskykyään. Mallit voidaan jaotella niiden tyyppien mukaan ohjattuun, puoliohjattuun, ohjaamattomaan ja vahvistusoppimiseen. Keskeisin ero mallien välillä on siinä, minkälaista opetusdataa malleille käytetään. Ohjatuille malleille käytetään valmiiksi luokiteltua dataa, ohjaamattomille luokitteluamatonta ja puoliohjatuille kummankin yhdistelmää. Vahvistusoppimisille ei käytetä valmista opetusdataa, vaan mallit oppivat ympäristöstä itse keräämänsä datan ja palautteen avulla. [25]

Koneoppimismalleja hyödyntämällä analyysimenetelmästä voidaan saada tarkempi, sopeutumiskykyisempi ja skaalautuvampi. Tekoälyä hyödyntämättömiä perinteisempiä analyysimenetelmiä käytetään kuitenkin vielä, koska ne ovat laskennallisesti kevyempiä ja vaativat vähemmän resursseja sekä koulutusdataa. Analyysi on kuitenkin manuaalista, minkä vuoksi se on myös epätarkempaa ja sopeutuu huonommin signaalin vaihteluihin. [26]

Servomootoreille tyypillisten vikojen havaitsemista on tutkittu useissa koneoppimismallien tutkimuksissa. Belgradin yliopiston julkaisemassa tutkimuksessa tutkittiin erilaisten koneoppimismallien kykyä jaotella laakerit kolmeen luokkaan vikojen perusteella. Parhaiten suoriutunut gradient boosting (GB) tunnisti laakeriviat parhaiten (99,5 %), minkä lisäksi adaboost (AB), random forest (RF), k-nearest neighbours (KNN), ja decision tree (DT) saavuttivat lähes yhtä korkean (98,7–99,4 %) tarkkuuden. Huonoiten suoriutunut support vector machine (SVM) tunnisti tutkimuksessa laakeriviat vain 43,8 prosentin tarkkuudella [27]. Prajapati et al. (2025) tekemässä tutkimuksessa taas tutkittiin linjausvirheitä, epätasapainoa ja laakerivikoja SVM:llä, jolloin tarkkuudeksi saatiin 98 prosenttia [26].

Myös koneoppimismalleja käytettäessä olisi suositeltavaa yhdistää useampi analyysimenetelmä. Siten koneoppimismallin heikkouksia pystyttäisiin paikkaamaan toisen analyysimenetelmän avulla. Tutkimuksissa hyviä tuloksia oli havaittu esimerkiksi jatkuvan aallokemuunnoksen (CWT) ja artificial neural networkin (ANN) sekä decision treen (DT) ja diskreetin aallokemuunnoksen (DWT) yhdistelmistä, joissa molemmissa toinen oli tekoälyä hyödyntävä koneoppimismalli ja toinen perinteisempi analyysimenetelmä. [16]

3 Tulokset

Kirjallisuuskatsauksessa tarkasteltiin kuula- tai johtoruuvivälityksellä toimivan servomoottorin järjestelmää sekä sen värähtelyanalyysiä lääketeollisuuden toimintaympäristössä. Laitteiston yleisimpien vikojen tuntemisen todettiin olevan tärkeää, jotta vikojen aiheuttamia kuvioita osataan etsiä signaalista sekä valita havaitsemista tukevat analyysimenetelmät. Kuularuuvin viat ovat kulumisesta ja väsymisestä johtuvia murtumia, esijännityksen häviämistä, välyksen muodostumista ja jumittumista. Servomoottorin viat taas ovat pääasiassa laakerivikoja, mutta myös hammaspyörän ja roottorin vikoja sekä linjausvirheitä. Näiden vikatyypin vuoksi järjestelmän signaalista tulee siis ensisijaisesti etsiä impulsseja sekä jaksottaisesti toistuvia vikakuvioita.

Värähtelyanalyysin on todettu olevan erittäin hyödyllinen menetelmä niin kuularuuvien kuin servomoottorienkin keskuudessa. Lisäksi monilla eri teollisuudenaloilla värähtelyanalyysi on osoitettu toimivaksi ja tehokkaaksi menetelmäksi ennakoivassa kunnossapidossa. Vaikka lääketeollisuuden laitteistoihin kohdistuu muita teollisuudenaloja tiukempaa sääntelyä ja korkeampia tarkkuusvaatimuksia, ne eivät luo estettä analyysimenetelmien käyttöönotolle. Tämän perusteella voidaan todeta, että värähtelyanalyysin käyttö on mahdollista myös servo-ohjatuilla lääketeollisuuden laitteilla, niin ennakoivan kunnossapidon kuin prosessin optimoinninkin kannalta. Ennakoivalla kunnossapidolla saavutettavien hyötyjen, kuten tuottavuuden tehostamisella ja huoltojen optimoinnilla saavutettaisiin samalla myös prosessin optimointi. Käyttöönotossa tulee huomioida erityisesti tuotantolaitteita ja -tiloja koskevat sääntelyt, mutta käytöllä saavutettavissa olevat parannukset edistävät samalla myös sääntelyiden noudattamista. Tällaisia ovat esimerkiksi laadun varmistaminen ja turvallisuuden takaaminen.

Taulukko 1 kokoaa yhteen erilaisten värähtelyanalyysimenetelmien hyötyjä ja rajoituksia kirjallisuuskatsauksen pohjalta lähteistä [13,14,16,19–24]. Jokainen esitelty analyysimenetelmä soveltuu tutkielmassa tutkitulle johto- tai kuularuuvin ja servomoottorin muodostamalle järjestelmälle. Menetelmien välillä on kuitenkin

havaittavissa eroja esimerkiksi analyysin tehokkuuden, suorituskyvyn ja rajoitusten osalta.

Taulukko 1: Värähtelyanalyysimenetelmien hyödyt ja rajoitukset.

Menetelmä	Hyödyt	Rajoitukset
Nopea Fourier-muunnos (FFT)	+ Aikatason muuntaminen taajuustasoon + Laskennallisesti nopea, yksinkertainen ja tehokas	- Spektrivuoto - Pääasiassa vain stationaariselle signaalille
Lyhytaikainen Fourier-muunnos (STFT)	+ Yksinkertainen ja helppo toteuttaa + Laskennallisesti nopea ja tehokas + Tehokas resoluutio + Etenkin laakerivikojen havaitsemiseen	- Skaalautumaton, kiinteä resoluutio
Diskreetti aallokemuunnos (DWT)	+ Vian paikantaminen ja etenemisen arviointi + Soveltuu matalille taajuuksille + Kohinan poisto ja signaalin pakkaaminen + Laskennallisesti suhteellisen tehokas + Säännöllisesti toistuville vikasignaaleille: kuularuuvit, pyörivät koneet	- Signaalin jatkuvan informaation puute
Jatkuva aallokemuunnos (CWT)	+ Soveltuu signaalin vaihteluun + Impulssien havaitseminen + Soveltuva laakeri-, roottori- ja hammaspyörävioille	- Laskennallisesti hidaskäyttö ja tehoton
Aalokepakettimuunnos (WPT)	+ Tarkempi kuin DWT + Korkeille taajuuksille + Pyörivien koneiden vioille: laakeri- ja hammaspyöräviat	- Tehoton alkavien vikojen sekä useiden samanaikaisten vikojen havaitsemisessa
Verhokäyrä-analyysi (EA)	+ Suodattimien käyttö: kohinanpoisto + Impulssien ja satunnaisten vikasignaalien havaitseminen: esim. laakeriviat + Muihin verrattuna tehokas, suoraviivainen ja helppo toteuttaa	- Resonanssitaajuus ja suodatettava taajuus tulee tietää ennakkoon - Heikko alkavien vikojen tunnistamisessa

Taulukon 1 perusteella Fourier-muunnoksien (FFT, STFT) voidaan todeta olevan muita menetelmiä yksinkertaisempia, mutta kuitenkin nopeita ja tehokkaita perusmenetelmiä värähtelyanalyysin toteuttamiseen. Aallokemuunnoksen alalajeilta löytyy useampia hyötyjä, joista jokaista yhdistää aika-taajuustasokuvaajan muodostuminen. Eroja on kuitenkin siinä, että diskreetti aallokemuunnos (DWT) soveltuu etenkin säännöllisesti toistuville vikasignaaleille, jatkuva aallokemuunnos (CWT) iskujen havaitsemiseen ja aalokepakettimuunnos (WPT) korkeammille taajuuksille kuin DWT.

Verhokäyräanalyysissä (EA) hyvinä puolina nousivat esiin signaalin muokkausmahdollisuus ja tehokkuus, mutta silti yksinkertaisuus ja helppous muihin menetelmiin verrattaessa.

Soveltuvimpina menetelminä taulukon 1 perusteella näyttäytyvät diskreetti aallokemuunnos sekä verhokäyräanalyysi. Diskreetti aallokemuunnos mahdollistaa vikojen paikantamisen ja arvioinnin sekä signaalin muokkaamisen kuitenkin laskennallisesti suhteellisen tehokkaasti. Verhokäyräanalyysi taas tarjoaa erittäin informatiivisen menetelmän suhteessa sen suoraviivaiseen toteutukseen.

Laakerivikojen, eli tutkitulle järjestelmälle tyypillisten vikojen tunnistamisessa suorituskkyiseksi koneoppimismalliksi todettiin gradient boosting. Lisäksi decision treen havaittiin olevan tehokas niin yksin käytettynä laakerivioille kuin myös yhdistettynä toisen analyysimenetelmän kanssa. Siten näiden koneoppimismallien voidaan katsoa soveltuvan myös tutkitulle järjestelmälle. Decision treen ja diskreetin aallokemuunnoksen yhdistelmä osoittautui tutkimuksissa toimivaksi ratkaisuksi, mikä tukee suositusta useamman eri analyysimenetelmän samanaikaisesta hyödyntämisestä.

4 Pohdinta

On selvää, että lääketeollisuuden sääntelyiden asettamien haasteiden vuoksi värähtelyanalyysin toteutuksessa tulee olla tarkempi kuin muilla teollisuudenaloilla. Sääntelyiden lisäksi haasteita käytännön toteutukselle tuo komponenttien aseman ja kuorman vaihtelu sekä järjestelmän lyhyt, jatkuvasti suuntaa vaihtava liike.

Värähtelyanalyysin käytön hyötyjä voidaan pohtia turvallisuuden, laadun ja talouden näkökulmasta. On laitteisto- ja sovelluskohtaista, miten hyödyllistä värähtelyanalyysi on näistä näkökulmista tarkasteltuna. Taloudellinen hyöty riippuu esimerkiksi värähtelyanalyysin käyttöönoton ja käytön kustannuksista, kunnossapitokustannusten muutoksesta sekä värähtelyanalyysin käyttöajasta. Läketeollisuudessa tärkeää on myös laadun ja turvallisuuden takaaminen, sillä niillä on yhteys niin työntekijöiden kuin potilaidenkin turvallisuuteen. Niiden hyötyjä ei kuitenkaan pystytä mittaamaan yhtä selkeästi kuin hyötyjä kustannusten osalta.

Kirjallisuuskatsauksen perusteella soveltuvimpien perinteisten analyysimenetelmien, diskreetin aallokemuunnoksen (DWT) ja verhoikäyräanalyysin (EA) rajoituksina on jatkuvan informaation puute, tarve asettaa suodattimet ennakkoon ja huono soveltuvuus alkaville vioille. Nämä rajoitukset eivät kuitenkaan ole ylitsepääsemättömiä. Suodattimen asetuksia ei tarvitse muuttaa jatkuvasti asettamisen jälkeen ja esitellyistä analyysimenetelmistä vain jatkuva aallokemuunnos (CWT) tarjoaa jatkuvaa informaatiota signaalista. Lisäksi viat pystytään havaitsemaan riittävän ajoissa myös tuntemalla järjestelmän tyypilliset viat ja vikakuviot.

Tekoäly kehittyi jatkuvasti, minkä vuoksi myös koneoppimismallit kehittyvät niiden rinnalla. Tämän vuoksi koneoppimisen hyödyntäminen värähtelyanalyysissä olisi kannattavaa kehityksen mukana pysymiseksi. Koneoppimismallit olivat saaneet hyviä tuloksia servomoottorien vikatyyppejä tutkivissa tutkimuksissa. Tuloksissa oli kuitenkin eroavaisuuksia erityisesti support vector machinen (SVM) osalta sen saadessa tarkkuudeksi eri tutkimuksissa 43,8 prosenttia ja 98 prosenttia. Tutkimuksissa ei kuitenkaan tutkittu täysin samanlaisia vikatyyppejä, mikä korostaa etenkin koneoppimismallien soveltuvuuden riippumista vikatyypeistä sekä analyysimenetelmien käytännön testaamisen tarvetta.

Jotta värähtelyanalyysi lääketieteellisyydessä voitaisiin ottaa käyttöön, tulisi aihetta testata käytännössä ja varmistaa oikeanlaisten analyysimenetelmien soveltuminen. Teoreettisesti voidaan kuitenkin todeta, että värähtelyanalyysiä on mahdollista hyödyntää ennakoivassa kunnossapidossa ja prosessin optimoinnissa servo-ohjatuilla lääketieteellisuuden laitteilla. Tutkitulle järjestelmälle eli johto- tai kuularuuville ja servomoottorille soveltuvimpina menetelminä näyttävät diskreetti aallokemuunnos, verhokäyräanalyysi, gradient boosting ja decision tree.

Lähteet

- [1] O. Manchadi, F.-E. Ben-Bouazza, A. Edder, I. Tafala, B. Jioudi, Predictive Maintenance in Pharma Manufacturing: Challenges and Strategic Directions, in: 7th Edition of the International Conference on Advanced Technologies for Humanity (ICATH 2025), MDPI, 2026: p. 80.
<https://doi.org/10.3390/engproc2025112080>.
- [2] R.K. Mobley, An introduction to predictive maintenance, 2nd ed, Butterworth-Heinemann, Amsterdam London New York [etc.], 2002.
- [3] H. Gupta, T. Mian, P. Kundu, Review of condition monitoring approaches for ball screws, *Advanced Engineering Informatics* 71 (2026) 104206.
<https://doi.org/10.1016/j.aei.2025.104206>.
- [4] Y. Maher, B. Danouj, Survey on Deep Learning applied to predictive maintenance, *IJECE* 10 (2020) 5592. <https://doi.org/10.11591/ijece.v10i6.pp5592-5598>.
- [5] E. del Castillo Marasco, *Process optimization: a statistical approach*, Springer, New York, 2007.
- [6] R.K. Mobley, ed., *Maintenance engineering handbook*, 8th ed, McGraw-Hill, New York, 2014.
- [7] World Health Organization, *Good Manufacturing Practices*, (2026).
<https://www.who.int/teams/health-product-policy-and-standards/standards-and-specifications/norms-and-standards/gmp> (accessed April 18, 2026).
- [8] S. Cetinkunt, *Mechatronics with Experiments*, 1st ed, John Wiley & Sons, Incorporated, Newark, 2015.
- [9] P.R.N. Childs, M.A. Masen, Fastening and power screws, in: *Mechanical Design Engineering Handbook*, Elsevier, 2025: pp. 705–762.
<https://doi.org/10.1016/B978-0-443-22077-7.00011-9>.
- [10] A. Hughes, B. Drury, *Electric motors and drives: fundamentals, types and applications*, 5th edition, Newness, Oxford, 2019.
- [11] C.F. Beards, ed., *Engineering vibration analysis with application to control systems*, Edward Arnold, London, 1995.
- [12] T.R. Govindaswamy, R. Ramadoss, A Review of Various Fault Diagnosis and RUL Estimation Techniques for Predictive Maintenance in Industrial Rotating

- Machinery, *J. Vib. Eng. Technol.* 14 (2026) 75. <https://doi.org/10.1007/s42417-025-02322-6>.
- [13] T. Chu, T. Nguyen, H. Yoo, J. Wang, A review of vibration analysis and its applications, *Heliyon* 10 (2024) e26282. <https://doi.org/10.1016/j.heliyon.2024.e26282>.
- [14] W.G. Lee, J.W. Lee, M.S. Hong, S.-H. Nam, Y. Jeon, M.G. Lee, Failure Diagnosis System for a Ball-Screw by Using Vibration Signals, *Shock and Vibration* 2015 (2015) 1–9. <https://doi.org/10.1155/2015/435870>.
- [15] J.Z. Sobolewski, Vibration of the ball screw drive, *Engineering Failure Analysis* 24 (2012) 1–8. <https://doi.org/10.1016/j.engfailanal.2012.03.002>.
- [16] H. Ahmed, A.K. Nandi, Condition monitoring with vibration signals: compressive sampling and learning algorithms for rotating machines, Wiley/IEEE Press, Hoboken, NJ, USA, 2020.
- [17] J. Tuma, Vehicle gearbox noise and vibration: measurement, signal analysis, signal processing, and noise reduction measures, John Wiley & Sons Inc, Chichester, West Sussex, United Kingdom, 2014. <https://doi.org/10.1002/9781118797563>.
- [18] J.K. Sinha, Vibration Analysis, Instruments, and Signal Processing, 1st ed, Taylor & Francis Group, London, 2014.
- [19] S. Mohammady, ed., Wavelet Theory, IntechOpen, Erscheinungsort nicht ermittelbar, 2021.
- [20] P. Kumar, S. Khalid, H. Kim, Prognostics and Health Management of Rotating Machinery of Industrial Robot with Deep Learning Applications—A Review, *Mathematics* 11 (2023) 3008. <https://doi.org/10.3390/math11133008>.
- [21] A. Boudiaf, A. Djebala, H. Bendjma, A. Balaska, A. Dahane, A summary of vibration analysis techniques for fault detection and diagnosis in bearing, in: 2016 8th International Conference on Modelling, Identification and Control (ICMIC), IEEE, Algiers, Algeria, 2016: pp. 37–42. <https://doi.org/10.1109/ICMIC.2016.7804187>.
- [22] J. Chen, Z. Li, J. Pan, G. Chen, Y. Zi, J. Yuan, B. Chen, Z. He, Wavelet transform based on inner product in fault diagnosis of rotating machinery: A review,

- Mechanical Systems and Signal Processing 70–71 (2016) 1–35.
<https://doi.org/10.1016/j.ymssp.2015.08.023>.
- [23] M. Feldman, Hilbert transform in vibration analysis, *Mechanical Systems and Signal Processing* 25 (2011) 735–802.
<https://doi.org/10.1016/j.ymssp.2010.07.018>.
- [24] J.E. Ruiz-Sarrio, J.A. Antonino-Daviu, C. Martis, Comprehensive Diagnosis of Localized Rolling Bearing Faults during Rotating Machine Start-Up via Vibration Envelope Analysis, *Electronics* 13 (2024) 375.
<https://doi.org/10.3390/electronics13020375>.
- [25] A. Nandi, A.K. Pal, Interpreting machine learning models: Learn model interpretability and explainability methods, Apress, Berkeley, CA, 2022.
<https://doi.org/https://doi.org/10.1007/978-1-4842-7802-4>.
- [26] R.R. Prajapati, B.A. Parekh, N.V. Chauhan, Z.J. Barad, H.B. Prajapati, Machine Vibration Analysis Using Machine Learning, in: 2025 4th OPJU International Technology Conference (OTCON) on Smart Computing for Innovation and Advancement in Industry 5.0, IEEE, Raigarh, India, 2025: pp. 1–6.
<https://doi.org/10.1109/OTCON65728.2025.11070797>.
- [27] N. Jebur, W. Soud, Wear fault diagnosis in journal bearings using vibration analysis and AI, *FME Transactions* 53 (2025) 401–408.
<https://doi.org/10.5937/fme2503401J>.