LAPPEENRANNAN TEKNILLINEN YLIOPISTO
SÄHKÖTEKNIIKAN OSASTO

Jatkuvatoimisen sellukeittimen säätöjen suorituskyvyn analysointi

Diplomityön aihe on hyväksytty Lappeenrannan teknillisen yliopiston Sähkötekniikan osaston osastoneuvoston kokouksessa 8.3.2006.

Työn tarkastajat: Professori Olli Pyrhönen ja TkT Riku Pöllänen
Työn ohjaaja: DI Juha Oksanen

Lappeenrannassa 24.4.2006

Ari Koponen
Punkkerikatu 8 as. 31
53850 Lappeenranta
p. +35850-556 2790

TIIVISTELMÄ

Lappeenrannan teknillinen yliopisto
Sähkötekniikan osasto

Ari Koponen

Jatkuvatoimisen sellukeittimen säätöjen suorituskyvyn analysointi
Diplomityö
2006

98 sivua, 37 kuvaa, 13 taulukkoa ja 3 liitettä

Tarkastajat: Professori Olli Pyrhönen
TkT Riku Pöllänen

Hakusanat: säädön suorituskyky, jatkuvatoimisen sellukeittimen säätö, aikasarjamallit
Keywords: control performance, continuous pulp digester control, time series models

Työssä tarkastellaan yleisiä menetelmiä säätöpiirien suorituskyvyn analysointiin ja sovelletaan niitä jatkuvatoimisen sellukeittimen säätöihin. Esitellyt menetelmät tarjoavat keinoja myös huonon säätötuloksen syyn selvittämiseen ja vinkkejä paremman suorituskyvyn saavuttamiseksi.

Analyysissä edettiin top-down periaatteen mukaisesti lähtien liikkeelle keittimen tärkeimmästä säädöstä eli kappaluvun säädöstä. Sitten etsittiin tähän vaikuttavia tekijöitä mitatuista suureista. Seuraavaksi arvioitiin tärkeimmäksi katsotun tekijän (hakepinnankorkeus) säädön suorituskyky, jossa havaittiin parannettavaa. Lopuksi hakepinnankorkeuden säädön viritystä muutettiin ja tehtiin identifiointikoe säätörakenteen uudelleen järjestelyä varten.

ABSTRACT

Lappeenranta University of Technology
Department of Electrical Engineering

Ari Koponen

Control performance assessment of continuous pulp digester
Master's thesis
2006

98 pages, 37 figures, 13 tables and 3 appendices

Examiners: Professor Olli Pyrhönen
D.Sc. Riku Pöllänen

Keywords: control performance, continuous pulp digester control, time series models

This study examines general methods for control loop performance assessment and applies them to the continuous pulp digester controls. The presented methods provide also means to determine the root causes for poor performance and guidelines how to improve the control performance.

The main controlled variable in pulp digester is the Kappa number. The analysis was started from the Kappa number control and proceeded in a top-down fashion. The main contributing factors were sought using the measurement data. The chip level was determined to be one of the most important factors contributing to the Kappa number variability. Next, the chip level control performance was assessed and it was found to be performing poorly. The chip level controller was re-tuned and an identification test was performed for the upcoming chip level control re-arrangement.

SISÄLLYSLUETTELO

1 JOHDANTO **7**

2 KEITTOPROSESSI **8**

2.1 Sellun keitto 9

2.1.1 Kehittyneitä keittomenetelmiä 12

2.2 Keiton hallinta 13

2.3 Hakevirta ja tuotantonopeus 14

2.4 Imeytystornin ja keittimen hakepinnat 14

2.5 Kemikaalien annostus 17

2.6 Kappaluvun säätö 18

2.7 Keitinpesu 21

2.8 Tutkimuskohteen keittimen säädöt 21

2.8.1 Keittokemikaalien annostus 22

2.8.2 Imeytystornin ja keittimen hakepinnankorkeudet 23

2.8.3 Keittimen lipeäpinnankorkeus 23

2.8.4 Pesukerroin 23

2.8.5 Kappaluku 24

2.8.6 Tuotantonopeus 25

2.9 Muita säätömenetelmiä 26

3 SÄÄTÖPIIRIEN SUORITUSKYVYN MITTAAMINEN **27**

3.1 Minimivarianssisäätö ja -indeksi 28

3.2 Minimivarianssin estimointi 31

3.2.1 Aikasarjamallit 32

3.2.2 Input-output mallit 33

3.2.3 Aikasarjamallien identifiointi 34

3.3 Häiriöiden etsintä ja eliminointi 41

3.3.1 Korrelaatioanalyysi 42

3.3.2 Häiriöiden voimakkuuden arvioiminen 47

3.4 Tehospektri 60

3.4.1 Tehospektrin estimointi 62

4 KEITTIMEN SÄÄTÖJEN ANALYSOINTI 68

4.1 Tiedonkeruu 68

4.2 Takaisinkytketty kappaluvun säätö 71

4.3 Kappalukuun vaikuttavien häiriöiden etsintä 77

4.4 Keittimen hakepinnankorkeuden säädön arviointi 84

4.4.1 Hakepinnankorkeuden ja puskuvirtauksen välisen siirtofunktion identifiointi 89

5 JOHTOPÄÄTÖKSET JA YHTEENVETO 94

VIITTEET 96

LIITTEET

1. Normalisoituja impulssivasteita kappalukuun

2. Hakepinnankorkeuden minimivarianssianalyysin kuvat

3. Normalisoituja impulssivasteita hakepinnan korkeuteen

Merkinnät

$A(q^{-1})$	siirtofunktion nimittäjäpolynomi
$B(q^{-1})$	siirtofunktion osoittajapolynomi
C	konsentraatio
c	aikasarjamallin yksikköympyrällä olevien napojen määrä
$c_{xx}(k)$	signaalin $x(n)$ autokovarianssiestimaatti
$c_{xy}(k)$	signaalien $x(n)$ ja $y(n)$ välinen ristikovarianssiestimaatti
d	viive
$e(n)$	säätöpoikkeama
F	tilavuusvirtaus
$G(q^{-1})$	siirtofunktio
H	H-tekijä
H_0	tilastollisen testauksen nollahypoteesi
$H(q^{-1})$	siirtofunktio
$h(k)$	impulssivaste
j	imaginääriyksikkö
k	viiveindeksi, reaktionopeuskerroin
L	ligniinipitoisuus
m	mitattujen häiriöiden lukumäärä
N	näytemäärä
n	diskreetti aikaindeksi
$P_{xx}(\omega)$	signaalin $x(n)$ tehospektrin estimaatti
p	aikasarjamallin napojen määrä
$p(x)$	todennäköisyystiheysfunktio satunnaismuuttujan arvolla x
Q	residuaalien riippumattomuuden tarkastelussa käytetty testisuure
q^{-1}	siirto-operaattori
$r(n)$	asetusarvo
$r_{xx}(k)$	signaalin $x(n)$ autokorrelaatioestimaatti
$r_{xy}(k)$	signaalien $x(n)$ ja $y(n)$ välinen ristikorrelaatioestimaatti
T	lämpötila

t	aika
$u(n)$	prosessin ohjaussuure
$v(n)$	valkoista kohinaa
$w(n)$	häiriösignaali
$y(n)$	prosessin lähtösuure
z	aikasarjamallin nollien määrä

Kreikkalaiset

α	riskitaso
$\Gamma_{xx}(\omega)$	signaalin $x(n)$ tehospektri
$\gamma_{xx}(k)$	signaalin $x(n)$ autokovarianssifunktio
$\gamma_{xy}(k)$	signaalien $x(n)$ ja $y(n)$ välinen ristikovarianssifunktio
$\delta(k)$	yksikköimpulssifunktio
η	säädön suorituskykyindeksi
μ	odotusarvo
$\rho_{xx}(k)$	signaalin $x(n)$ autokorrelaatiofunktio
$\rho_{xy}(k)$	signaalien $x(n)$ ja $y(n)$ välinen ristikorrelaatiofunktio
σ	keskihajonta
ω	diskreetti kulmataajuus

Ala- ja yläindeksit

BT	Blackman-Tukey
c	säädin
cl	takaisinkytketty systeemi
dead	kuollut aika
e	mallinnusvirhe
eff	efektiivinen
fb	takaisinkytkentään liittyvä
ff	myötäkytkentään liittyvä
ff/fb	sekä myötä- että takaisinkytkentään liittyvä
mv	minimivarianssi
p	prosessi
pw	esivalkaisu
r	reaktionopeus

Lyhenteet

AIC	Akaike's Information Criterion
AR	Autoregressive
ARIMA	Autoregressive Integrated Moving Average
DMT	Dynamic Modelling Technique
EKF	Extended Kalman Filter
FIR	Finite Impulse Response
FPE	Final Prediction Error
GUIDE	Graphical User Interface Development Environment
HIC	Honeywell Infocenter
IIR	Infinite Impulse Response
LTI	Linear Time Invariant
MA	Moving Average
MDL	Minimum Description Length
MIMO	Multiple Input Multiple Output
MPC	Model Predictive Controller
QP	Quadratic Programming
SISO	Single Input Single Output

1 JOHDANTO

Automaatiojärjestelmät ovat olennainen osa nykyisiä tuotantolaitoksia. Niiden tehtävänä ovat prosessin ohjaus sekä mittaustiedon kerääminen ja sen jalostaminen prosessia valvovien operaattoreiden käyttöön. Automaatiojärjestelmät koostuvat tietokoneista, niitä yhdistävistä verkoista ja ohjelmistosta, joka toteuttaa prosessin ohjauksen. Prosessin ohjauksen toteuttava ohjelmisto sisältää järjestelmän ”älyn”.

Prosessin ohjauksen merkitystä tuotannon tehokkuuteen ei usein nähdä kovin merkityksellisenä. Signaalit, joita prosessin ohjaus käsittelee, eivät ole käsin kosketeltavia, maisteltavia eikä haisteltavia toisin kuin vaikkapa lopputuotteen määrä, jonka yleensä pystyy jollain tavalla ihmisaistein havaitsemaan, ellei kyseessä satu olemaan entsyymit tai bakteerit. Automaatiojärjestelmän käsittelemät signaalit ovat kuitenkin sellaisia, joiden mukaan prosessin toimilaitteet (venttiilit, moottorit, pumput, puhaltimet jne.) toimivat. Prosessin toimilaitteilla vaikutetaan suoraan prosessin lopputuotteeseen. Tuotannon tehokkuuden kannalta on siis merkitystä sillä, kuinka toimilaitteita ohjataan.

Säädöt eivät välttämättä pysy vireessä koko tuotantolaitoksen elinkaaren ajan, vaikka ne olisi toimitusvaiheessa viritettykin kuntoon. Syitä on lukuisia. Säätöjärjestelmä voi muuttua esimerkiksi toimilaitteiden tai mittalaitteiden kulumisen seurauksena. Kun uusi toimi- tai mittalaite vaihdetaan, se voi toimia hieman eri tavalla kuin aikaisempi. Myös itse säädettävä prosessi voi muuttua ajan saatossa esimerkiksi toisenlaiseen raaka-aineeseen siirtymisen vuoksi. Kaikki nämä muutokset vaikuttavat säätöjärjestelmään ja siten sen suorituskykyyn. Siksi on oltava käyttökelpoisia suorituskyvyn mittareita, joilla prosessin tilaa pystytään monitoroimaan. Kun indikaatio huonosta suorituskyvystä saadaan, ongelmiin voidaan reagoida.

Tämän työn tavoitteena oli selvittää keinoja säätöjärjestelmien suorituskyvyn analysointiin ja soveltaa niitä jatkuvatoimisen sellukeittimen säätöihin. Koska prosessi on tunnettava ennen kuin sitä voidaan säätää, työssä on luotu katsaus sellun keittoon ja keittimen säätöön kirjallisuuden ja tieteellisten artikkelien pohjalta. Säätöpiirien suorituskykyä tarkastellaan pääasiassa stokastiseen säätöteoriaan pohjautuvien menetelmien avulla.

2 KEITTOPROSESSI

Puun tultua sellutehtaalle se kuoritaan ja haketetaan. Kuorinnan ja lajittelun jälkeen hake kuljetetaan keittoon, jonka tarkoituksena on poistaa puukuituja yhteensitovaa ligniiniä. Keiton jälkeistä ligniinipitoisuutta eli ns. jäännösligniiniä kuvataan usein kappaluvulla. Mitä alhaisempi kappaluku on, sitä vähemmän massassa on ligniiniä jäljellä. Ligniiniä ei kuitenkaan poisteta keittovaiheessa kokonaan, koska liian pitkä keitto heikentää massan muita ominaisuuksia kuten lujuutta ja vähentää saantoa. Tästä syystä massan kappaluvulle asetetaan jokin tietty tavoitearvo, johon keitolla pyritään. Keiton ja sen säädön tavoitteena on tuottaa kappaluvultaan mahdollisimman tasalaatuista sellua, sillä laatuvaihteluiden kompensointi myöhemmissä prosessivaiheissa kuluttaa kalliita raaka-aineita ja energiaa. [1]

Keittoprosessin päävaiheet ovat pasutus, imeytys ja keitto. Pasutuksella pyritään poistamaan hakepaloissa oleva ilma, joka haittaa imeytystä. Imeytyksessä hakepalat kyllästetään keittokemikaaleilla. Keitossa poistetaan pääosa puun ligniinistä, jotta kuidut saadaan erilleen toisistaan. Prosessiteknisesti nämä vaiheet voidaan toteuttaa erilaisilla ratkaisuilla. Seuraavassa esitellään yksi menetelmä.

Hake tuodaan ensin puskurisäiliönä toimivaan hakesiiloon. Pasutus voidaan aloittaa jo hakesiilossa tuomalla sen pohjaan kuumaa höyryä. Pasutus jatkuu pasutusastiassa normaalissa ilmanpaineessa. Keittoprosessiin syötettävää hakevirtaa ohjataan hakeruuvilla tai -mittarilla. Pasutusastiasta hake siirtyy syöttökaulaan, jossa se kohtaa keittokemikaalit. Keittimen paine on huomattavasti normaalia ilmanpainetta korkeampi. Hake syötetään keittimen paineeseen korkeapainekiikin avulla. Korkeapainekiikkiin liittyy kaksi kiertoa: matalapaineinen kaulakierto ja korkeapaineinen siirtokierto. Kaulakierrossa erotellaan hakkeen seasta prosessiin kuulumattomia esineitä pois. Siirtokierto kuljettaa hake-lipeäseosta imeytystorniin. Prosessiin tulevat keittokemikaalit voidaan syöttää korkeapainepumppujen avulla siirtokiertoon. Haketta syötetään keittimen syöttökiertoon imeytystornin pohjassa olevalla pohjakaavarilla. Apuna toimii imeytystornin pohjaan syötettävä pohjalaimennus. Syöttökierto vie hake-lipeäseoksen keittimen huipulla olevaan huippuruuviin, joka erottaa hakkeen ja lipeän. Hake ohjataan keittimeen ja lipeä palaa imeytystorniin. Massa poistuu

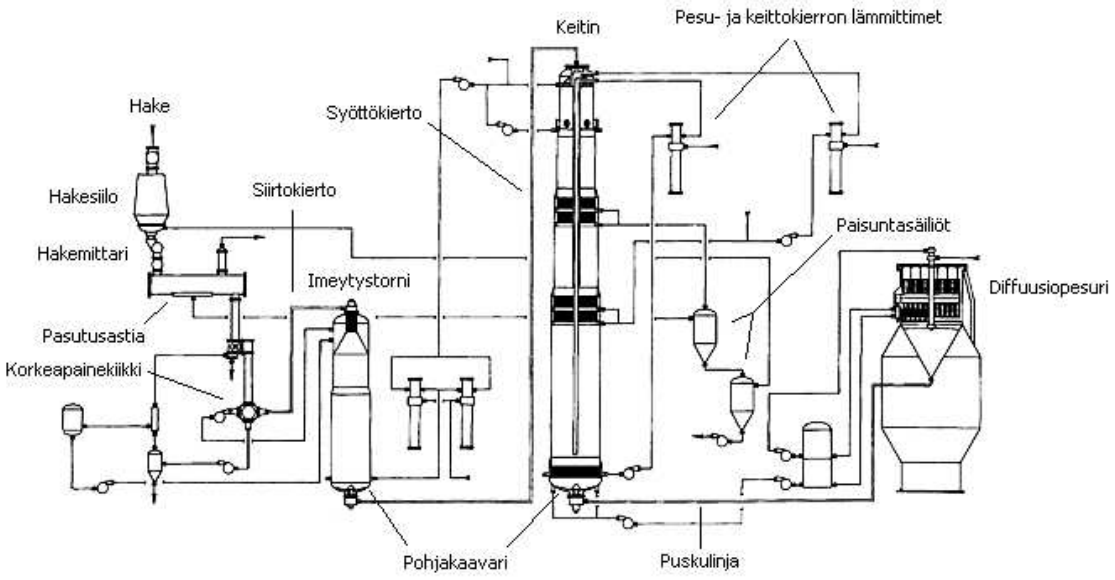

Kuva 2.1 Tyypillisen kaksiastiaisen keittimen prosessiympäristö. Hake saapuu hakesiiloon, josta se syötetään hakeruuvilla tai -mittarilla pasutusastiaan. Sieltä hake kulkee syöttökaulaan, jossa se kohtaa keittolipeän. Alapuolella oleva korkeapainekiikki syöttää massan korkeapaineiseen siirtokiertoon, joka kuljettaa sen imeytystorniin. Lämmön ja paineen vaikutuksesta keittokemikaalit diffusoituvat hakepalojen sisään. Massa syötetään imeytystornin pohjasta pohjakaavarin ja pohjalaimennuksen avulla syöttökiertoon, joka vie sen keittimen huipulle. Keitetty massa poistuu keittimestä sen pohjassa olevasta puskulinjasta. Seuraava prosessivaihe on massan pesu. [1]

keittimestä sen pohjassa olevasta puskulinjasta, jolloin puumassan kuidut erottuvat toisistaan. Edellä kuvattu prosessi on esitetty kuvassa 2.1. Tällaista keittoprosessia kutsutaan kaksiastiaiseksi, koska imeytys ja keitto tapahtuvat erillisissä astioissa.

Keiton jälkeisiä vaiheita ovat sellun pesu, happidelignifiointi ja valkaisu. Valkaistu sellu voidaan joko kuivata ja paalata kuljettamista varten tai se voidaan pumpata paperi- tai kartonkitehtaalle [1, 2].

2.1 Sellun keitto

Ligniiniä voidaan erottaa useilla erilaisilla keittokemikaaleilla. Tässä työssä keskitytään sulfaattikeittoon, jossa keittokemikaalina käytetään valkolipeää. Sen reagoivina aineina ovat natriumhydroksidi (NaOH) ja natriumsulfidi (Na_2S). Valkolipeään

liukenee keiton aikana erilaisia yhdisteitä, jotka värjäävät sen tummaksi. Siksi reagoinutta valkolipeää kutsutaan mustalipeäksi. [2]

Keittotapoja on kaksi päätyyppiä: erä- ja vuokeitto. Eräkeitossa hake ja keittokemikaalit ovat keiton ajan suljetussa keittoastiassa, josta ne pumpataan tai pusketaan keiton jälkeen pois. Eräkeitossa keitetään siis haketta erä kerrallaan. Vuokeitossa sen sijaan sekä hake että keittokemikaalit kulkevat jatkuvana virtana keittimen läpi. Tässä työssä keskitytään vuokeittoon ja sen säätöön.

Vuokeittimiä on kahta tyyppiä: neste-höyryfaasikeitin ja hydraulinen keitin. Erona näillä on se, että hydraulinen keitin on täynnä nestettä, kun taas neste-höyryfaasikeittimessä lipeäpinta on hakepintaa alempana. Näin jälkimmäisen keitintyypin yläosaan muodostuu höyryfaasi.

Vuokeittimissä on useita vyöhykkeitä, joiden määrä vaihtelee keitinmallista riippuen. Hakevirtaus on kaikissa vyöhykkeissä alaspäin, mutta keittokemikaalien virtaussuunnat vaihtelevat. Perinteisen keitinmallin vyöhykkeet ovat keittimen yläosasta lukien imeytys, myötävirtakeitto ja vastavirtapesu. Tätä keittomenetelmää kutsutaan konventionaaliseksi.

Imeytys voidaan toteuttaa joko erillisessä astiassa (imeytystorni) tai sitten varsinaisen keittimen ensimmäisessä osassa. Tämän perusteella keittimet jaotellaankin yksi- ja kaksiastiaisiin keittimiin. Imeytyksessä keittokemikaalit tunkeutuvat huokoiseen puuhun n. 100 - 130 °C lämpötilassa [2]. Imeytyksen onnistumisen kannalta oleellisin tekijä on hakelastun paksuus, sillä se määrää matkan, jonka keittonesteen on diffusoiduttava hakkeen sisään [1].

Keittovyöhykkeessä tapahtuu varsinainen ligniinin poistaminen. Ligniinin liukenemisreaktiolle on kehitelty useita erilaisia malleja, joista yksinkertaisin lienee ns. H-tekijä, joka yhdistää keittoajan ja lämpötilan [1, s. 292]:

$$H = \int_0^t k_\mathrm{r} dt, \tag{2.1}$$

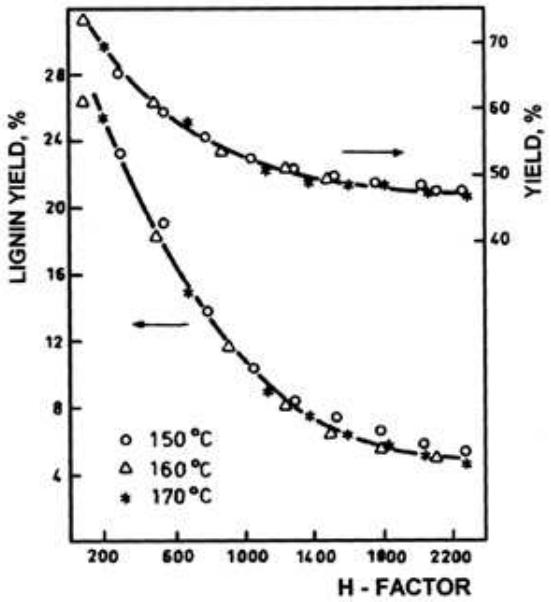

Kuva 2.2 Jäännösligniinin (lignin yield) ja keiton saannon (yield) riippuvuus H-tekijästä [1].

missä reaktionopeuskerroin k_r on

$$k_\mathrm{r} = e^{43,2-\frac{16115}{T}}, \tag{2.2}$$

t on keittoaika ja T [K] on keittolämpötila. Jäännösligniinipitoisuus voidaan esittää eri puulajeille ja alkalipitoisuuksille H-tekijän funktiona. Yksi esimerkki tällaisesta käyrästä on kuvassa 2.2. H-tekijä ei kuitenkaan ota huomioon mitenkään keittokemikaalien ominaisuuksia. Yksityiskohtaisempi kineettinen malli on esimerkiksi Gustafssonin malli, joka jakaa delignifioitumisen kolmeen vaiheeseen: alku-, pää-, ja jäännösdelignifioitumiseen. Esimerkiksi pohjoismaiselle männylle, jonka alkuperäinen ligniinipitoisuus on 27 %, on saatu laboratorio-oloissa seuraavanlaiset yhtälöt [1, s. 293]. Alkudelignifioitumisessa

$$\frac{dL(t)}{dt} = k_\mathrm{il} L(t) e^{17,5-\frac{8760}{T}}, \tag{2.3}$$

missä k_{il} on puulajista riippuva vakio ja $L(t)$ on ligniinipitoisuus hetkellä t. Pääde-lignifioitumisessa

$$\frac{dL(t)}{dt} = k_{\mathrm{bl}_0} C_{\mathrm{OH}^-} L(t) e^{35,5-\frac{17200}{T}} + k_{\mathrm{bl}_1} C_{\mathrm{OH}^-}^{0,5} C_{\mathrm{HS}^-}^{0,4} L(t) e^{29,4-\frac{14400}{T}}, \tag{2.4}$$

missä k_{bl_0} ja k_{bl_1} ovat puulajikohtaisia vakioita, C_{OH^-}on hydroksyyli-ionien konsentraatio ja C_{HS^-}on hydrosulfidi-ionien konsentraatio. Jäännösdelignifioinnissa ligniini liukenee nopeudella

$$\frac{dL(t)}{dt} = k_{\mathrm{rl}} C_{\mathrm{OH}^-}^{0,7} L(t) e^{19,64-\frac{10804}{T}}, \tag{2.5}$$

missä k_{rl}on puulajista riippuva vakio.

Massan tullessa pesuvyöhykkeeseen keittymisreaktiot hidastuvat, koska lämpötila laskee siellä huomattavasti. Pesuvyöhykkeen tehtävä on katkaista keitto ja toimia ensimmäisenä massan pesuvaiheena. Keitinpesu erottaa tehokkaasti keittolipeään liuenneita aineita, koska lämpötila ja paine ovat korkeammat kuin keittimen jälkeisissä pesuvaiheissa. Pesuvyöhykkeessä pesulipeä virtaa keittimen pohjasta ylöspäin kohti paisuntasihtejä, joiden kautta mustalipeää ohjataan paisuntasäiliöihin. Paisunnan jälkeen mustalipeä kuljetetaan haihduttamolle ja sieltä edelleen kemikaalien regenerointiin.

2.1.1 Kehittyneitä keittomenetelmiä

Perinteisestä keittomenetelmästä on kehitetty ajan saatossa useita variaatioita:

- MCC (Modified Continuous Cooking)
- EMCC (Extended Modified Continuous Cooking)
- ITC (Isothermal Cooking)
- LSC (LoSolids Cooking)

Modifikaatioiden päämäärä on ollut tuottaa kappaluvultaan alhaisempaa sellua siten, että kuitujen vahvuus ei heikkene yhtä paljon kuin perinteisessä keitossa. Pääperiaatteena näissä menetelmissä on alkalikonsentraation parempi hallinta keiton eri

vaiheissa [1, s. A56]. Keiton alussa alkalikonsentraation tulisi olla alhainen ja sen tulisi nousta keiton loppua kohti. Tähän pyritään lisäämällä keittimeen keittolipeää useasta kohdasta.

2.2 Keiton hallinta

Prosessisäädön tavoitteena on aikaansaada mahdollisimman samanlaiset keitto-olosuhteet kaikille hakepaloille, jotta sellun laatu pysyisi tasaisena. Säädön toteutukselle haasteita asettavat mm. pitkä prosessiviive sekä lukuisat hankalasti mitattavat häiriöt. Keittymiseen vaikuttavat mm. seuraavat puun ominaisuudet [1]:

- kosteus
- puun ikä ja hakepalan sijainti rungossa
- lahonneisuusaste
- morfologiset ominaisuudet (kuitujen dimensiot ja kokojakauma)
- tiheys

Näitä ei voida käyttää aktiivisesti prosessisäädössä hyödyksi, koska niistä ei saada riittävän nopeasti näytteistettyä mittaustietoa. Prosessisäädöllä voidaan vaikuttaa keittotulokseen pääasiassa seuraavien tekijöiden avulla [1]:

- hakkeen dimensiot ja kokojakauma
- keittokemikaalien koostumus, annostus ja konsentraatio
- imeytysolosuhteet
- keittoaika ja lämpötila/lämpötilaprofiili

Hakkeen dimensioita ei luonnollisesti pystytä pitämään aivan samanlaisina, joten hakkeen palakoon vaihtelut ovat myös tuntematon häiriölähde säädölle. Se mihin tehdas pystyy kuitenkin vaikuttamaan on dimensioiden jakauma.

Yleensä keiton ohjaus ja säätö on jaettu usealle ylätason piirille, joilla pyritään jakamaan keittoprosessi erilaisiin itsenäisiin kokonaisuuksiin. Tällaisia kokonaisuuksia ovat mm. tuotantonopeus, kemikaalien annostus, imeytystornin ja keittimen hakepintojen säädöt, kappaluvun säätö ja vastavirtapesun hallinta [2, 3, 4]. Seuraavissa kappaleissa perehdytään näihin tarkemmin.

2.3 Hakevirta ja tuotantonopeus

Tuotantonopeutta eli hakevirran nopeutta prosessin läpi ohjataan pääasiassa hakesiilon alapuolella olevan hakeruuvin tai -mittarin pyörimisnopeudella. Tuotantonopeuden ohjaus on ensiarvoisen tärkeä, sillä se vaikuttaa suoraan moniin muihin keittimen säätöpiireihin muuttamalla niiden asetusarvoja. Esimerkiksi keittokemikaalien annostusta ja keittolämpötilaa muutetaan tuotantonopeuden vaihtuessa. Tuotantonopeus toimii siis ylätason säätönä näille piireille.

Hakeruuvin täyttöaste oletetaan yleensä vakioksi. Hakkeen pakkautumistiheys ruuvissa kuitenkin vaihtelee ja siten hakeruuvin täyttöaste vaihtelee. Näin hakkeen massavirta vaihtelee aiheuttaen häiriöitä keittymisessä, koska todellinen hakemäärä ei vastaa oletettua hakkeen määrää [2].

Seuraava tärkeä toimilaite hakevirran liikkumisen kannalta on korkeapainekiikki. Sen pyörimisnopeutta voidaan ohjata tuotantonopeuteen verrannollisena suureena tai se voidaan pitää myös vakiona [2].

2.4 Imeytystornin ja keittimen hakepinnat

Hakepintojen stabiloinnilla pyritään pitämään hakkeen keskimääräinen nopeus vakiona imeytystornissa ja keittimessä [4]. Nämä säädöt ovat siten tärkeitä keittymisen kannalta, koska ne vaikuttavat hakkeen viipymäaikoihin eri keittovyöhykkeissä.

Imeytystornin hakepintaa voidaan säätää tornin pohjakaavarin pyörimisnopeudella sekä pohjalaimennusvirtauksella [2]. Keittimen hakepintaan voidaan vaikuttaa useilla ohjausmuuttujilla. Tällaisia ovat puskuvirtaus, pohjakaavarin pyörimisnopeus sekä hakkeen syöttöä säätelevä hakeruuvin pyörimisnopeus [3]. Kuva 2.3 pyrkii

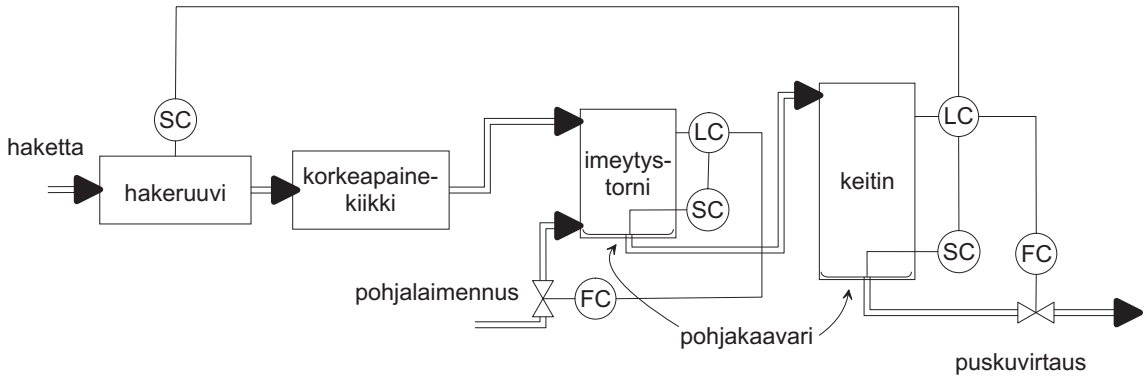

Kuva 2.3 Keittimen ja imeytystornin hakepintojen säädössä käytettäviä menetelmiä. Hakepintoja voidaan ohjata joko syöttöpuolelta hakeruuvin pyörimisnopeudella tai poistopuolelta pohjakaavarilla, pohjalaimennuksella tai puskuvirtauksella.

havainnollistamaan keittimen ja imeytystornin hakepintasäätöjä. Puskuvirtaus vaikuttaa keittimestä poistuvaan massavirtaan ja pohjakaavarin pyörimisnopeus vaikuttaa massan sakeuteen keittimen alaosassa. Edellä mainittuja ohjaussuureita voidaan käyttää eri yhdistelminä esimerkiksi siten, että hakeruuvin pyörimisnopeutta käytetään pääohjaussuureena ja puskuvirtausta muutetaan vasta kun hakeruuvi saavuttaa säätörajat. Lisäksi puskuvirtausta ohjataan tuotantonopeuden mukaan. Leiviskän [3, s. 75] mukaan tällainen säätöstrategia häiritsee vähiten keittimen toimintaa.

Hakepinnan säätöön on esitetty kirjallisuudessa erilaisia kehittyneitä menetelmiä. Esimerkiksi Allison ja Dumont [5, 6] ovat esittäneet adaptiivisten mallipredikiivisten (Model Predictive Controller, MPC) säädinten käyttöä hakepinnankorkeuden säädössä. Esitetyt tulokset ovat kuitenkin hieman ristiriitaisia. Ensin keittimen hakepintaa säädettiin pelkästään puskuvirtauksella [5]. Hakepinnan säätötulos parani (värähtelyt vähenivät) ja jäännösligniinipitoisuuden keskihajonnan havaittiin pienenenevän. Myöhemmin hakeruuvin pyörimisnopeus lisättiin toiseksi ohjausmuuttujaksi, jolloin puskuvirtauksen muutoksia saatiin pienennettyä jopa 50 % heikentämättä kuitenkaan hakepinnankorkeuden säädön suorituskykyä [6]. Tämän säätöstrategian käyttö lopetettiin kuitenkin puolen vuoden kokeilun jälkeen, koska kappaluvun hajonnan ei havaittu pienenevän vaan se näytti jopa kasvaneen. Syiksi tosin arveltiin mm. sitä, että tehtaalla oli kokeiltu tuona aikana erilaisia hakelaatuja.

Lindgren et al. [7] esittivät artikkelissaan katsauksen hakepinnan säädöstä julkaistuihin tutkimuksiin. Lisäksi esiteltiin mallipredikiivinen hakepinnan säätöstrategia kaksiastiaiselle neste-höyryfaasikeittimelle, joka tähtäsi keittimen pohjan olosuhteiden stabilointiin. MPC säätää sekä keittimen ja imeytystornin hakepinnankorkeutta että keittimen pohjan sakeutta. Keittimen hakepinnankorkeuden pääohjaussuureena käytetään hakeruuvin pyörimisnopeutta. Imeytystornin pinnankorkeutta säädetään tornin pohjalaimennuksella. Hakeruuvin pyörimisnopeuden ja keittimen hakepinnan välisen viiveen pienentämiseksi ja tuotantonopeuden muutosten vaikutusten vähentämiseksi hakeruuvin pyörimisnopeudesta otettiin myötäkytkentä imeytystornin pinnankorkeuden säätöön. MPC säätää keittimen pohjan sakeutta pohjakaavarin pyörimisnopeudella. Tarkkaan ottaen keittimen pohjan sakeutta ei säädetty suoraan vaan se tehtiin välillisesti säätämällä keittimen pohjan ja puskulinjan välistä paineeroa. Olennainen ajatus esitetyssä säätöstrategiassa on se, että keittimen puskuvirtausta pyritään muuttelemaan mahdollisimman vähän. Puskuvirtausta käytetäänkin lähinnä vain pitämään keittimen hakepinta hakeruuvin säätöalueella. Uutta säätöstrategiaa verrattiin alkuperäiseen, jossa pääohjausmuuttujana oli puskuvirtaus. Vaikka hakepinnankorkeuden vaihtelut eivät juuri vähentyneet niin puskuvirtauksen muutokset ja puskusakeuden keskihajonta pienenivät. Myös kappaluvun keskihajonta oli huomattavasti pienempi uudella säädöllä. Tekijät kuitenkin totesivat, että kappaluvun hajonnan pieneneminen saattaa selittyä muillakin tekijöillä kuten tasaisemmilla tuotanto-olosuhteilla.

Amirthalingam ja Lee [8] puolestaan tarkastelivat hakepinnan säätöä keittimen reaktiokinetiikkaa ja virtausdynamiikkaa kuvaavan simulaattorin avulla. Artikkelissa ehdotettiin, että hakepintaa ei välttämättä kannatakaan yrittää säätää kovin tarkasti, vaan sitä voitaisiin ennemminkin käyttää mallintamaan kappaluvun vaihteluita mm. keittolipeämittausten kanssa. Kun tätä mallia käytettäisiin kappaluvun säädössä, em. häiriöiden vaikutus kappalukuun voitaisiin kompensoida. Jos hakepinnan värähtelyt vaimennetaan täysin, niin tätä signaalia ei voida luonnollisesti käyttää enää kappaluvun ennustamiseen.

Hakepinnan säädössä pinnankorkeus voidaan mitata joko mekaanisilla tai neste-höyryfaasikeittimessä radiometrisillä antureilla. Radiometristä mittausta häiritsee

höyryfaasin seiniin kertyvä saostuma ja kuohaaminen [2]. Mekaaniset pinnankorkeusanturit ovat keittimen sisäpuolelle asennettuja lapoja, jotka mittaavat vääntömomenttia. Mitä enemmän haketta lavan päällä on, sitä suuremman kuormituksen se kohdistaa lapaan. Antureita on yleensä kolme tai enemmän ja ne asennetaan 1 - 2 metrin etäisyyksille toisistaan. Lapamittaukset ovat hyvin kohinaisia hakepilarin heterogeenisuudesta johtuen, joten yleensä kaikkien mittarien signaalit yhdistetään automaatiojärjestelmässä yhdeksi hakepinnankorkeussignaaliksi [5].

2.5 Kemikaalien annostus

Valkolipeä syötetään yleensä prosessiin keittimen ja/tai imeytystornin syöttökierrossa. Syötettävän valkolipeän määrä perustuu yleensä ns. alkaliannoksen laskentaan, jossa suhteutetaan alkalimäärä täysin kuivaan hakemäärään. Alkaliannoksen laskentaan on monia käytäntöjä mm. siksi, että alkalimäärä voidaan ilmaista tehollisena tai vaikuttavana alkalina. Kemikaalien annostuksen tavoitteena on saada aikaiseksi haluttu alkali-puusuhde keittimessä. Tarvittava lipeävirtaus voidaan laskea tuotantotason, halutun alkali-puusuhteen sekä valkolipeän väkevyyden avulla. Jos alkalia annostellaan useaan kohtaan prosessia, niin puhutaan alkaliprofiilin säädöstä. Muunnelluissa keittomenetelmissä tätä käytetään yleisesti. [2, 3]

Myös jäännösalkalipitoisuuksia voidaan säätää, jos keittimen kierroissa on tarvittavat alkaliväkevyysmittaukset. Tähän tarkoitukseen suunnitellun säätimen esittelivät Gough ja Kay [9]. Kuvattu säätö on adaptiivinen ja prediktiivinen. Adaptiivinen säädin mukautuu prosessissa tapahtuviin muutoksiin automaattisesti. Adaptiivisuus toteutettiin DMT-tekniikalla (Dynamic Modelling Technology) identifioitujen prosessimallien perusteella. DMT perustuu Laguerre-sarjakehitelmien käyttöön prosessin dynamiikan kuvaamisessa. Prosessin dynamiikka kuvataan Laguerre-sarjakehitelmällä [9]

$$g(t) = \sum_{i=1}^{\infty} c_i l_i(t), \tag{2.6}$$

missä c_i on painotuskerroin ja $l_i(t)$ on Laguerre-funktio, joka on muotoa

$$l_i(t) = \sqrt{2p}\frac{e^{pt}}{(i-1)!}\frac{d^{i-1}}{dt^{i-1}}\left[t^{i-1}e^{-2pt}\right], \tag{2.7}$$

missä p on Laguerre-napa. Laguerre-funktiot ovat ortonormaaleja. Tämän ansiosta parametrien etsimiseen voidaan käyttää tehokkaasti rekursiivisia pienimmän neliösumman algoritmeja. Rekursiivisilla menetelmillä voidaan toteuttaa mallin adaptiivisuus, koska niillä voidaan estimoida parametreja aina, kun saadaan uudet näytteet prosessista. Artikkelin mukaan Laguerre-sarjakehitelmillä prosessi voidaan mallintaa paremmin kuin perinteisillä Laplace-tason siirtofunktioilla.

Säätö- ja identifiointialgoritmia suoritti erillinen PC-tietokone, joka kytkettiin automaatiojärjestelmään sarjaliikenneyhteydellä. Säädin sai tämän välityksellä automaatiojärjestelmästä mm. mittauksen säädettävästä suureesta (vaikuttavan alkalin online-analysaattorilta) ja palautti automaatiojärjestelmään laskemansa ohjauksen alkali-puu -suhteen säätäjälle. Tehtaalla käytettiin mustalipeää selvittämään keittimessä ilmenneitä haketukoksia. Koska mustalipeä vaikuttaa alkalikonsentraatioon, niin mustalipeävirtausta käytettiin myös jäännösalkalin säädössä myötäkytkentänä. Kun säädin oli kytketty järjestelmään, se identifioi ensin tarvittavat siirtofunktiot ja muutaman viikon jälkeen se kytkettiin ohjaamaan prosessia. Säädön käyttöönoton seurauksena kappaluvun keskihajonta pieneni 3,76:sta 3,40:een eli noin 10 %. Tutkijat arvioivat, että tämä merkitsi tehtaalle noin 110 000 dollarin vuotuista säästöä.

2.6 Kappaluvun säätö

Kappaleessa 2.2 esiteltiin tapoja, joilla voidaan vaikuttaa keitetyn massan kappalukuun. Kemikaalien annostuksen ohjaus pyrkii vakioimaan kemikaaliannoksen ja tuotantonopeus asettelee keittoajan. Jäljelle jää siis vaikuttavaksi tekijäksi keittolämpötila. Keittolämpötilaan voidaan vaikuttaa keitintyypistä riippuen hieman eri tavoin. Menetelmää, jossa lämpötiloja muutetaan useammassa kohdassa keitintä, kutsutaan lämpötilaprofiilin säädöksi. Mahdollisia säädeltäviä lämpötiloja ovat siirtokierron, höyryfaasin, sekä keittokierron lämpötilat.

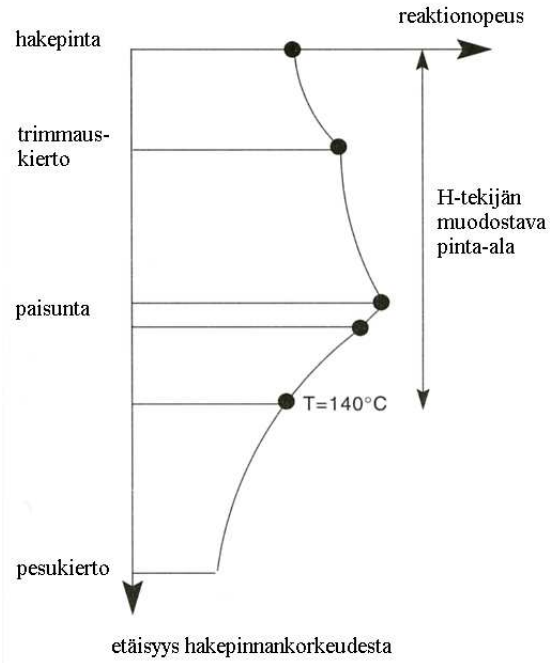

Kuva 2.4 Yksinkertainen esimerkki H-tekijän laskennasta todellisessa keittimessä [3]. Eri keittovyöhykkeissä mitatuista lämpötiloista voidaan arvioida reaktionopeuskertoimet, joista saadaan käyrällä yhdistämällä hakepinnankorkeuden etäisyyden funktio. Olettamalla hakkeen etenemisnopeus keittimessä vakioksi voidaan keittimen dimensioiden avulla pystyakseli muuttaa aika-akseliksi. Integroimalla muodostuneen reaktionopeuskäyrän yli ajan suhteen saadaan laskettua H-tekijä. Vertaa yhtälöön (2.1).

Yksi vaihtoehto lämpötilaprofiilin asetteluun on tehdä se kokonais-H-tekijän perusteella. Kokonais-H-tekijä voidaan arvioida keittimen dimensioiden, keittimen eri vyöhykkeiden lämpötilojen ja tuotantonopeuden, joka määrää hakepatsaan keskimääräisen liikenopeuden, avulla. Kun lämpötilat eri keittovaiheissa tunnetaan, reaktionopeuskertoimet kussakin kohdassa keitintä voidaan arvioida yhtälön (2.2) avulla. Jos hakkeen liike oletetaan tasaiseksi, niin tuotantonopeudesta voidaan laskea hakepilarin nopeus. Tämän ja keittimen dimensioiden avulla voidaan laskea hakkeen viipymäaika eri lämpötilanmittauspisteiden välillä. Yhdistämällä eri lämpötilanmittauspisteissä lasketut reaktionopeuskertoimet esimerkiksi suoralla saadaan reaktionopeuskäyrä. Lämpötilanmittauspisteiden väliset H-tekijät voidaan nyt laskea integroimalla pisteiden välinen reaktionopeuskäyrä viipymäajan yli. Kokonais-H-tekijä saadaan näin eri vyöhykkeiden H-tekijöiden summana. Tätä on havainnollistettu kuvassa 2.4.

Pelkkä H-tekijän käyttö on säätöteknisessä mielessä avoimen piirin säätö, koska siinä ei käytetä takaisinkytkentää mitatusta kappaluvusta. Aikaisemmin suoran takaisinkytkennän käyttö oli hankalaa, koska kappa-analysaattoreita ei ollut ja laboratorioanalyysit tehtiin n. kahden tunnin välein. Tätä varten kappalukua pyrittiin ennustamaan erilaisilla malleilla, jotka pyrkivät lyhentämään säädölle hankalaa viivettä. Nykyään on olemassa kappa-analysaattoreita, joiden käyttö keittimen puskulinjassa lyhentää analyysiviivettä oleellisesti, ja suoran takaisinkytkennän käyttö H-tekijän korjaukseen on mielekkäämpää [3].

Analysaattori mittaa kappaluvun optisesti UV-valon absorptioon perustuvalla mittausmenetelmällä. UV-valo tuotetaan Xenon-lampulla. Ennen varsinaista mittausta näytteestä poistetaan prosessi- ja siirtovesi, pestään mahdollisesti useita kertoja, sekoitetaan näyte ja mitataan sen alkusakeus. Kappaluvun mittaamisen jälkeen analysaattori pestään ja kalibroidaan vesiarvomittauksen perusteella. Analysaattori voi määrittää myös näytteen puulajisuhteen. Ilmakuplat häiritsevät mittausta ja näytteen pesua, joten nämä vaiheet tehdään paineistettuna. Kuva 2.5 esittää kappa-analysaattorin suorittamat vaiheet kappaluvun mittauksessa. [2]

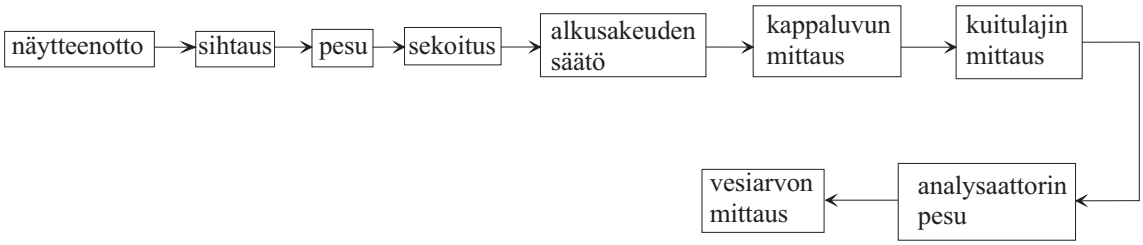

Kuva 2.5 Kappa-analysaattorin mittaussekvenssin vaiheet.

Leiviskän [3] mukaan lipeäanalysaattoreiden avulla kappaluvun säätöä on onnistuttu parantamaan edelleen. Keittimen eri kierroista mitattujen alkalikonsentraatioiden perusteella eri keittovaiheiden kappaluku voidaan ennustaa melko hyvin esim. neuroverkolla. Tätä voidaan käyttää myötäkytkentäsäätöön, jotta korjaustoimenpiteitä voidaan tehdä ennen kuin massa saavuttaa puskulinjan.

2.7 Keitinpesu

Pesuvyöhyke katkaisee perinteisessä vuokeittimessä keittovyöhykkeen. Vyöhykejako saadaan aikaan jäähdyttämällä hake keittimen pohjasta ylöspäin virtaavalla pesulipeällä. Mitä enemmän lipeää virtaa ylöspäin, sitä lähempänä paisuntasihtejä keittyminen pysähtyy. Pesun hallinta perustuu yleensä pesukertoimen laskentaan. Pesukerroin määritellään ylöspäin virtaavan pesulipeän ja alaspäin virtaavan massan suhteena. Se voidaan laskea materiaalitasapainosta ja sitä säädetään yleensä keittimen pohjaan tuotavan pesulipeän virtauksen avulla. [2, 10]

2.8 Tutkimuskohteen keittimen säädöt

Kuitulinja 2:n keitin on 1970-luvulla rakennettu kaksiastiainen höyry-nestefaasikeitin. Tätä työtä tehtäessä sillä keitetään pelkästään mäntysellua. Keittimen ajomalli on konventionaalinen, tosin siihen on tehty modifikaatiot Downflow Lo-Solids keittoa varten mutta tällä hetkellä sitä ei käytetä. Tuotannon ohjaus ja säätö on toteutettu Honeywellin TotalPlant Alcont automaatiojärjestelmällä. Säätöjärjestelmä muodostuu kaskadipiireistä, joissa ylätason säätimet antavat perustason säätimille asetusarvot ja perustason säätimet ohjaavat varsinaisia toimilaitteita. Tuotantoa ohjaavat ylätason säädöt noudattavat pääosin samoja pääperiaatteita kuin kappaleissa 2.3 – 2.7 kuvattiin. Ylätason säätöjä ovat [10]

- tuotantonopeuden,
- alkali-puu suhteen,
- neste-puu suhteen,
- imeytystornin- ja keittimen hakepintojen,
- keittimen lipeäpinnan,
- keittimen pesukertoimen,
- puskusakeuden ja

- kappaluvun säädöt.

Seuraavaksi tarkastellaan näitä tarkemmin. Kuvaan 2.6 on kerätty prosessin tärkeimpiä säätöpiirejä.

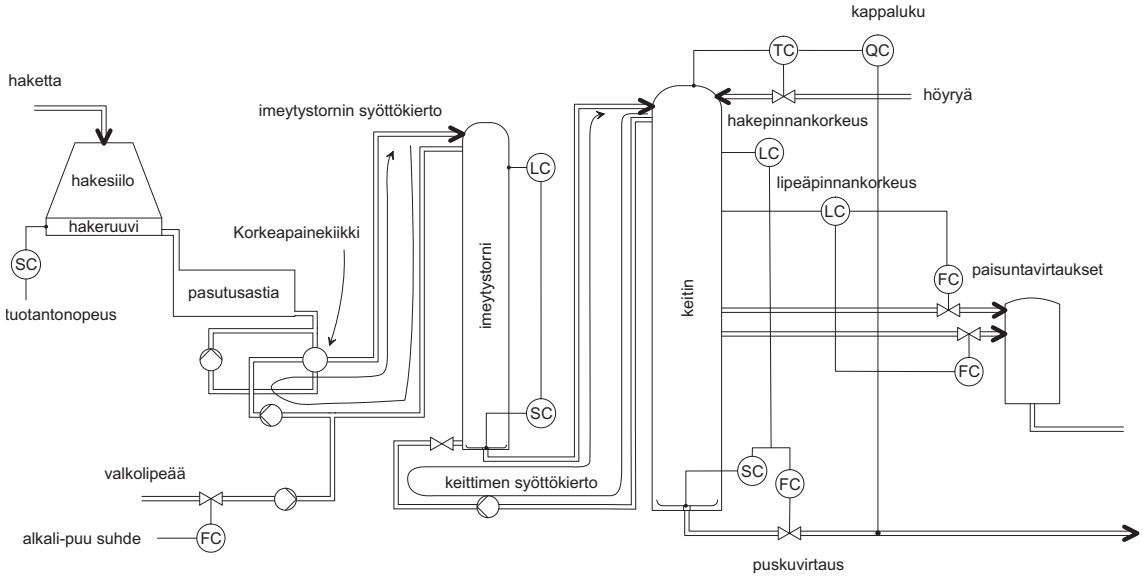

Kuva 2.6 Keittoprosessin tärkeimpiä säätöpiirejä.

2.8.1 Keittokemikaalien annostus

Alkali-puu suhteen säädin ohjaa valkolipeän virtausta imeytystornin syöttökiertoon. Järjestelmällä on mahdollista säätää myös alkaliprofiilia ohjaamalla keittimen syöttökierron valkolipeän määrää, mutta työn aikana sitä ei käytetty. Alkali-puusuhteen säätö perustuu alkali- ja hakemäärän suhteen laskentaan. Syötetty alkalimäärä voidaan laskea tarkasti, koska alkaliväkevyys ja syötetty alkalivirtaus mitataan. Sen sijaan hakemäärää ei tunneta tarkasti, koska se lasketaan vain hakeruuvin pyörimisnopeuden mukaan. Näin ollen todellisen hakemäärän heilahdellessa myös alkali-puu suhde heilahtelee.

Neste-puu suhteen säätäjä ohjaa kuitusuotimelta keittimeen tulevan rejektivirtauksen asetusarvoa. Neste-puu suhde ilmaisee kaiken keittimessä olevan nesteen määrän suhteessa hakemäärään. Nestemäärän laskennassa otetaan huomioon eri prosessivaiheissa syötetyt neste- ja höyryvirrat. Hakemäärä on sama kuin tuotantonopeuden säädössä.

2.8.2 Imeytystornin ja keittimen hakepinnankorkeudet

Imeytystornin hakepinnan säätö on takaisinkytketty pinnankorkeutta mittaavasta mekaanisesta lapamittarista. Säädin ohjaa pinnankorkeutta antamalla asetusarvon imeytystornin pohjakaavarin pyörimisnopeudelle ja pohjalaimennusvirtauksen määrälle. Pohjakaavarin pyörimisnopeus on pääsäätösuure ja pohjalaimennusta käytetään, kun pohjakaavarin pyörimisnopeus saavuttaa säätörajoitukset.

Keittimen hakepinnan säädön pääohjausmuuttujana voidaan käyttää joko hakeruuvin pyörimisnopeutta tai puskuvirtausta, eli sitä voidaan periaatteessa ohjata sekä hakkeen syötöllä että poistolla. Näille ohjauksille on määritelty rajoitteet, jotta keskimääräinen tuotantotaso saadaan ylläpidettyä. Jos hakeruuvin pyörimisnopeus on valittu pääohjaussuureeksi, niin puskuvirtaus ja pohjakaavarin pyörimisnopeus toimivat apuohjausmuuttujana. Pohjakaavarin pyörimisnopeutta muutetaan vasta, kun puskuvirtaus saavuttaa sille asetetut rajoitteet. Tätä työtä tehtäessä keittimen hakepinnan ohjausmuuttujana oli vain puskuvirtaus. Takaisinkytkentäsignaaliksi voidaan valita joko toinen kahdesta radiometrisestä pinnankorkeusmittauksesta tai mekaanisten hakepintamittausten yhdistetty pinnankorkeussignaali.

2.8.3 Keittimen lipeäpinnankorkeus

Myös keittimen lipeäpintaa säädetään. Säädön ohjausmuuttujina ovat ylempi ja alempi paisuntalipeävirtaus, joiden suhdetta operaattori voi halutessaan muuttaa. Säätö on takaisinkytketty lipeän pinnankorkeusmittauksesta, joka perustuu paineeron mittaamiseen.

2.8.4 Pesukerroin

Pesukertoimen säätö on kappaleessa 2.7 kuvatun mukainen. Operaattori voi valita pesukertoimen säädössä alas virtaavan massan laskennan tapahtumaan joko puskuvirtaus- ja -sakeusmittausten perusteella tai hakeruuvin pyörimisnopeudesta perusteella. Puskusakeuden säätö avustaa pesukertoimen säätöä pyrkien auttamaan keittimen massaläpivirtauksen hallintaa. Puskusakeutta ohjataan keittimen

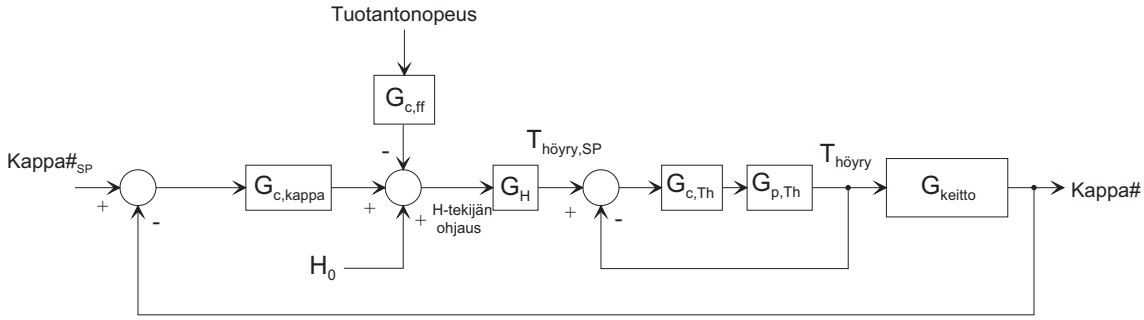

Kuva 2.7 Kappalukua säädetään kuvan mukaisella kaskadisäätörakenteella. Sisemmän tason säädin säätää keittimen höyrytilan lämpötilaa ohjaamalla höyryventtiiliä. Sisempi säädin saa asetusarvonsa kappaluvun säätimeltä H-tekijä muunnoksen kautta. H-tekijällä on vakiotoimintapiste $H_0 = 800$. Tuotantonopeuden muutos on kuvattu myötäkytkentänä.

pohjalaimennuksella sekä pesulipeävirtauksella. Kumpaakaan em. säätöä ei käytetä yleensä.

2.8.5 Kappaluku

Kappaluvun säädön ohjausmuuttuja on keittimen höyryfaasin lämpötila, joka saa asetusarvon kaskadissa olevalta kappaluvun säätimeltä. Kappaluvun säädin asettelee H-tekijän ohjearvoa, joka muutetaan ensin keittimen höyrytilanlämpötilaohjeeksi ja edelleen höyrytilan lämpötilan säätimen toimesta höyryventtiilin ohjaukseksi. H-tekijä saa toimintapisteen tuotantonopeuden säätimeltä. Näin tuotantonopeutta voidaan ikään kuin ajatella myötäkytkentäsignaaliksi tässä säädössä. Säätörakenteen lohkokaavio on esitetty kuvassa 2.7. Kuvassa oleva H_0 on vakiotoimintapiste 800, jonka ympärille H-tekijän ohjaus on sidottu. Merkintä $\mathrm{G_H}$ tarkoittaa muunnosta H-tekijästä höyryfaasin lämpötilan asetusarvoksi.

Kappalukua mitataan kappa-analysaattorilla. Analysaattorissa on neljä näytelinjaa, joista kolme on käytössä. Yksi näistä on keittimen puskukappa. Kaksi muuta ovat valkaisimon käytössä. Näytteiden analysointi etenee sekvenssissä, jossa kukin näyte analysoidaan vuorollaan. Yhden näytteen analysointi kestää noin 11 minuuttia, joten normaalisti puskukapan näyteväli on noin 33 minuuttia. Mikäli näyte on huono, analyysi epäonnistuu ja näyte hylätään. Jos sekvenssi etenee normaalisti, niin seuraava näyte saadaan taas 33 minuutin päästä tästä hetkestä, joten näyteväliksi tulee

noin 66 minuuttia. Jos toinenkin mittaus epäonnistuu, näyteväli on jo 99 minuuttia. Myös sellainen tilanne on mahdollinen, että kaksi muuta näytelinjaa eivät ole käytössä valkaisimon käyttöhäiriön vuoksi. Tällöin näyteväliaika on 11 minuuttia, jos näytteenotto onnistuu normaalisti.

2.8.6 Tuotantonopeus

Tuotantonopeuden säätö ohjaa hakeruuvin ja korkeapainekiikin pyörimisnopeutta sekä pasutusastiaan menevän höyryn virtausta eli kaasausta. Hakeruuvin pyörimisnopeus toimii tuotantonopeuden pääohjausmuuttujana. Hakeruuvin pyörimisnopeuden asetusarvo lasketaan arvioidun keiton saannon ja prosessin läpi vuorokaudessa kulkevan hakemäärän avulla. Sekä hakemäärän laskenta että keiton saanto ovat vakioiden avulla laskettavia suureita, joten piiri on säätöteknisessä mielessä tuotantonopeuden ohjaus, koska se ei sisällä takaisinkytkentää todellisesta vuorokausittaisesta tuotannosta. Korkeapainekiikin pyörimisnopeuden asetusarvo on suoraan suhteessa laskettuun hakemäärään. Myös pasutusastian kaasausta ohjataan lasketun hakemäärän avulla. Lisäksi tuotantonopeuden säätö huomioi hakkeen kuiva-ainepitoisuuden, jonka operaattori voi valita joko laboratoriomäärityksen tai hakesiilon pinnankorkeuden ja painon avulla lasketun suureen väliltä.

Tuotantonopeuden muutos on järjestelmässä omana toimintonaan. Se on vaikuttaa useisiin muihin säätöpiireihin muuttaen niiden asetusarvoja. Tärkeimpiä ovat hakeruuviin, puskuvirtaukseen, paisuntavirtaukseen, keittolämpötilaan ja valkolipeän syöttöön kohdistuvat muutokset. Näiden perustason piirien kannalta tuotantonopeuden muutos on ylätason säätö. Joihinkin edellä mainittuihin piireihin liittyy kuitenkin myös takaisinkytketty ylemmän tason säädin. Tällaisia ovat hakepinnan, lipeäpinnan ja kappaluvun säädöt (ks. kuvat 2.6 ja 2.7). Tuotantonopeuden muutoksen ohjaus toimii näin siis myötäkytkentäsäätönä edellä mainituille ylätason piireille. Tuotantonopeuden muutokseen on järjestelmässä kaksi tapaa: nopea ja suunniteltu.

2.9 Muita säätömenetelmiä

Viime aikoina on tutkittu uusien monimuuttujamenetelmien kuten mallipredikiivisten säädinten käyttöä keiton hallinnassa. Simulaatiotulosten perusteella näillä säätömenetelmillä näyttäisi olevan potentiaalia vähentää kappaluvun vaihteluita huomattavasti perinteiseen monen piirin itsenäiseen säätöön verrattuna [11]. Michaelsen et al. [12] kuvasivat säätöstrategian, jossa käytettiin mallia, joka jakaa keittimen seitsemään osaan. Malli perustuu energia- ja massataseilla laajennettuun ns. kineettiseen Purdue-malliin. Näistä yhtälöistä muodostettiin epälineaarinen tilayhtälömalli, jossa tilamuuttujina olivat lämpötila, vaikuttava alkali ja jäännösligniini sekä kineettisen yhtälön reaktiokertoimet. Tilamuuttujien estimointiin käytettiin laajennettua Kalman-suodinta (EKF), koska malli on epälineaarinen. Kalman-suotimen käyttäminen mahdollistaa mittausepävarmuuden huomioimisen tilaestimaattien laskennassa. Ennen ohjausmuuttujien laskentaa em. epälineaarinen tilamalli linearisoidaan jokaisella säätökierroksella sen hetkisen tilaestimaatin ympäristöön. Ohjaukset lasketaan neliölliseen ohjelmointiin (quadratic programming, QP) perustuvalla menetelmällä. Se mahdollistaa mm. ohjausmuuttujien rajoitteiden huomioinnin ohjausten laskennassa. Tällainen säätö on joustava, koska se mahdollistaa minkä tahansa tilaestimaattorin tulomuuttujan valinnan ohjausmuuttujaksi ja minkä tahansa lähtömuuttujan (kuten kappaluku tai paisunnan jäännösalkalimäärä) valinnan säädettäväksi suureeksi. Uutta kappaluvun monimuuttujasäätöstrategiaa verrattiin vanhaan PI-säätöön todellista prosessidataa hyväksi käyttävän simulaation avulla. Uusi säätömenetelmä havaittiin paremmaksi kuin vanha, koska se näytti kykenevän parempaan häiriöiden vaimennukseen. Simulaation lisäksi tutkimuksessa verrattiin mallin ennustamia kappalukuja toteutuneisiin ja todettiin ennustusvirheen keskihajonnan olevan tyypillisesti luokkaa 3 – 4. Artikkelissa ei kuitenkaan esitetä mitään tuloksia siitä, kuinka paljon uusi säätöjärjestelmä on pienentänyt esim. kappaluvun keskihajontaa. Alustavien kokeiden raportoitiin olleen hyvin lupaavia.

3 SÄÄTÖPIIRIEN SUORITUSKYVYN MITTAAMINEN

Säädön onnistumista voidaan arvioida mm. säädettävän suureen varianssin perustella. Varianssi on tilastollinen suure, joka kuvaa satunnaismuuttujan hajontaa. Pelkästään variansseja vertailemalla ei saada kuitenkaan tietoa siitä, kuinka pieni varianssi voisi olla. Harrisin [13] kehittämällä minimivarianssianalyysillä tämä on mahdollista. Menetelmä soveltuu takaisinkytketyille SISO-säätöpiireille (Single Input Single Output). Sillä voidaan verrata prosessin lähtösuureen varianssia minimivarianssisäätimellä saavutettavaan varianssiin. Tämän analyysin suorittamiseksi prosessia ei tarvitse häiritä millään testisignaaleilla vaan minimivarianssi voidaan estimoida säädetystä piiristä mitattujen signaalien avulla. Menetelmää on laajennettu käsittelemään myös myötäkytkettyjä SISO-säätöjä [14] sekä MIMO-säätöjä (Multiple Input Multiple Output) [15, 16].

Minimivarianssisäätöä on arvosteltu mm. epärobustiksi. Se saattaa myös tuottaa suuria ohjausliikkeitä, joten minimivarianssisäätöä ei välttämättä kannata toteuttaa. Se määrittelee kuitenkin prosessivarianssin alarajan, johon ylipäätään millään lineaarisella säätimellä voidaan päästä. Näin sitä voidaan käyttää hyvänä vertailukohtana. Jos osoittautuu, että prosessin varianssi on lähellä minimivarianssia, niin säätimen virittämisestä ei ole hyötyä. Tällöin varianssia voidaan pienentää esim. myötäkytkennän avulla, mikäli tunnetaan säädettävään suureeseen vaikuttavia häiriösignaaleja. Mikäli häiriötä ei voida jostain syystä käyttää myötäkytkennässä, niin sen vaikutusta voidaan yrittää pienentää vaikuttamalla itse häiriöön sitä kontrolloivalla takaisinkytketyllä säätöpiirillä. Kolmas mahdollisuus on muuttaa itse prosessia niin, että siitä tulee helpommin säädettävä. Tällaisia muutoksia ovat esim. viiveen lyhentäminen ja ohjausmuuttujien lisääminen. [17]

Koska tarkasteltavassa keittimessä kappaluvun säätö on toteutettu takaisinkytkettynä SISO-säätönä, niin seuraavaksi tutustutaan tässä työssä käytettyihin SISO-piirien suorituskyvyn analysointimenetelmiin.

3.1 Minimivarianssisäätö ja -indeksi

Oletetaan, että prosessin lähtösuuretta y voidaan mallintaa diskreettiaikaisella lineaarisella siirtofunktiolla

$$y(n) = \frac{B(q^{-1})}{A(q^{-1})} q^{-d_\mathrm{p}} u(n) + w(n) = G_\mathrm{p}(q^{-1}) u(n) + w(n), \tag{3.1}$$

missä n on diskreetti aika-indeksi, u on ohjaussignaali, w on häiriösignaali, d_p on prosessin viive ja q on siirto-operaattori, joka tarkoittaa, että $q^{-k}u(n) = u(n-k)$. Viive d_p on aina vähintään yhden näytevälin suuruinen. Se voidaan ilmaista muodossa

$$d_\mathrm{p} = 1 + d_\mathrm{dead}, \tag{3.2}$$

missä d_dead on prosessin kuollut aika tai analyysiviive. Häiriösignaali voidaan mallintaa siirtofunktiolla

$$w(n) = H(q^{-1}) v(n), \tag{3.3}$$

missä $v(n)$ on nollakeskiarvoista valkoista kohinaa, jonka varianssi on σ_v^2. Säätölaki voidaan kirjoittaa muodossa

$$u(n) = G_\mathrm{c}(q^{-1}) e(n), \tag{3.4}$$

missä e on säätöpoikkeama (kutsutaan myös erosuureeksi), joka puolestaan voidaan kirjoittaa muodossa $e(n) = r(n) - y(n)$, missä r on asetusarvo. Kuvan 3.1 lohkokaavioesitys havainnollistaa näitä määrittelyjä.

Minimivarianssisäädön tavoitteena on ohjata prosessia niin, että σ_y^2 minimoituu. Superpositioperiaatteen mukaan kunkin tulosignaalin vaikutusta prosessin lähtöön voidaan tarkastella erikseen. Tarkastellaan seuraavaksi häiriön v vaikutusta prosessin lähtösuureeseen, jolloin merkitään $r(n) = 0$. Tällöin takaisinkytketyn systeemille voidaan kirjoittaa

$$y(n) - \mu_y = \frac{H(q^{-1})}{1 + G_\mathrm{c}(q^{-1}) G_\mathrm{p}(q^{-1})} v(n) = G_\mathrm{cl}(q^{-1}) v(n), \tag{3.5}$$

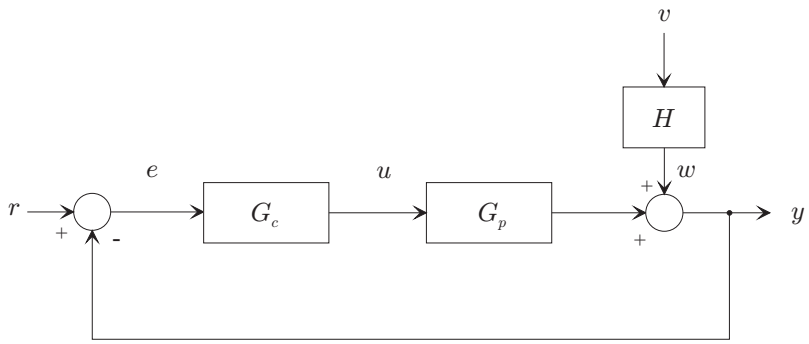

Kuva 3.1 Takaisinkytketyn systeemin lohkokaavio. Systeemiin liittyy signaalit: r – asetusarvo, y – prosessin lähtösuure, v – nollakeskiarvoista valkoista kohinaa, e – säätöpoikkeama, w – valkoisesta kohinasta suodatettu häiriösignaali ja u – prosessin ohjausmuuttuja,

missä μ_y on systeemin lähtösignaalin odotusarvo ja samalla myös säätöpoikkeaman keskiarvo. Ideaalitapauksessa $\mu_y = 0$, eli säätö kykenee vaimentamaan häiriöiden aiheuttaman keskimääräisen vaikutuksen (ts. jatkuvuustilan virheen), mutta näin ei aina välttämättä ole. Harris [13] osoitti, että siirtofunktio $G_{\mathrm{cl}}(q^{-1})$ voidaan hajottaa kahteen toisistaan riippumattomaan osaan

$$y(n) - \mu_y = G_{\mathrm{cl}_1}(q^{-1})v(n) + G_{\mathrm{cl}_2}(q^{-1})v(n - d_{\mathrm{p}}). \tag{3.6}$$

Ensimmäinen osa riippuu ainoastaan häiriön siirtofunktiosta $H(q^{-1})$ ja viiveestä d_{p}. Se voidaan kirjoittaa myös muodossa

$$G_{\mathrm{cl}_1}(q^{-1}) = h(0)+h(1)q^{-1}+...+h(k)q^{-k}+...+h(d_{\mathrm{p}}-1)q^{-d_{\mathrm{p}}+1} = \sum_{k=0}^{d_{\mathrm{p}}-1} h(k)q^{-k}, \tag{3.7}$$

missä $h(k)$ on siirtofunktion $G_{\mathrm{cl}}(q^{-1})$ impulssivaste viiveillä k. Jälkimmäinen osa riippuu säätimestä, prosessista ja häiriön siirtofunktiosta. Minimivarianssisäädössä tämä termi on nolla. Tällöin prosessin varianssi on

$$\sigma^2_{\mathrm{mv}} = \mathrm{var}\left\{G_{\mathrm{cl}_1}(q^{-1})v(n)\right\} = \sigma_v^2 \sum_{k=0}^{d_{\mathrm{p}}-1} h^2(k). \tag{3.8}$$

Jos prosessi ei ole minimivarianssisäädössä, yhtälön (3.6) oikean puolen jälkimmäinen termi kasvattaa prosessin varianssia osuudella

$$\sigma_{\mathrm{fb}}^2 = \mathrm{var}\left\{G_{\mathrm{cl2}}(q^{-1})v(n-d_{\mathrm{p}})\right\} = \sigma_v^2 \sum_{k=d_{\mathrm{p}}}^{\infty} h^2(k) \tag{3.9}$$

ja tällöin prosessin kokonaisvarianssi on

$$\sigma_y^2 = \sigma_{\mathrm{mv}}^2 + \sigma_{\mathrm{fb}}^2 = \sigma_v^2 \sum_{k=0}^{\infty} h^2(k). \tag{3.10}$$

Kun halutaan tarkastella, kuinka suuri osuus prosessin varianssista on peräisin takaisinkytkennän epäideaalisuudesta, voidaan tutkia suuretta [17, 18]

$$\eta(d_{\mathrm{p}}) = 1 - \frac{\sigma_{\mathrm{mv}}^2}{\sigma_y^2} = \frac{\sigma_y^2 - \sigma_{\mathrm{mv}}^2}{\sigma_y^2} = \frac{\sigma_{\mathrm{fb}}^2}{\sigma_y^2}, \tag{3.11}$$

joka on rajoitettu välille [0,1]. Indeksi kertoo suoraan, kuinka monta prosenttia säädettävän suureen varianssi on suurempi kuin minimivarianssisäätimellä. Indeksi d_{p} painottaa yhtälössä (3.11) sitä, että kyse on minimivarianssista. Mikäli todellista viivettä ei tunneta tai se mahdollisesti vaihtelee, voidaan tarkastella indeksiä $\eta(i)$ käyttäjän määrittelemillä viiveillä $i \in [1,l]$. Sijoittamalla yhtälöön (3.8) d_{p}:n paikalle i saadaan

$$\begin{aligned}\eta(i) &= 1 - \frac{\sigma_v^2 \sum_{k=0}^{i-1} h^2(k)}{\sigma_v^2 \sum_{k=0}^{\infty} h^2(k)} = \frac{\sigma_v^2 \sum_{k=0}^{\infty} h^2(k) - \sigma_v^2 \sum_{k=0}^{i-1} h^2(k)}{\sigma_v^2 \sum_{k=0}^{i-1} h^2(k)} \\ &= \frac{\sum_{k=i}^{\infty} h^2(k)}{\sum_{k=0}^{\infty} h^2(k)}, \quad i = 1,2,\ldots,l. \end{aligned} \tag{3.12}$$

Tämä indeksi kertoo säädön suorituskyvyn suhteessa käyttäjän määrittämään viiveeseen l, joka voidaan ajatella myös systeemin asettumisaikana. Indeksin avulla voidaan siis asettaa jokin asettumisaikatavoite l ja tutkia, kuinka hyvin suljettu systeemi vastaa asetettua tavoitetta. Jos indeksi on lähellä nollaa, asettumisaika on tavoiteltu l. Säädön suorituskyvyn arviointia havainnollistaa jo pelkän impulssivas-

teen piirtäminen. Karkeasti sanottuna mitä nopeammin ja värähdyksettömämmin impulssivaste vaimenee, sitä paremmin säädin eliminoi häiriöt.

Vaikka edellä tutkittiin vain häiriön v vaikutusta prosessin lähtöön, niin se ei tarkoita, että minimivarianssianalyysi ei soveltuisi esimerkiksi asetusarvon muutosten aiheuttamien transienttien analysointiin. Yleisessä tapauksessa voidaan tarkastella erosuureen e dynamiikkaa eri häiriölähteiden näkökulmasta. Tällöin kuvan 3.1 systeemille pätee yhtälö

$$e(n) = \frac{1}{1 + G_{\mathrm{c}}(q^{-1})G_{\mathrm{p}}(q^{-1})} r(n) + \frac{H(q^{-1})}{1 + G_{\mathrm{c}}(q^{-1})G_{\mathrm{p}}(q^{-1})} v(n). \tag{3.13}$$

Minimivarianssisäätö ajatellaan nyt erosuureen varianssin minimoivaksi säädöksi. Erosuureen varianssi voidaan tässäkin tapauksessa hajottaa samalla tavalla kuin aiemmin tässä kappaleessa tehtiin lähtösuureelle y yhtälössä (3.10). Ainoa kysymys on, kuinka voidaan mallintaa deterministiset signaalit, kuten askelfunktio, valkoisen kohinan avulla. Tämä saavutetaan sijoittamalla mallin napoja yksikköympyrälle, mihin palataan kappaleessa 3.2.1. Esimerkiksi askelmaisen herätteen tilastollisia ominaisuuksia voidaan kuvata siirtofunktiolla

$$G_r\left(q^{-1}\right) = \frac{1}{1 - q^{-1}}, \tag{3.14}$$

jonka herätteenä on valkoinen kohina $v_r(n)$.

3.2 Minimivarianssin estimointi

Koska yhtälön (3.6) termit ovat toisistaan riippumattomia, minimivarianssi voidaan laskea suljetun systeemin siirtofunktion $G_{\mathrm{cl}}(q^{-1})$ impulssivasteen avulla esim. yhtälöllä (3.8). Tämä ei kuitenkaan tarkoita sitä, että kaikki yhtälön (3.5) termit pitäisi identifioida erikseen vaan riittää, kun prosessin lähtösuure mallinnetaan hyvin sovittavalla aikasarjamallilla. Mahdollisia rakenteita mallille ovat AR-, MA-, ARMA-, ja ARIMA-mallit. Kullakin näistä on omat erityispiirteensä, joten käydään ne lyhyesti läpi [19].

3.2.1 Aikasarjamallit

AR-malli differenssiyhtälönä esitettynä on

$$y(n) = a_1 y(n-1) + a_2 y(n-2) + ... + a_p y(n-p) + v(n), \tag{3.15}$$

missä $a_i, i = 1,...,p$ ovat mallin kertoimia. Malli siis ilmaisee prosessin nykyisen tilan p:n aikaisemman tilansa sekä satunnaismuuttujan v lineaarikombinaationa. Siirtofunktiona ilmaistuna se on

$$y(n) = \frac{1}{1 - a_1 q^{-1} - a_2 q^{-2} - ... - a_p q^{-p}} v(n) = \frac{1}{A(q^{-1})} v(n). \tag{3.16}$$

AR-malli on siis suodatin, joka sisältää p kappaletta nimittäjän nollakohtia eli napoja. Tällaisen siirtofunktion impulssivaste on ääretön, eli sitä sanotaan IIR-tyyppiseksi. Tämä rakenne on käytännöllinen, koska sen parametrien laskentaan on olemassa tehokkaita algoritmeja [21, ss. 920 - 930]. AR-rakennetta käytettäessä parametrit on mahdollista estimoida myös rekursiivisesti, mikä mahdollistaa mallin identifioinnin samalla kun dataa kerätään.

MA-malli differenssiyhtälömuodossa on

$$y(n) = v(n) - b_1 v(n-1) - b_2 v(n-2) - ... - b_z v(n-z) \tag{3.17}$$

ja siirtofunktiona

$$y(n) = (1 - b_1 q^{-1} - b_2 q^{-2} - ... - b_z q^{-z}) v(n) = B(q^{-1}) v(n), \tag{3.18}$$

eli se on suodatin, joka sisältää z kappaletta osoittajan nollakohtia eli nollia. Tällaisen suodattimen impulssivaste on äärellinen eli se on FIR-tyyppinen. Tämä siis tarkoittaa, että suodattimen impulssivasteessa on äärellinen määrä nollasta poikkeavia termejä. Tähän liittyy eräs mielenkiintoinen ominaisuus: MA-prosessin tuottaman signaalin autokorrelaatiofunktiossa on nimittäin vain z ensimmäistä termiä nollasta poikkeavia [13]. Minimivarianssisäädetty prosessi on itse asiassa juuri tällainen, koska säädin nollaa suljetun systeemin impulssivasteesta viiveen jälkeiset termit, kuten

aiemmin todettiin. Tämän vuoksi yksi helppo ja havainnollinen tapa tutkia, onko säädin minimivarianssisäädin, on tarkastella säädetyn suureen autokorrelaatiofunktiota. Tähän palataan myöhemmin.

ARMA-malli on AR- ja MA-mallien yhdistelmä. Siksi se on myös joustavin näistä. Differenssiyhtälönä se on

$$y(n) = a_1 y(n-1) + ... + a_p y(n-p) + v(t) - b_1 v(n-1) - ... - b_z v(n-z) \quad (3.19)$$

ja siirtofunktiona

$$y(n) = \frac{B(q^{-1})}{A(q^{-1})} v(n). \quad (3.20)$$

ARIMA-malli on edellä mainituista kaikkein monipuolisin. Sillä on mahdollista kuvata useimpia stokastisia ja jopa deterministisiä häiriöitä kuten askelia, ramppeja ja eksponentiaalista kasvua valkoisen kohinan generoimana [17]. Malli on siirtofunktiomuodossaan ilmaistuna

$$y(n) = \frac{B(q^{-1})}{A(q^{-1})\nabla^c} v(n), \quad (3.21)$$

missä $\nabla^c = (1 - q^{-1})^c$tarkoittaen, että mallissa pakotetaan c kappaletta napoja yksikköympyrälle. ARIMA-malli voidaan muodostaa esim. seuraavalla tavalla. Määritellään ensin apusignaali

$$a(n) = \nabla^c y(n), \quad (3.22)$$

eli lasketaan *y:n c*:s differenssi. Tämän jälkeen apusignaali voidaan mallintaa ARMA-prosessina

$$a(n) = \frac{B(q^{-1})}{A(q^{-1})} v(n). \quad (3.23)$$

Kukin em. malleista ilmaistaan joskus myös pelkästään kertalukujensa avulla. Esim. merkintä ARIMA(p,c,z) tarkoittaa sellaista mallia, jolla on p napaa, c napaa yksikköympyrällä (c kappaletta differenssejä) ja z nollaa.

3.2.2 Input-output mallit

Aikasarjamalleilla mallinnetaan tarkasteltavaa signaalia valkoisen kohinan avulla. Tätä mallia voidaan laajentaa siten, että otetaan huomioon myös jonkin toisen suu-

reen vaikutus tarkasteltavaan signaaliin. Kutsumme siksi näitä malleja tässä input-output malleiksi. Näissä malleissa on edelleen myös valkoisella kohinalla mallinnettava osuus. Input-output malleja ovat esim. ARX-, ARMAX- ja Box-Jenkins mallit. Kirjain X tulee sanasta exogenous eli ulkoinen. ARX-malli on muotoa

$$A(q^{-1})y(n) = B(q^{-1})u(n) + v(n) \tag{3.24}$$

ja ARMAX-malli muotoa

$$A(q^{-1})y(n) = B(q^{-1})u(n) + C(q^{-1})v(n). \tag{3.25}$$

Box-Jenkins malli on edellisiä joustavampi, koska siinä tuntemattomalla häiriöllä $v(n)$ ja systeemin tulosignaalilla $u(n)$ on erilliset nimittäjäpolynomit. Box-Jenkins mallit ovat muotoa

$$y(n) = \frac{B(q^{-1})}{F(q^{-1})}u(n) + \frac{C(q^{-1})}{D(q^{-1})}v(n). \tag{3.26}$$

3.2.3 Aikasarjamallien identifiointi

Aikasarjamallien päättely prosessidatan perusteella on systeemien identifioinnin osa-alue. Siinä pyritään etsimään mallin rakenne (AR, MA, ARMA jne.), numeeriset arvot mallin parametreille a_i, b_i sekä kertaluvut p, c ja z. Systeemien identifiointi on laaja alue ja siitä on kirjoitettu viimeisten vuosikymmenien aikana useita kirjoja. Tämä kappale pyrkii selvittämään pääperiaatteita, kuinka aikasarjamalleja identifioidaan sovittamalla niitä kerättyyn datajoukkoon. Kun malli on identifioitu, sen tuottamaa vastetta verrataan mitattuun dataan ja tarkastellaan mallinnusvirheiden ominaisuuksia. Tätä kutsutaan mallin validoimiseksi. Tässä vaiheessa saadaan tietoa siitä, kuinka hyvin malli on onnistunut kuvaamaan datan ja kuinka luotettava se on.

Systeemien identifioinnin yhteydessä törmätään yleensä siihen, että mallit joudutaan sovittamaan äärellisen mittaisen datajoukon perusteella. Tämä johtaa siihen, että analysoinnissa joudutaan käyttämään tilastollisia estimaatteja. Sen vuoksi malleja pitää tarkastella tilastollisten menetelmien kuten luottamusvälien avulla. Ne siis

ilmaisevat rajat, joiden sisällä todellinen arvo on valitulla todennäköisyydellä. Luottamusvälien perusteella voidaan tehdä johtopäätöksiä mm. siitä, poikkeaako estimaatti merkittävästi oletetusta käyttäytymisestä eli ns. nollahypoteesista H_0. Mikäli H_0 ei sisälly luottamusväleihin, on poikkeama valitulla riskitasolla α merkittävä ja nollahypoteesi voidaan hylätä. Koska kyse on tilastollisesta testaamisesta, ei voida olla täysin varmoja johtopäätöksen oikeellisuudesta, joten analysoija valitsee riskitason, jolla hän haluaa ilmiötä tutkia. Riskitaso α tarkoittaa sitä todennäköisyyttä, jolla H_0 hylätään vaikka se on tosi. Tätä kutsutaan myös lajin I eli hylkäysvirheen todennäköisyydeksi. Tyypillisiä riskitasoja ovat $\alpha = 0{,}05$; 0,01 ja 0,001 ja näitä vastaavat luottamusvälit ovat 95 %, 99 % ja 99,9 %. Luottamusvälien määrittämiseksi täytyy tuntea estimaatin todennäköisyysjakauma. Riskitasoa ei kannata valita liian pieneksi, koska tällöin lajin II virheen todennäköisyys kasvaa yleisesti. Tämä virhe tarkoittaa, että H_0 hyväksytään vaikka se ei todellisuudessa pidä paikkaansa. Näin lajityypin II virheriskin kasvaminen heikentää testin kykyä erottaa todelliset poikkeamat satunnaisvaihtelusta. Vaihtoehto riskitason α valinnalle tilastollisessa tarkastelussa on määrittää testin P-arvo eli merkitsevyystaso. Se tarkoittaa pienintä riskitasoa α, jolla H_0 tulisi hylätyksi. Tämä merkitsee sitä, että mitä pienempi P-arvo, sitä vahvempi tuki vastahypoteesille. [22]

Tässä työssä ei keskitytä varsinaisiin menetelmiin, joilla mallien parametreja a_i ja b_i estimoidaan, koska alue on laaja ja niiden laskentaan on olemassa erilaisia valmiita työkaluja, kuten Matlabin System Identification Toolbox. Sen sijaan tarkastellaan kertalukujen p, c ja z määritystä. Ensiksi kuitenkin käsitellään erilaisia tilastollisia funktioita [19, 21], koska niitä tarvitaan sekä kertalukujen määrityksessä että mallin validoimisessa. Seuraavassa oletetaan käsiteltävän signaalin olevan stationaarinen, mikä tarkoittaa, että signaalin tilastolliset ominaisuudet pysyvät muuttumattomina ajan kuluessa.

Odotusarvo määritellään

$$\mu_y = \mathrm{E}[y(t)] = \int_{-\infty}^{\infty} y(t) p\left[y(t)\right] dy, \tag{3.27}$$

missä merkintä E[·] tarkoittaa odotusarvoa ja $p\left[y(t)\right]$ on signaalin $y(t)$ todennäköisyystiheysfunktio. Odotusarvo ilmaisee tason, jonka ympärillä signaali vaihtelee. Äärellisestä näytejoukosta odotusarvo voidaan estimoida keskiarvofunktiolla

$$\hat{\mu}_y = \bar{y} = \frac{1}{N}\sum_{t=1}^{N} y(n). \tag{3.28}$$

Varianssi, joka kuvaa signaalin hajontaa tason μ_y ympärillä, määritellään

$$\sigma_y^2 = \mathrm{E}\left\{[y(t)-\mu_y]^2\right\} = \int_{-\infty}^{\infty} [y(t)-\mu_y]^2\, p\left[y(t)\right] dy. \tag{3.29}$$

Keskihajonta σ_y saadaan suoraan varianssista laskemalla tämän neliöjuuri. Otosvarianssi voidaan laskea kerätystä näytejoukosta

$$\hat{\sigma}_y^2 = \frac{1}{N}\sum_{t=1}^{N}[y(n)-\bar{y}]^2. \tag{3.30}$$

Autokovarianssifunktio, joka kuvaa signaalin ajallista riippuvuutta edellisistä arvoistaan, määritellään

$$\gamma_{yy}(k) = \mathrm{E}\left\{[y(t)-\mu_y][y(t+k)-\mu_y]\right\}. \tag{3.31}$$

Tämän avulla päästään käsiksi mm. signaalissa esiintyviin jaksollisiin komponentteihin. Jaksollisia komponentteja etsittäessä autokovarianssia havainnollisempi esitystapa on **tehospektri**, joka on autokovarianssifunktion Fourier-muunnos. Tähän palataan kappaleessa 3.4. Jos autokovarianssifunktioon (3.31) sijoitetaan $k = 0$, niin saadaan yhtälö (3.29), eli viiveellä nolla autokovarianssifunktio on signaalin varianssi.

Eräs tärkeä signaalien erikoistapaus on valkoinen kohina. Tällaisen signaalin peräkkäiset näytteet eivät korreloi lainkaan. Tämä tarkoittaa sitä, että signaalin autokovarianssi on nollasta poikkeava vain viiveellä nolla, eli vain samalta näytehetkeltä otetut arvot riippuvat ajallisesti toisistaan. Kun tällaisesta funktiosta lasketaan Fourier-muunnos, niin tuloksena on vakio. Tehospektri saa siis saman arvon kaikil-

la taajuuksilla. Valkoisen kohinan nimitys tuleekin auringon valon spektristä, joka sisältää yhtä paljon tehoa kaikilla näkyvän valon aallonpituuksilla.

Autokovarianssiestimaatti $c_{yy}(k)$ voidaan laskea äärellisestä näytejoukosta y_1,y_2,...,y_N useilla menetelmillä, esimerkiksi harhattomalla eli biasoimattomalla estimaatilla [26]

$$\acute{c}_{yy}(k) = \frac{1}{N-k}\sum_{n=1}^{N-k}[y(n)-\bar{y}][y(n+k)-\bar{y}] \tag{3.32}$$

tai harhallisella eli biasoidulla estimaatilla

$$c_{yy}(k) = \frac{1}{N}\sum_{n=1}^{N-k}[y(n)-\bar{y}][y(n+k)-\bar{y}]. \tag{3.33}$$

Tilastollisessa analyysissä suositaan yleensä harhatonta estimaattia. Joissain tapauksissa on kuitenkin suositeltavampaa käyttää harhallista estimaattia. Harhaton autokovarianssiestimaatti kärsii nimittäin suuresta varianssista suurilla viiveen k arvoilla eli toisin sanottuna k:n lähestyessä N:ää estimaatti antaa epäluotettavampia arvoja kuin harhallinen estimaatti. Tämä johtuu siitä, että k:n kasvaessa estimaatin laskennassa käytetään yhä vähemmän näytteitä signaalista.

Autokovarianssin ominaisuuksiin kuuluu, että se on symmetrinen origon suhteen. Siksi riittää laskea se pelkästään k:n positiivisilla arvoilla. Toinen tärkeä ominaisuus on, että autokovarianssi saa maksimiarvonsa viiveellä nolla. Kun halutaan tarkastella signaalin riippuvuuden voimakkuutta eri ajan hetkistä niin funktio voidaan skaalata välille [-1,1] juuri em. ominaisuuden perusteella. Tällöin saadaan **autokorrelaatiofunktio**

$$\rho_{yy}(k) = \frac{\gamma_{yy}(k)}{\gamma_{yy}(0)} = \frac{\gamma_{yy}(k)}{\sigma_y^2}, \tag{3.34}$$

jonka estimaattia merkitään $r_{yy}(k)$. Jatkossa edellä selostetuista korrelaatiofunktioista käytetään lyhyempiä merkintöjä γ_k,c_k,ρ_k ja r_k, mikäli ei erikseen haluta painottaa käsiteltävää signaalia. Käytännössä autokovarianssi- ja korrelaatiofunktioita ei ole järkevää estimoida kovin suurilla k:n arvoilla, koska mitä suuremmaksi k tulee, sitä epäluotettavampia estimaatit ovat. Esim. Box ja Jenkins [19] suosittelevat k:n ylärajaksi korkeintaan $N/4$ ja N vähintään 50.

Aiemmin todettiin, että minimivarianssisäädössä säädetyn suureen autokorrelaation tulee olla nolla prosessiviiveen jälkeen. Koska käytössä on vain tilastollisia estimaatteja, autokorrelaatiota on verrattava luottamusväleihin. Jos oletetaan, että viiveen d jälkeiset termit autokorrelaatiossa ovat nollia, voidaan normaalijakautuneen satunnaissignaalin autokorrelaation varianssille johtaa viiveen d jälkeen yhtälö [19, s. 35]

$$\mathrm{var}[r_k] \simeq \frac{1}{N}\left(1 + \sum_{m=1}^{d} \rho_m\right), \qquad k > d. \tag{3.35}$$

Käytännössä teoreettisia arvoja autokorrelaatiolle ρ_m ei tunneta, mutta jos niiden paikalle vaihdetaan estimaatit r_m, saadaan luottamusvälin estimaatti. Näin autokorrelaation keskihajonnaksi saadaan

$$\hat{\sigma}_{r_k} = \sqrt{\frac{1}{N}\left(1 + \sum_{m=1}^{d} r_m\right)}, \qquad k > d. \tag{3.36}$$

Valkoisella kohinalla tämä supistuu muotoon

$$\hat{\sigma}_{r_k} = \frac{1}{\sqrt{N}}. \tag{3.37}$$

Jos oletetaan autokorrelaatiofunktio normaalijakautuneeksi, sen $(1-\alpha)\cdot 100\%$ luottamusväliksi saadaan

$$-z_{1-\frac{\alpha}{2}}\hat{\sigma}_{r_k} < \rho_k < z_{1-\frac{\alpha}{2}}\hat{\sigma}_{r_k}, \tag{3.38}$$

jossa $z_{1-\frac{\alpha}{2}}$ on satunnaismuuttujan arvo, jolla N(0,1) normaalijakauman kertymäfunktio saa arvon $1-\frac{\alpha}{2}$. Esimerkiksi $z_{0,975} \approx 1{,}96$ vastaa 95 % luottamusväliä, $z_{0,995} \approx 2{,}58$ vastaa 99 % luottamusväliä ja $z_{0,9995} \approx 3{,}29$ vastaa 99,9 % luottamusväliä.

Mallin kertalukujen määrityksessä lähdetään liikkeelle signaalin stationaarisuuden tarkastelusta, koska menetelmät olettavat signaalin olevan stationaarinen. Signaalin epästationaarisuus ilmenee mm. ajan mittaan vaihtelevana keskiarvona. Jos tällaisia ilmiöitä on havaittavissa, niin ne voidaan poistaa muodostamalla apusignaali differenssin avulla yhtälön (3.22) mukaisesti. Tätä jatketaan niin kauan, kunnes epästa-

tionäärisyydet ovat poistuneet. Yleensä riittää tarkastella kertalukuja $c = 0{,}1$ ja 2 [19].

Seuraava vaihe on löytää kertaluvut p ja z. Jos käytetään AR-mallia, niin kertaluku z on nolla ja MA-mallissa puolestaan kertaluku p on nolla. Eräs menetelmä kertaluvun valintaan on mallinnusvirheen suuruuden vertailu eri kertaluvuilla. Tämä tarkoittaa sitä, että ensin valitaan tarkasteltavat kertaluvut, minkä jälkeen lasketaan kaikilla näillä kertaluvuilla varsinaiset mallin parametrit a_i ja b_i. Tämän jälkeen lasketaan kullekin mallille mallinnusvirheet eli residuaalit ja lopuksi lasketaan niiden varianssi. Ongelma on kuitenkin siinä, että parametrimäärän kasvaessa mallinnusvirheen varianssi $\hat{\sigma}_e^2$ yleensä pienenee. Varsinaista minimiä, josta paras kertaluku voitaisiin päätellä, ei siis muodostu. Tätä varten on kehitelty erilaisia kriteereitä, jotka kasvavat parametrimäärän kasvaessa. Näitä ovat esim. [21] Akaike's Information Criterion (**AIC**)

$$\mathrm{AIC}(n) = \ln \hat{\sigma}_e^2 + \frac{2n}{N}, \tag{3.39}$$

missä n on estimoitujen parametrien määrä, Final Prediction Error (**FPE**)

$$\mathrm{FPE}(n) = \hat{\sigma}_e^2 \left(\frac{N + n + 1}{N - n - 2} \right) \tag{3.40}$$

ja Rissasen Minimum Description Length (**MDL**)

$$\mathrm{MDL}(n) = N \ln \hat{\sigma}_e^2 + n \ln N. \tag{3.41}$$

Jonkinlainen arvio mallin kertaluvusta voidaan saada myös autokorrelaatio- ja **osittaisautokorrelaatiofunktioiden** (partial autocorrelation function) avulla. Kuten jo aiemmin todettiin, MA-prosessilla autokorrelaatio on nollasta poikkeava vain z ensimmäistä termiä. Osittaisautokorrelaatio on analoginen funktio AR-malleille. Se lasketaan sovittamalla dataan AR-malli kaikilla tarkastelun kohteena olevilla kertaluvuilla p. Osittaisautokorrelaatio kullakin kertaluvulla on kyseisen mallin viimeinen parametri a_p. Jos prosessi on AR(p)-tyyppinen, niin osittaisautokorrelaatiofunktio poikkeaa nollasta vain p:llä ensimmäisellä termillä. Käytännössä siis p:n jälkeiset termit osittaisautokorrelaatiofunktiossa ovat tilastollisesti merkityksettömiä. Tämän

funktion jakauma p:n jälkeisillä termeillä on sama kuin valkoisen kohinan autokorrelaation, eli luottamusvälit voidaan laskea yhtälön (3.37) avulla. [19]

Kun mallin parametrit on estimoitu, tarkastellaan, kuinka hyvin malli sovittuu dataan. Eräs tärkeä mallin ominaisuus, jota yleensä tarkastellaan, ovat residuaalit. Ne voidaan laskea suodattamalla mallinnettava signaali identifioidun mallin inversiolla:

$$v(n) = \frac{A(q^{-1})}{B(q^{-1})} a(n), \tag{3.42}$$

missä $a(n) = \nabla^c y(n)$. Hyvällä mallilla residuaalien pitäisi olla toisistaan riippumattomia, mitä voidaan tarkastella esim. autokorrelaation $r_v(k)$ avulla. Luottamusväleinä voidaan käyttää valkoiselle kohinalle johdettuja luottamusvälejä, jotka saadaan yhtälön (3.37) avulla. On tosin osoitettu, että pienillä viiveillä todelliset luottamusvälit voivat olla estimoituja luottamusvälejä huomattavasti kapeammat [19]. Viiveiden kasvaessa todelliset luottamusvälit lähestyvät kuitenkin em. luottamusvälejä yleensä varsin nopeasti, joten yhtälön (3.37) avulla saatuja luottamusvälejä voidaan pitää luottamusvälien "ylärajana".

Toinen vaihtoehto on tutkia suurempaa autokorrelaatiojoukkoa testisuureen

$$Q = n \sum_{k=1}^{K} r_v^2(k) \tag{3.43}$$

avulla, joka on likimäärin $\chi^2(K - p - z)$ jakautunut, ja missä $n = N - c$ ja K on huomioitavien autokorrelaatiofunktion termien määrä. Merkintä $\chi^2(K - p - z)$ tarkoittaa χ^2-jakaumaa vapausasteilla $K - p - z$. Testin nollahypoteesi on, että residuaalit ovat toisistaan riippumattomia eli malli sovittaa datan hyvin. Vastahypoteesi on puolestaan, että residuaalit eivät ole toisistaan riippumattomia. Testissä H_0 hylätään valitulla riskitasolla α, jos

$$Q > \chi^2_{1-\alpha}(K - p - z). \tag{3.44}$$

Testi suoritetaan siten, että valitaan todennäköisyys α, että malli hylätään vaikka se on kelvollinen, lasketaan testisuure Q ja verrataan tätä kertymäfunktion $\chi^2_{1-\alpha}(K -$

$p-z$) arvoon. Toinen vaihtoehto on laskea ensin Q ja tämän jälkeen laskea testin P-arvo. Mitä pienempi P-arvoksi tulee, sitä enemmän testi puoltaa H_0 : n hylkäämistä eli residuaalit riippuvat toisistaan. Tällöin malli on siis hylättävä.[19, 23]

Tarkastellaan autokorrelaation luottamusvälien estimointia esimerkin avulla. Matlabilla generoitiin normaalijakautunut satunnaislukuvektori $x(n)$. Tarkastetaan autokorrelaation avulla, ovatko luvut satunnaislukuja eli onko signaali valkoista kohinaa. Satunnaislukujen tulisi olla toisistaan riippumattomia. Signaali ei saisi siis korreloida aikaisempien eikä myöhempien arvojensa kanssa. Toisin sanottuna valkoisen kohinalla

$$\rho_{xx}(k) = \delta(k), \tag{3.45}$$

missä $\delta(k)$ on yksikköimpulssi, joka määritellään

$$\delta(k) = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases}. \tag{3.46}$$

Testataan seuraavaksi signaalin autokorrelaatiofunktiota testillä, jossa nollahypoteesi on, että signaali on valkoista kohinaa. Kuvaan 3.2a on piirretty Matlabin generoima signaali $x(n)$ ja kuvaan 3.2b autokorrelaatiofunktioestimaatin $r_{xx}(k)$ 20 ensimmäistä arvoa 95 % luottamusväleillä. Kuvaa ei ole tarvetta piirtää k:n negatiivisilla arvoilla, koska $\rho(k) = \rho(-k)$. Luottamusvälit on laskettu yhtälön (3.37) avulla. Autokorrelaatioestimaatin perusteella voidaan todeta, että generoitu signaali on valkoista kohinaa, koska autokorrelaatiofunktio pysyy luottamusvälien sisällä, kun $k > 0$.

3.3 Häiriöiden etsintä ja eliminointi

Mikäli takaisinkytketty säätö toimii optimaalisesti, on etsittävä muita keinoja prosessin varianssin pienentämiseksi. Yksi vaihtoehto on käyttää myötäkytkentää, mikäli jonkin häiriösuureen dynaaminen vaikutus lähtösuureeseen tunnetaan ja häiriöstä

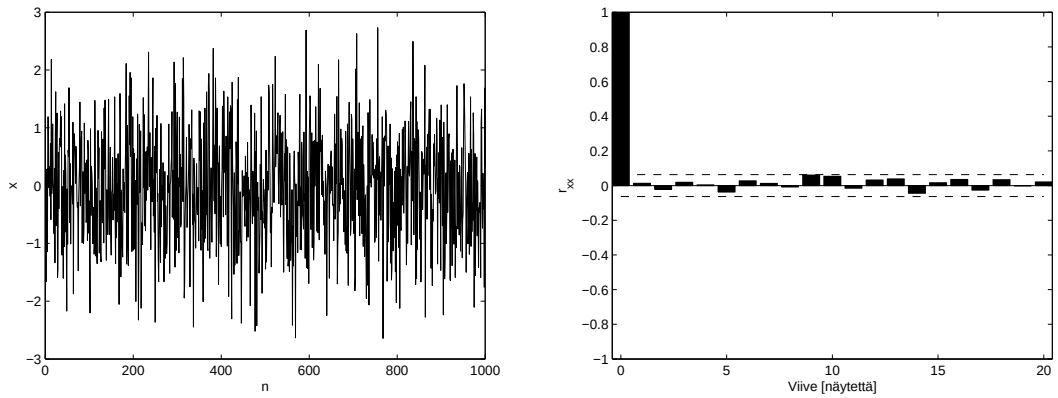

(a) (b)

Kuva 3.2 Esimerkki (a) valkoisesta kohinasta ja (b) sen autokorrelaatiofunktion estimaatista.

on olemassa mittaus tai se voidaan luotettavasti estimoida. Lisäksi on tunnettava prosessin siirtofunktio ohjausmuuttujasta lähtöön, eli yhtälön (3.1) merkinnöillä siirtofunktio G_p. Nämä vaatimukset johtuvat siitä, että ideaalinen myötäkytkennän säätäjä suunnitellaan yhtälön

$$u(n) = -\frac{H(q^{-1})}{G_\mathrm{p}(q^{-1})} w(n) \tag{3.47}$$

mukaan, missä siirtofunktio H kuvaa häiriön dynaamisen vaikutuksen lähtöön [24]. Säätäjää ei tietenkään aina voida tällaisenaan toteuttaa, mutta yhtälö antaa silti selkeän ohjenuoran, jonka mukaan tulisi toimia. Jos myötäkytkentäsäätäjä on väärin suunniteltu, se voi jopa kasvattaa prosessin varianssia.

Mikäli prosessin lähtösuureeseen vaikuttavia häiriöitä ei ole entuudestaan tiedossa, niin niitä voidaan etsiä. Seuraavaksi esitetään menetelmiä, joilla voidaan todeta häiriöiden olemassaolo ja arvioida niiden soveltuvuutta myötäkytkettyyn säätöön.

3.3.1 Korrelaatioanalyysi

Tavoitteena on siis etsiä kausaalinen vuorovaikutus häiriöstä w lähtöön y. Siirtofunktio on yksi tapa kuvata tällainen vuorovaikutus. Koska systeemi on takaisinkytketty, niin yhtälön (3.47) siirtofunktioista ei ole saada tarkkaa tietoa ilman prosessikokeita.

Sen sijaan on mahdollista identifioida suljetun systeemin siirtofunktio

$$y(n) - \mu_y = \frac{H(q^{-1})}{1 + G_{\mathrm{c}}(q^{-1})G_{\mathrm{p}}(q^{-1})} w(n) = H_{\mathrm{cl}}(q^{-1})w(n). \tag{3.48}$$

Mikäli häiriön vuorovaikutus on merkittävää, niin tämä on nähtävissä mm. merkittävinä tilastollisina poikkeamina siirtofunktion H_{cl} impulssivasteessa. On tietenkin mahdollista, että säädin G_{c} eliminoi häiriön, jolloin vuorovaikutusta ei nähdä, mutta silloinhan tilanne on hyvä. Toisin sanoen tutkimalla siirtofunktion H_{cl} impulssivastetta voidaan löytää häiriölähteitä, joita säädin ei pysty eliminoimaan. Stanfelj et al. [25] käyttivät samantyyppistä lähestymistapaa myötäkytketyn säätäjän suorituskyvyn tutkimiseen.

Impulssivaste voidaan määrittää joko parametrisesti tai epäparametrisesti. Parametrisessa lähestymistavassa häiriön ja lähdön välille identifioidaan ensin siirtofunktio, jonka avulla lasketaan impulssivaste luottamusväleineen. Epäparametrisissa menetelmissä dataan sovitetaan suoraan impulssivaste. Niillä saadaan karkeampi arvio kuin parametrisilla menetelmillä, mutta laskenta on yksinkertaisempaa. Tässä työssä käytetään häiriöiden etsinnässä epäparametrista menetelmää, koska menetelmän tarkoituksena on vain löytää merkittäviä häiriötekijöitä ilmentäviä syyseuraussuhteita eikä kuvata tässä vaiheessa systeemiä sen tarkemmin.

Tarkastellaan takaisinkytkettyä prosessia

$$y(n) = H_{\mathrm{cl}}(q^{-1})w(n) + v(n) = h_{\mathrm{cl}}(0)w(n) + h_{\mathrm{cl}}(1)w(n-1) + ... + v(n) \tag{3.49}$$

missä $h_{\mathrm{cl}}(k), k = 0,1,2,...$ on siirtofunktion H_{cl} impulssivaste, $v(n)$ on tuntematon häiriö, joka voidaan mallintaa ARIMA-prosessina samoin kuin tutkittava häiriölähde $w(n)$. Oletetaan myös, että w ja v ovat toisistaan riippumattomia. Siirtofunktion $H_{\mathrm{cl}}(q^{-1})$ impulssivaste $h_{\mathrm{cl}}(k)$ voidaan määrittää yhtälöllä [19, s. 379]

$$\mathbf{G}_{wy} = \mathbf{G}_{ww}\mathbf{h}_{\mathrm{cl}}, \tag{3.50}$$

missä

$$\mathbf{G}_{wy} = \begin{bmatrix} \gamma_{wy}(0) \\ \gamma_{wy}(1) \\ \vdots \\ \gamma_{wy}(N) \end{bmatrix} \quad \mathbf{G}_{ww} = \begin{bmatrix} \gamma_{ww}(0) & \gamma_{ww}(1) & \dots & \gamma_{ww}(N) \\ \gamma_{ww}(1) & \gamma_{ww}(0) & \dots & \gamma_{ww}(N-1) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{ww}(N) & \gamma_{ww}(N-1) & \dots & \gamma_{ww}(0) \end{bmatrix}$$

$$\mathbf{h}_{\mathrm{cl}} = \begin{bmatrix} h_{\mathrm{cl}}(0) \\ h_{\mathrm{cl}}(1) \\ \vdots \\ h_{\mathrm{cl}}(N) \end{bmatrix}. \tag{3.51}$$

Laskenta kuitenkin yksinkertaistuu huomattavasti, mikäli häiriö w on valkoista kohinaa. Jos näin ei ole, niin häiriösignaali voidaan ns. valkaista. Tätä toimenpidettä kutsutaan esivalkaisuksi (prewhitening). Esivalkaisu tapahtuu siten, että mallinnetaan ensin tunnettu häiriösignaali w aikasarjamallilla

$$w(n) = H_{\mathrm{pw}}(q^{-1})a(n), \tag{3.52}$$

missä $a(n)$ on valkoista kohinaa, jonka keskihajonta on σ_a. Jos w on epästationaarinen, voidaan lisäksi käyttää differenssiä muuntamaan se stationaariseksi. Seuraavaksi luodaan signaali $a(n)$ suodattamalla häiriösignaali edellisen inversiolla eli

$$a(n) = \frac{1}{H_{\mathrm{pw}}(q^{-1})}w(n). \tag{3.53}$$

Tämän pitäisi olla valkoista kohinaa. Seuraavaksi suodatetaan lähtösignaali samalla suodattimella, jolloin saadaan

$$b(n) = \frac{1}{H_{\mathrm{pw}}(q^{-1})}y(n). \tag{3.54}$$

Impulssivaste $h_{\mathrm{cl}}(k)$ saadaan nyt ristikovarianssin γ_{ab} tai ristikorrelaation ρ_{ab} avulla

$$h_{\mathrm{cl}}(k) = \frac{\gamma_{ab}(k)}{\sigma_a^2} = \frac{\rho_{ab}(k)\sigma_b}{\sigma_a}, \qquad k = 0,1,2,... \tag{3.55}$$

missä σ_b on signaalin $b(n)$ keskihajonta. Signaalien a ja b ristikovarianssi määritellään [19]

$$\gamma_{ab}(k) = \mathrm{E}\left\{[a(n) - \mu_a][b(n+k) - \mu_b]\right\}, \tag{3.56}$$

josta saadaan edelleen ristikorrelaatio

$$\rho_{ab}(k) = \frac{\gamma_{ab}(k)}{\sigma_a \sigma_b}. \qquad k = 0, \pm 1, \pm 2,... \tag{3.57}$$

Näin siis valkaistun tulosignaalin ja vastaavalla suodatuksella muunnetun lähtösignaalin ristikorrelaatio on suoraan verrannollinen suljetun systeemin impulssivasteeseen. Käytännössä ristikovarianssi ja -korrelaatio on estimoitava, joten niitä on tarkasteltava tilastollisina estimaattoreina. Eräs estimaattori ristikovarianssille $\gamma_{xy}(k)$ on [19, s. 374]

$$c_{xy}(k) = \begin{cases} \frac{1}{N} \sum\limits_{n=1}^{N-k} [x(n) - \bar{x}]\,[y(n+k) - \bar{y}] & k = 0,1,2,... \\ \frac{1}{N} \sum\limits_{n=1}^{N+k} [y(n) - \bar{y}]\,[x(n-k) - \bar{x}] & k = 0, -1, -2,.. \end{cases}. \tag{3.58}$$

Ristikorrelaation $\rho_{xy}(k)$ estimaatti $r_{xy}(k)$ saadaan tämän perusteella

$$r_{xy}(k) = \frac{c_{xy}(k)}{\hat{\sigma}_x \hat{\sigma}_y}, \tag{3.59}$$

missä $\hat{\sigma}_x$ ja $\hat{\sigma}_y$ ovat signaalien x ja y keskihajonnan estimaatteja.

Tarkastellaan seuraavaksi ristikorrelaation luottamusvälejä. Oletetaan, että ristikorrelaatio on nollasta poikkeava vain tietyllä äärellisellä viiveiden joukolla $k_1 \leq k \leq k_2$, mikä yleensä on varsin hyvä oletus. Tällöin ristikorrelaatioestimaatin luottamusvälit tämän joukon ulkopuolella saadaan yhtälöllä [19, s. 377]

$$\mathrm{var}\left[r_{xy}(k)\right] \simeq \frac{1}{N-k} \sum_{\nu=-\infty}^{\infty} \rho_{xx}(\nu)\rho_{yy}(\nu). \quad k \geq 0 \tag{3.60}$$

Luottamusvälien testauksessa nollahypoteesina pidetään sitä, että signaalit x ja y eivät korreloi keskenään. Tällöin $r_{xy}(k)$ pysyy luottamusvälien sisällä kaikilla k:n arvoilla. Kun tarkastellaan yhtälöä (3.60) esivalkaistulla tulosignaalilla $x(n) = a(n)$

ja suodatetulla lähtösignaalilla $y(n) = b(n)$, niin sitä voidaan vielä yksinkertaistaa lisää, koska valkaistun häiriösignaalin $\rho_{aa}(k) = \delta(k)$. Näin ristikorrelaation varianssi supistuu muotoon

$$\mathrm{var}\,[r_{ab}(k)] \simeq \frac{\rho_{bb}(0)}{N-k} = \frac{1}{N-k}, \tag{3.61}$$

koska $\rho_{bb}(0) = 1$ autokorrelaation määritelmän (3.34) mukaan. Tässä tapauksessa esim. ristikorrelaation 95 % luottamusväleiksi saadaan $\pm\frac{1{,}96}{\sqrt{N-k}}$. Jos halutaan tarkastella myös ristikorrelaation negatiivisia viiveitä, niin estimaatin keskihajonta on laskettava toisella tavalla. Ristikorrelaatiolle pätee

$$\rho_{xy}(-k) = \rho_{yx}(k). \tag{3.62}$$

Sijoittamalla tämä yhtälöön (3.60) saadaan

$$\mathrm{var}\,[r_{xy}(-k)] = \mathrm{var}\,[r_{yx}(k)] \simeq \frac{1}{N-k}\sum_{\nu=-\infty}^{\infty}\rho_{yy}(\nu)\rho_{xx}(\nu), \quad k \geq 0 \tag{3.63}$$

joka suppenee muotoon

$$\mathrm{var}\,[r_{xy}(-k)] = \frac{1}{N-k} \quad ,k \geq 0 \tag{3.64}$$

signaalin x ollessa valkoista kohinaa tai vaihtoehtoisesti muotoon

$$\mathrm{var}\,[r_{xy}(k)] = \frac{1}{N+k} \quad ,k < 0. \tag{3.65}$$

Ristikorrelaation tarkastelu negatiivisilla k:n arvoilla voi olla mielekästä, jos ei tiedetä varmasti kumpi signaali vaikuttaa kumpaan. Se voi myös paljastaa vuorovaikutuksen, jossa molemmat signaalit vaikuttavat toisiinsa. Esimerkkinä tästä on takaisinkytketyssä järjestelmässä ohjaussignaalin u ja lähtösignaalin y vuorovaikutus. Avoimessa piirissä ohjausmuuttujan vaikutus näkyy impulssivasteessa positiivisilla viiveillä mutta takaisinkytkennästä johtuen lähtösignaali vaikuttaa myös ohjaussignaaliin, mikä näkyy merkittävinä tilastollisina poikkeamina negatiivisilla viiveillä korrelaatiossa $r_{uy}(k)$. Analyysi voi paljastaa myös MIMO-riippuvuuksia. Mikäli tar-

kasteltava signaali x ei ole ohjausmuuttuja ja viiveen $k = 0$ molemmilla puolilla esiintyy merkittäviä ristikorrelaatioita, niin se merkitsee, että signaali x vaikuttaa lähtömuuttujan y ja päinvastoin. Takaisinkytketyssä systeemissä on tietysti mahdollista myös esimerkiksi se, että signaali y ei välttämättä vaikuta suoraan signaaliin x, vaan siihen voi vaikuttaa ohjausmuuttuja u, johon signaali y vaikuttaa.

3.3.2 Häiriöiden voimakkuuden arvioiminen

Kun potentiaalisia häiriösignaaleja on löydetty, niin on hyödyllistä tietää myös, kuinka suuri niiden vaikutus on säädettävän suureen vaihteluihin. Näin voidaan arvioida, kuinka järkevää niitä on käyttää myötäkytkennässä. Desborough ja Harris [14] esittelivät menetelmän, jolla voidaan arvioida häiriösignaalien osuutta prosessin kokonaisvarianssiin. Analyysi voidaan tehdä suljetun systeemin datan perusteella ilman prosessikokeita. Menetelmän tärkein oletus on, että mitatut ja tuntemattomat häiriöt ovat toisistaan riippumattomia, eli ne eivät korreloi keskenään. Tarkastellaan lineaarista prosessia

$$y(n) - \mu_y = G_\mathrm{p}(q^{-1})q^{-d_\mathrm{p}}u(n) + w_0(n) + \sum_{i=1}^{m} N_i(q^{-1})q^{-d_i}\left[w_i(n) - \mu_i\right], \tag{3.66}$$

missä m on prosessiin vaikuttavien mitattujen häiriöiden $w_i(n)$ lukumäärä ja d_i on viive, jonka jälkeen häiriön w_i vaikutus alkaa näkyä prosessin lähdössä. Termi $w_0(n)$ kuvaa tuntemattomien häiriöiden yhteisvaikutuksen prosessin lähtöön. Häiriösignaalit voidaan mallintaa ARIMA-malleilla

$$w_i(n) - \mu_i = \frac{B_i(q^{-1})}{A_i(q^{-1})\nabla^{c_i}}v_i(n), \tag{3.67}$$

missä $v_i(n)$ on valkoista kohinaa, jonka varianssi on σ_i^2. Kuvassa 3.3 on esitetty takaisinkytketty systeemi edellä kuvatuilla määrityksillä. Takaisinkytketyssä systeemissä prosessin lähtösuure voidaan kuvata yhtälöllä

$$y(n) - \mu_y = \sum_{i=0}^{n} H_i(q^{-1})v_i(n) = \sum_{i=0}^{n} y_i(n), \tag{3.68}$$

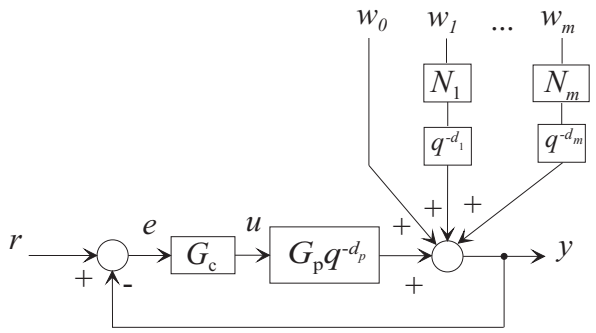

Kuva 3.3 Takaisinkytketty systeemi, johon vaikuttaa häiriösuureet w_0,$w_1, \ldots ,w_m$. Häiriösuureet w_1,$w_2, \ldots ,w_m$ mitataan ja häiriö w_0 on tuntemattomien häiriöiden kokonaisvaikutus.

missä $H_i(q^{-1})$ on i:nnen häiriön ja keskiarvolla korjatun lähdön välinen suljetun systeemin siirtofunktio ja y_i on i:nnestä häiriöstä aiheutuva komponentti säädettävään suureeseen. Näin menetellen kunkin komponentin tuottama varianssi lähtösuureeseen voidaan kirjoittaa olettaen häiriölähteet $v_i(n)$ toisistaan riippumattomiksi

$$\mathrm{var}[y_i(n)] = \sigma_i^2 \sum_{k=0}^{\infty} h_i^2(k), \tag{3.69}$$

missä $h_i(k)$ on suljetun systeemin siirtofunktion $H_i(q^{-1})$ impulssivaste. Impulssivaste eli painojono voidaan laskea mm. jakamalla siirtofunktion osoittajapolynomi nimittäjäpolynomilla polynomien jakolaskulla tai määrittämällä siirtofunktion käänteismuunnos osamurtokehitelmien ja tunnettujen signaalien käänteismuunnosten avulla. Käytännössä äärettömän pitkä impulssivaste katkaistaan usein äärelliseksi laskemalla vain merkittävimmät termit vasteen alusta.

Jotta häiriötä voitaisiin käyttää myötäkytkennässä, on tarkasteltava vielä prosessin viiveitä. Myötäkytkennän kannalta on edullista, että häiriön viive d_i on pidempi kuin prosessin viive d_p. Tämä on nähtävissä esim. yhtälöstä (3.47). Jos yhtälön nimittäjän (prosessin) viive on pidempi kuin osoittajan (häiriön), yhtälöön tulee termi $q^{d_\mathrm{p}-d_i} = q^a$, jossa $a > 0$. Tämä tarkoittaa, että optimaalinen säätölaki tarvitsee ennustajaa. Mitä suurempi a, sitä vaikeampaa ennustaminen on. Seuraavassa tämä pyritään selittämään minimivarianssisäädön näkökulmasta. Minimivarianssisäätö tuottaa prosessin lähtöön komponentin $y_\mathrm{mv}(n)$, joka voidaan kirjoittaa häiriöiden

ennustusvirheiden $e_i^{\mathrm{mv}}(n)$ avulla:

$$y_{\mathrm{mv}}(n) = \sum_{i=0}^{m} e_i^{\mathrm{mv}}(n), \tag{3.70}$$

missä

$$e_i^{\mathrm{mv}}(n) = \begin{cases} 0 & d_i > d_{\mathrm{p}} \\ \sum\limits_{k=d_{i,\mathrm{eff}}}^{d_{\mathrm{p}}} h_i(k) q^{-k} v_i(t) & d_i \leq d_{\mathrm{p}} \end{cases} \tag{3.71}$$

ja $d_{i,\mathrm{eff}}$ on se hetki, jolloin häiriön i vaikutus alkaa näkyä lähdössä. Mikäli järjestelmässä on olemassa myötäkytkentä häiriöstä i niin $d_{i,\mathrm{eff}} = \min(d_{\mathrm{p}}, d_i)$ ja muuten $d_{i,\mathrm{eff}} = d_i$. Yhtälö (3.71) siis kertoo, että häiriön viiveen ollessa prosessiviivettä pidempi ennustusvirhe on nolla, koska ennustusta ei tarvita ja että mitä suurempi d_{p} on d_i:n verrattuna sitä suurempi ennustusvirheestä tulee. Jos prosessiviive on suurempi kuin häiriön viive, summaus aloitetaan termistä $d_{i,\mathrm{eff}}$, koska impulssivasteen $h_i(k)$ ensimmäiset termit ovat nollia. Prosessin varianssiksi minimivarianssisäädössä tulee

$$\sigma_{\mathrm{mv}}^2 = \sum_{i=0}^{m} \mathrm{var}\left[e_i^{\mathrm{mv}}(n)\right], \tag{3.72}$$

missä

$$\mathrm{var}\left[e_i^{\mathrm{mv}}(n)\right] = \begin{cases} 0 & d > d_{\mathrm{p}} \\ \sigma_i^2 \sum\limits_{k=d_{i,\mathrm{eff}}}^{d_{\mathrm{p}}} h_i^2(k) & d \leq d_{\mathrm{p}} \end{cases}. \tag{3.73}$$

Mikäli säädin ei ole minimivarianssisäädin, suljetun systeemin impulssivaste $h_i(k)$ on nollasta poikkeava arvoilla $k > d_{\mathrm{p}}$. Siten häiriöstä i prosessin lähtöön aiheutuva komponentti voidaan kirjoittaa

$$y_i(n) = e_i^{\mathrm{mv}}(n) + \sum_{n=d_{\mathrm{p}}}^{\infty} h_i(k) q^{-k} v(n). \tag{3.74}$$

Yhtälö jakaa häiriön kahteen toisistaan riippumattomaan osaan, joista jälkimmäinen johtuu säätimen epäoptimaalisuudesta.

Tuntemattomien häiriöiden muodostaman w_0:n lähtösuureeseen aiheuttama häiriökomponentti $y_0(n)$ voidaan jakaa säätimestä riippumattomaan osaan $e_0^{\mathrm{mv}}(n)$ ja ta-

kaisinkytkennän epäideaalisuudesta johtuvaan osaan $y_0^{\mathrm{fb}}(n)$:

$$y_0(n) = e_0^{\mathrm{mv}}(n) + y_0^{\mathrm{fb}}(n) = \sum_{k=0}^{d_{\mathrm{p}}-1} h_0(k)q^{-k}v(n) + \sum_{k=d_{\mathrm{p}}}^{\infty} h_0(k)q^{-k}v(n). \tag{3.75}$$

Tunnettujen häiriöiden $w_i(n), i = 1...m$ vaimennukseen käytettyjen myötäkytkentäsäädinten epäoptimaalisuus voidaan jakaa yksin myötäkytkennästä johtuvaan osaan $y_i^{\mathrm{ff}}(n)$ sekä myötäkytkennästä ja takaisinkytkennästä johtuvaan osaan $y_i^{\mathrm{ff/fb}}(n)$. Näin i:nnestä häiriöstä lähtösuureeseen aiheutuva komponentti voidaan kirjoittaa

$$y_i(n) = e_i^{\mathrm{mv}}(n) + y_i^{\mathrm{ff}}(n) + y_i^{\mathrm{ff/fb}}(n), \tag{3.76}$$

missä

$$y_i^{\mathrm{ff}}(n) = \sum_{k=d_{\mathrm{p}}}^{d_{\mathrm{p}}+d_{i,\mathrm{eff}}-1} h_i(k)q^{-k}v_i(n) \tag{3.77}$$

$$y_i^{\mathrm{ff/fb}}(n) = \sum_{k=d_{\mathrm{p}}+d_{i,\mathrm{eff}}}^{\infty} h_i(k)q^{-k}v_i(n). \tag{3.78}$$

Tällaisen jaon avulla voidaan arvioida olemassa olevan myötäkytkennän suorituskykyä tai myötäkytkennän lisäämisen kannattavuutta kustakin signaalista, mikäli kyseisistä signaaleista ei ole tarkastelujaksolla käytetty myötäkytkentää. Prosessin lähtösuureen kokonaisvarianssiksi σ_y^2 saadaan

$$\sigma_y^2 = \sigma_{\mathrm{mv}}^2 + \sum_{i=0}^{m} \left\{ \mathrm{var}\left[y_i^{\mathrm{ff}}(n)\right] + \mathrm{var}\left[y_i^{\mathrm{ff/fb}}(n)\right] \right\}, \tag{3.79}$$

missä summauksen sisällä oleva osa kuvaa säädinten epäideaalisuudesta johtuvia varianssikomponentteja, jotka voidaan laskea yhtälöiden (3.77) ja (3.78) avulla seuraavasti:

$$\mathrm{var}\left[y_i^{\mathrm{ff}}(n)\right] = \sigma_i^2 \sum_{k=d_{\mathrm{p}}}^{d_{\mathrm{p}}+d_{i,\mathrm{eff}}-1} h_i^2(k). \tag{3.80}$$

$$\mathrm{var}\left[y_i^{\mathrm{ff/fb}}(n)\right] = \sigma_i^2 \sum_{k=d_{\mathrm{p}}+d_{i,\mathrm{eff}}}^{\infty} h_i^2(k) \tag{3.81}$$

Taulukko 3.1 Säädettävän suureen varianssin jako eri lähteistä johtuviin tekijöihin. Lyhenteiden merkitykset: mv $\hat{=}$ minimivarianssi, fb $\hat{=}$ tuntemattomasta häiriöstä johtuva osuus (voidaan poistaa optimaalisella takaisinkytkennällä), ff $\hat{=}$ yksin myötäkytkennästä (tai sen puutteesta) johtuva osuus ja ff/fb $\hat{=}$ komponentti, johon molemmat säätimet vaikuttavat (voidaan kuitenkin eliminoida myötäkytkennällä).

Häiriölähde	Varianssin syy				Yhteensä
	mv	fb	ff	ff/fb	
w_0	$\mathrm{var}(e_0^{\mathrm{mv}})$	$\mathrm{var}(y_0^{\mathrm{fb}})$	—	—	$\mathrm{var}(y_0)$
w_1	$\mathrm{var}(e_1^{\mathrm{mv}})$	—	$\mathrm{var}(y_1^{\mathrm{ff}})$	$\mathrm{var}(y_1^{\mathrm{ff/fb}})$	$\mathrm{var}(y_1)$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
w_m	$\mathrm{var}(e_m^{\mathrm{mv}})$	—	$\mathrm{var}(y_m^{\mathrm{ff}})$	$\mathrm{var}(y_m^{\mathrm{ff/fb}})$	$\mathrm{var}(y_m)$
Yhteensä	σ_{mv}^2	$\sigma_y^2 - \sigma_{\mathrm{mv}}^2$			σ_y^2

Tuntemattomien häiriöiden tapauksessa, eli kun $i = 0$, yhtälössä (3.79) $y_0^{\mathrm{ff}}(n) = 0$ ja $y_0^{\mathrm{ff/fb}}(n) = y_0^{\mathrm{fb}}(n)$. Tämä johtuu siitä, että tuntemattomaan häiriöön ei vaikuteta myötäkytkentäsäätimellä.

Tulokset voidaan koota esim. taulukon 3.1 mukaiseen muotoon. Taulukon riveillä olevat häiriösignaalien $w_0(n) \ldots w_n(n)$ aiheuttamat varianssit on jaettu sarakkeilla minimivarianssiin, takaisinkytkennästä johtuvaan, myötäkytkennästä johtuvaan ja molemmista säädöistä johtuvaan osaan. Viimeinen sarake kertoo kunkin häiriösignaalin aiheuttaman kokonaisvarianssin. Taulukon viimeinen rivi puolestaan jakaa säädettävän suureen varianssin minimivarianssiin ja nykyisen säädön epäoptimaalisuudesta johtuvaan osaan. Taulukon arvot voidaan laskea suljetun systeemin impulssivasteista yhtälön

$$\text{termi} = \sigma_i^2 \sum_{k=\text{alku}}^{\text{loppu}} h_i^2(k) \tag{3.82}$$

ja taulukon 3.2 avulla.

Taulukon 3.1 täyttämiseksi on identifioitava yhtälön (3.68) suljetun systeemin siirtofunktiot $H_i(q^{-1})$. Tämä voidaan tehdä useassa vaiheessa yhtälöihin (3.66) ja (3.67) perustuen. Ensin mallinnetaan kaikkien häiriöiden $w_i(n)$ yhteisvaikutus lähtösuureeseen. Tähän voidaan käyttää esim. ARX-, ARMAX- tai Box-Jenkins malleja,

Taulukko 3.2 Summauksen alku- ja loppuindeksit yhtälöön (3.82) taulukon 3.1 arvojen laskemiseksi.

i	termi	alku	loppu
0	$\mathrm{var}(e_0^{\mathrm{mv}})$	0	$d_{\mathrm{p}} - 1$
	$\mathrm{var}(y_0^{\mathrm{fb}})$	d_{p}	∞
$i \geq 1$	$\mathrm{var}(e_i^{\mathrm{mv}})$	$d_{i,\mathrm{eff}}$	$d_{\mathrm{p}} - 1$
	$\mathrm{var}(y_i^{\mathrm{ff}})$	d_{p}	$d_{\mathrm{p}} + d_{i,\mathrm{eff}} - 1$
	$\mathrm{var}(y_i^{\mathrm{ff/fb}})$	$d_{\mathrm{p}} + d_{i,\mathrm{eff}}$	∞

jotka esiteltiin kappaleessa 3.2.2. Sovelletaan näitä malleja seuraavaksi. Koska tässä tapauksessa mitattuja häiriöitä voi olla useita niin kirjoitetaan ARX-malli

$$A_0(q^{-1})y(n) = \sum_{i=1}^{m} B_i(q^{-1})q^{-d_i}w_i(n) + v_0(n), \tag{3.83}$$

ARMAX-malli

$$A_0(q^{-1})y(n) = \sum_{i=1}^{m} B_i(q^{-1})q^{-d_i}w_i(n) + C(q^{-1})v_0(n) \tag{3.84}$$

ja Box-Jenkins malli

$$y(n) = \sum_{i=1}^{m} \frac{B_i(q^{-1})}{F_i(q^{-1})}q^{-d_i}w_i(n) + \frac{C(q^{-1})}{D(q^{-1})}v_0(n). \tag{3.85}$$

Näissä yhtälöissä on havainnollistamisen vuoksi otettu viivetermit q^{-d_i} erilleen siirtofunktioista $B_i(q^{-1})$. Mallia identifioitaessa viiveet d_i joudutaan valitsemaan, joten ne ovat tavallaan sovitusparametreja.

Toisessa vaiheessa kukin häiriösignaali mallinnetaan jollakin kappaleessa 3.2.1 esitellyllä aikasarjamallilla, esimerkiksi AR-mallilla

$$w_i(n) = \frac{1}{A_i(q^{-1})}v_i(n). \tag{3.86}$$

Lopuksi mallit yhdistetään siten, että säädettävä suure $y(n)$ jaetaan eri satunnaissignaaleista $v_i(n)$ johtuviin komponentteihin $y_i(n)$. Tuntemattomasta häiriöstä johtuva komponentti saadaan aina suoraan ensimmäisessä vaiheessa identifioidusta mallista.

Esimerkiksi ARX-mallilla tämä komponentti on

$$y_0(n) = H_0(q^{-1})v_0(n) = \frac{1}{A_0(q^{-1})}v_0(n). \tag{3.87}$$

Jos tunnetut häiriöt w_i, $i = 1...m$ mallinnetaan toisessa vaiheessa AR-mallilla, niin niistä johtuvat komponentit ovat

$$y_i(n) = H_i(q^{-1})v_i(n) = \frac{B_i(q^{-1})q^{-d_i}}{A_0(q^{-1})A_i(q^{-1})}v_i(n). \tag{3.88}$$

Nyt varianssihajotelmat voidaan laskea. Menetelmän tärkeintä oletusta eli häiriöiden $v_i(n)$ riippumattomuutta voidaan tarkastella esimerkiksi residuaalien $\hat{v}_i(n)$ kovarianssimatriisin avulla [14]. Mikäli residuaaleilla ei ole merkittävää tilastollista kovarianssia, niin oletus residuaalien riippumattomuudesta pitää paikkansa.

Kun signaali mallinnetaan input-output mallilla, niin sovituksen onnistumista voidaan tarkastella residuaalien autokorrelaatioiden lisäksi myös residuaalien ja tulosignaalin ristikorrelaation avulla. Tämä ristikorrelaatio ei saisi sisältää tilastollisesti merkittäviä poikkeamia nollasta. Muutoin residuaalit sisältävät tulosignaalista lähtöisin olevan komponentin. Malli ei siis tällöin kykene kuvaamaan tulon ja lähdön välistä vuorovaikutusta tarkasti [27, 23].

Tarkastellaan seuraavaksi menetelmän käyttöä esimerkin avulla. Määritellään prosessi seuraavasti

$$y(n) = \frac{0{,}33}{1 - 0{,}67q^{-1}}q^{-4}u(n) + w_0(n) + \left(1 - 0{,}7q^{-1}\right)q^{-6}w_1(n),$$

missä häiriöt w_0 ja w_1 ovat

$$\begin{aligned} w_0(n) &= \frac{1 - 0{,}4q^{-1}}{1 - 0{,}67q^{-1}}v_0(n) \\ w_1(n) &= \frac{1}{1 - 0{,}5q^{-1}}v_1(n). \end{aligned}$$

Valkoisten kohinasignaalien varianssit ovat $\sigma_0^2 = 0{,}36$ ja $\sigma_1^2 = 0{,}2$. Säätimen siirtofunktioksi valittiin

$$u(n) = \frac{0{,}5876 - 0{,}3523q^{-1}}{1 - q^{-1}} y(n),$$

mikä edustaa PI-säädintä. Säädin viritettiin λ-menetelmällä muuntamalla prosessin siirtofunktio ensin jatkuva-aikaiseksi. Diskretointiajaksi valittiin 0,1 s. Diskretointiajalla ei ole merkitystä muun kuin säätimen virityksen kannalta. PI-säätimen λ-parametriksi valittiin arvo 0,1. Näin saadaan suljetun systeemin siirtofunktioiksi

$$\begin{aligned} H_0(q^{-1}) &= \frac{1 - 1{,}4q^{-1} + 0{,}4q^{-2}}{1 - 0{,}67q^{-1} + 0{,}67q^{-2} + 7{,}216 \cdot 10^{-16}q^{-3} + 0{,}1939q^{-4} - 0{,}1162q^{-5}} \\ H_1(q^{-1}) &= \frac{\left(1 - 2{,}37q^{-1} + 1{,}839q^{-2} - 0{,}469q^{-3}\right) q^{-6}}{1 - 2{,}17q^{-1} + 1{,}505q^{-2} - 0{,}335q^{-3} + 0{,}1939q^{-4} - 0{,}2132q^{-5} + 0{,}05812q^{-6}}. \end{aligned}$$

Näistä siirtofunktioista laskettiin impulssivasteet Matlabin *impulse*-funktiolla ja niiden avulla laskettiin varianssin jakautuminen eri lähteille.

Varianssianalyysi tehtiin myös identifioitujen mallien perusteella. Prosessimallista tehtiin Simulink-malli, joka on esitetty kuvassa 3.4. Tällä mallilla simuloitiin prosessin lähdöstä y ja tunnetusta häiriöstä w_1 1000 näytettä, joista identifioitiin mallit H_0 ja H_1. Jotta häiriöt $v_0(n)$ ja $v_1(n)$ olisivat toisistaan riippumattomia, niin satunnaisgeneraattorit alustettiin eri siemenluvuilla. Lähtösignaalin varianssiksi $\hat{\sigma}_y^2$ tuli 0,8397. Talletetun signaalin w_1 ja lähdön y välille identifioitiin ensin erilaisia aikasarjamalleja, joita merkitään seuraavassa $W_1(q^{-1})$. Tämän jälkeen identifioitiin signaalin w_1 aikasarjamalli ja lopuksi molemmat mallit yhdistettiin aiemmin kuvatulla tavalla, jolloin saatiin suljetun systeemin siirtofunktiot H_0 ja H_1. Varianssinanalyysi laskettiin kahden erilaisen identifioidun mallin W_1 perusteella. Toinen malleista oli Box-Jenkins tyyppinen ja toinen AIC-kriteerillä valittu ARX-malli. Häiriösignaalin w_1 siirtofunktiona käytettiin molemmissa tapauksissa samaa aikasarjamallia

$$w_1(n) = \frac{1}{1 - 0{,}4873q^{-1}} v_1(n).$$

Tässä tapauksessa sekä MDL että AIC tulivat samaan tulokseen mallin kertaluvun valinnassa. Matlabin ennustusvirhemenetelmä (PEM) estimoi häiriön $v_1$varianssiksi $\hat{\sigma}_{v_1}^2 = 0{,}2037$. Tuntemattoman häiriön v_0 varianssi saadaan W_1 mallien häiriömal-

lista. Box-Jenkins mallissa tuntemattoman häiriön varianssiksi tuli $\hat{\sigma}^2_{v_0} = 0{,}3793$ ja ARX-mallissa $\hat{\sigma}^2_{v_0} = 0{,}4234$. Varianssihajotelmat on koottu taulukkoon 3.3. Verrattaessa ARX- ja Box-Jenkins-mallien perusteella saatuja varianssihajotelmia siirtofunktioista laskettuihin variansseihin voidaan todeta, että identifioidut mallit kykenevät erottelemaan varianssikomponentit tässä tapauksessa varsin hyvin. Vain ARX-mallilla näyttää olevan pieniä ongelmia tuntemattoman häiriön jakamisessa minimivarianssiin ja takaisinkytkennän osuuteen. Tämä johtunee siitä, että ARX-mallissa tulosignaalilla ja tuntemattomalla häiriöllä on yhteiset navat, joten toisen mallinnus saattaa kärsiä.

Vertaillaan seuraavaksi hieman identifioitujen mallien ominaisuuksia suhteessa todelliseen malliin. Kuvaan 3.5 on piirretty simuloinnissa käytetyn mallin siirtofunktioiden W_1 ja H_0 impulssivasteet ja napa-nollakohtakuvaajat. Identifioiduista malleista on piirretty kuviin 3.6 ja 3.7 edellä mainittujen ominaisuuksien lisäksi myös residuaalien autokorrelaatiot ja ristikorrelaatiot häiriösignaalin kanssa. Residuaalien perusteella mallit näyttävät varsin päteviltä, vaikkakin ARX-mallin residuaalien autokorrelaatiot näyttävät hieman epäilyttäviltä viiveen 20 jälkeen. Impulssivastekuvia verrattaessa havaitaan, että molemmilla identifioiduilla malleilla saadaan hyvin samanlaiset vasteet kuin todellisten siirtofunktioiden perusteella lasketut ovat. Napa-nollakohtakuvat ovat muuten varsin järkevän oloisia, mutta Box-Jenkins mallissa siirtofunktio H_0 saattaa olla hieman ylimallinnettu, koska yhden napa- ja nollaparin luottamusvälit leikkaavat toisensa selvästi.

Tarkastellaan vielä mallien taajuusvasteita. Kuvassa 3.8 on vertailun helpottamiseksi kaikkien kolmen W_1 ja H_0 siirtofunktion bode-diagrammit. Box-Jenkins mallin taajuusvasteet näyttävät olevan lähempänä todellista kuin ARX-mallilla. Varsinkin tuntemattoman häiriön mallissa H_0 ero on selkeä.

Taulukko 3.3 Esimerkkiprosessin varianssin analyysitaulukko. Taulukon arvot on laskettu kolmella eri mallilla: simuloinnissa käytetyt siirtofunktiot, identifioitu Box-Jenkins (BJ) ja identifioitu ARX-malli. Tämän vuoksi jokainen taulukon 3.1 solu on jaettu kolmeen osaan.

Häiriölähde	Varianssin syy												Yhteensä		
	mv			fb			ff			ff/fb					
	oikea	BJ	ARX	oikea	BJ	ARX	oikea	BJ	ARX	oikea	BJ	ARX	oikea	BJ	ARX
w_0	0,403	0,399	0,516	0,203	0,212	0,093	—			—			0,606	0,610	0,609
w_1	0,00			—			0,208	0,212	0,216	0,036	0,035	0,028	0,244	0,247	0,244
Yhteensä	0,403	0,399	0,516	0,447			0,458			0,338			0,850	0,857	0,854
				oikea			BJ			ARX					

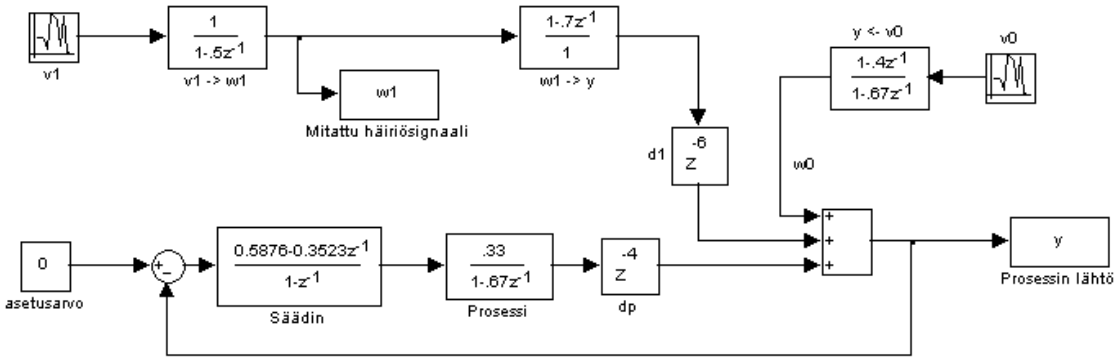

Kuva 3.4 Häiriöiden vaikutuksen arviointiin käytetyn esimerkin simulointimalli.

Tarkastetaan lopuksi häiriöiden riippumattomuus toisistaan. Residuaalien kovarianssimatriiseiksi saadaan Matlabin *cov* funktiolla Box-Jenkins ja ARX-malleille:

$$\mathbf{C_{BJ}} = \begin{bmatrix} 0{,}3648 & 0{,}0024 \\ 0{,}0024 & 0{,}2035 \end{bmatrix}$$

$$\mathbf{C_{ARX}} = \begin{bmatrix} 0{,}4140 & 0{,}0037 \\ 0{,}0037 & 0{,}2035 \end{bmatrix}$$

Residuaalien kovarianssitermit ovat varsin pieniä, mutta funktio ei kuitenkaan anna luottamusvälejä, joten kovarianssien tilastollista merkittävyyttä ei voida arvioida. Parempi funktio onkin *corrcoef*, jolla saadaan korrelaatiomatriisi ja haluttaessa korrelaatioiden merkitsevyystasot P sekä luottamusvälit. Funktio antaa Box-Jenkins mallilla residuaalien ristikorrelaation merkitsevyystasoksi $P = 0{,}78$ ja ARX-mallilla $P = 0{,}69$, mikä tarkoittaa että häiriölähteiden riippuvuus toisistaan on molemmissa tapauksissa hyvin epätodennäköistä.

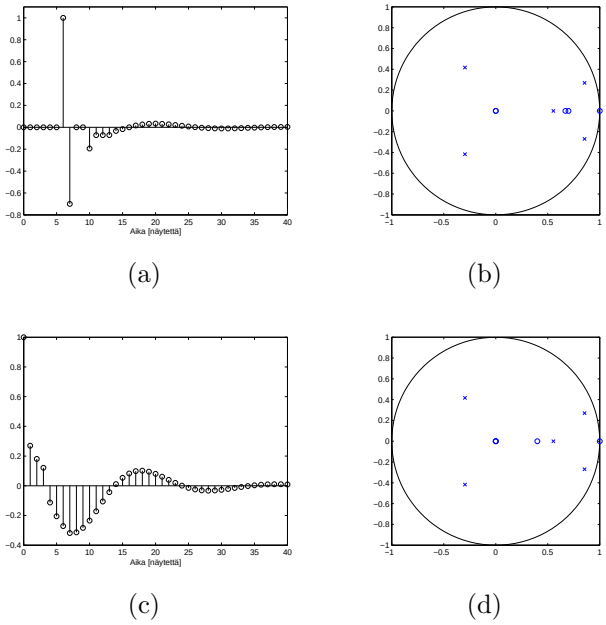

Kuva 3.5 Esimerkissä käytetyn todellisen siirtofunktioiden ominaisuuksia: (a) Siirtofunktion W_1 impulssivaste ja (b) napa-nollakohtakuvaaja sekä (c) siirtofunktion H_0 impulssivaste ja (d) napa-nollakohtakuvaaja.

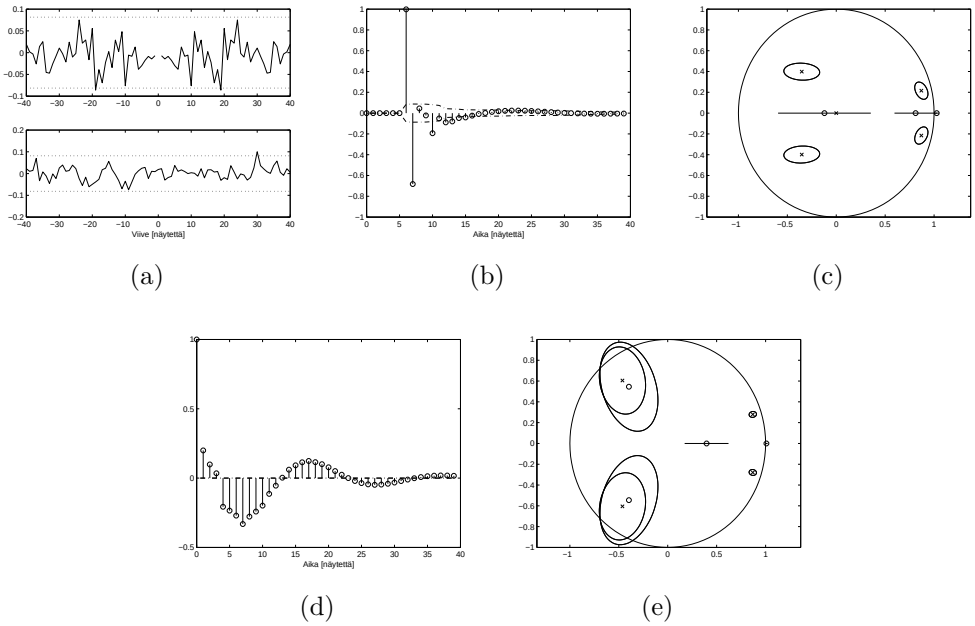

Kuva 3.6 Datan perusteella identifioidun Box-Jenkins mallin kuvaajia: (a) residuaalien autokorrelaatio ja ristikorrelaatio häiriösignaalin w_1 kanssa, (b) siirtofunktion W_1 impulssivaste, (c) siirtofunktion W_1 napa-nollakohtakuvaaja, (d) siirtofunktion H_0 impulssivaste, (e) siirtofunktion H_0 napa-nollakohtakuvaaja. Kuviin on merkitty myös 99 % luottamusvälit.

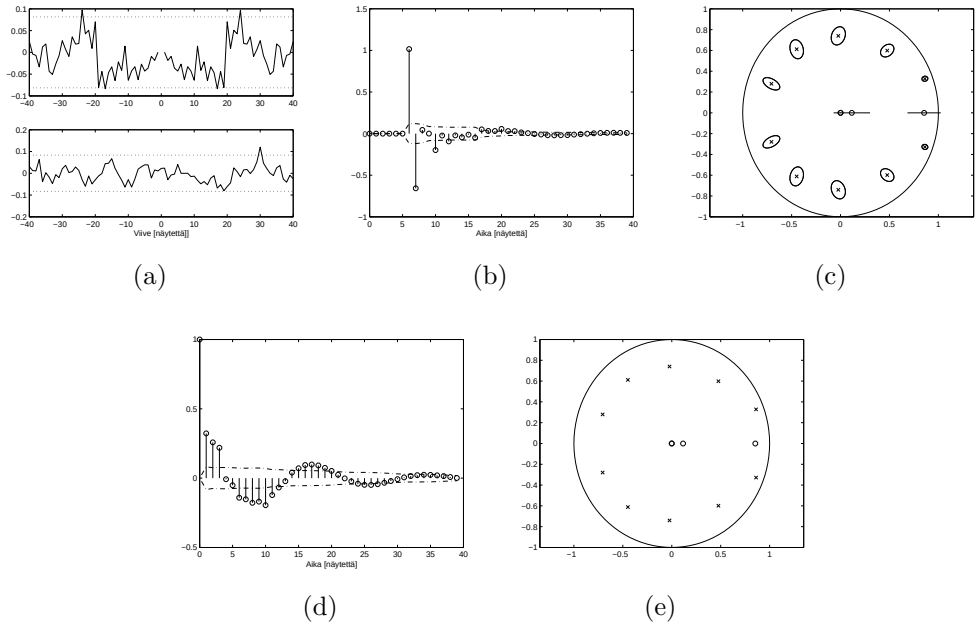

(a) (b) (c)

(d) (e)

Kuva 3.7 Datan perusteella identifioidun ARX-mallin kuvaajia: (a) residuaalien autokorrelaatio ja ristikorrelaatio häiriösignaalin w_1 kanssa, (b) siirtofunktion W_1 impulssivaste, (c) siirtofunktion W_1 napa-nollakohtakuvaaja, (d) siirtofunktion H_0 impulssivaste, (e) siirtofunktion H_0 napa-nollakohtakuvaaja. Kuvissa on esitetty myös 99% luottamusvälit.

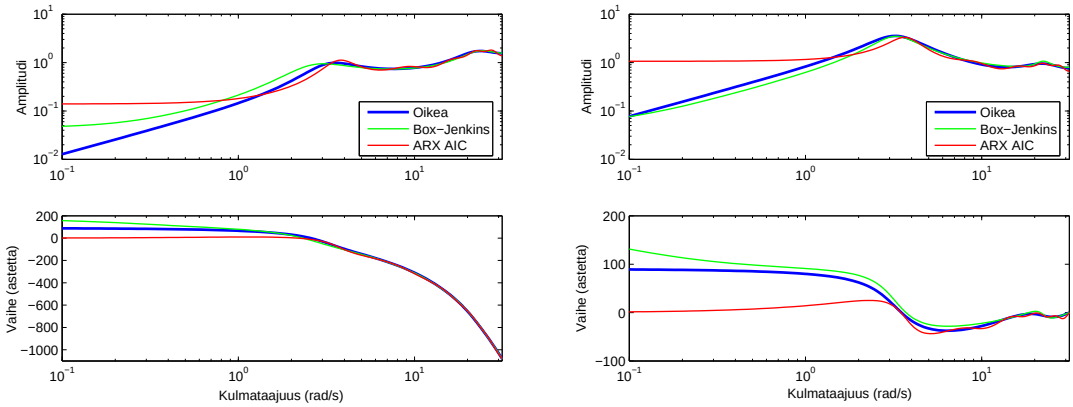

(a) (b)

Kuva 3.8 Bode-diagrammit eri menetelmillä saaduille siirtofunktioille (a) W_1 ja (b) H_0.

3.4 Tehospektri

Aikatasossa signaalin $x(n)$ keskineliöarvoa (Mean square value) $\mathrm{E}[x(n)^2]$ kutsutaan signaalin keskimääräiseksi tehoksi. Varianssi saadaan keskineliöarvon avulla muotoon

$$\sigma_x^2 = \mathrm{E}[x\,(n)^2] - \mu_x^2. \tag{3.89}$$

Näin ollen nollakeskiarvoisen signaalin varianssi on samalla sen keskimääräinen teho, jonka vuoksi sitä kutsutaankin myös signaalin AC-tehoksi [20]. Keskiarvon neliötä μ_x^2 voidaan puolestaan luonnehtia signaalin DC-tehoksi.

Signaaleja on usein hyödyllistä tarkastella aikatason lisäksi myös taajuustasossa. Tehospektri esittää signaalin sisältämän tehon taajuuden funktiona. Siitä siis selviää, onko teho keskittynyt joillekin taajuuksille vai onko se jakautunut tasaisesti kaikille taajuuksille. Tästä tiedosta voi olla hyötyä esim. säätösovelluksissa mahdollisten häiriölähteiden etsinnässä ja analysoinnissa. Tehospektri ei kuitenkaan yksin riitä todentamaan, että jokin mittaus ilmentää esimerkiksi häiriötä, ellei entuudestaan tunneta kausaalista vuorovaikutusta mitatun signaalin ja tarkasteltavan suureen välillä. Yleensä säätötekniikassa ollaan kiinnostuneita vain vaihtelevan komponentin (AC-komponentti) tehosta. Siksi tasakomponentti (DC-komponentti) yleensä hävitetään signaalista ennen jatkotoimenpiteitä vähentämällä siitä sen näytekeskiarvo.

Tarkastellaan seuraavaksi, miten tehospektri suhtautuu varianssiin ja autokovarianssiin. Diskreetin signaalin $x(n)$ tehospektri voidaan määritellä autokovarianssin $\gamma_{xx}(k)$ Fourier-muunnoksena

$$\Gamma_{xx}(\omega) = \mathcal{F}\left\{\gamma_{xx}(k)\right\}. \tag{3.90}$$

Ajatellaan autokovarianssia $\gamma_{xx}(k)$ diskreettiaikaisena äärellisen energian signaalina. Diskreettiaikaisuus tarkoittaa sitä, että signaali on määritelty vain yksittäisinä ajan hetkinä k. Signaalin äärellinen energia puolestaan tarkoittaa käytännössä sitä, että signaali vaimenee k:n kasvaessa kohti ääretöntä.

Energialtaan äärellisen jaksottoman diskreetin signaalin $s(n)$ Fourier-muunnospari määritellään [21, s. 256]

$$\mathcal{F}\{s(n)\} = S(\omega) = \sum_{n=-\infty}^{\infty} s(n)e^{-j\omega n}, \tag{3.91}$$

$$\mathcal{F}^{-1}\{S(\omega)\} = s(n) = \frac{1}{2\pi}\int_{-\pi}^{\pi} S(\omega)e^{j\omega n}d\omega. \tag{3.92}$$

missä ω on diskreetti kulmataajuus väliltä $[-\pi,\pi]$ ja $j = \sqrt{-1}$ on imaginääriyksikkö. Merkintä $\mathcal{F}\{s(n)\}$ tarkoittaa signaalin $s(n)$ Fourier-muunnosta taajuustasoon ja $\mathcal{F}^{-1}\{S(\omega)\}$ taajuustason esityksen $S(\omega)$ muunnosta takaisin aikatasoon.

Palataan takaisin tehospektrin laskentaan. Aiemmin tarkastelemamme aikatason signaalin $x(n)$ autokovarianssin $\gamma_{xx}(k)$ Fourier-muunnos on siis yhtälön (3.91) mukaan

$$\Gamma_{xx}(\omega) = \sum_{k=-\infty}^{\infty} \gamma_{xx}(k)e^{-j\omega k} \tag{3.93}$$

ja tämän käänteismuunnos on yhtälön (3.92) mukaan autokovarianssifunktio

$$\gamma_{xx}(k) = \frac{1}{2\pi}\int_{-\pi}^{\pi} \Gamma_{xx}(\omega)e^{j\omega k}d\omega. \tag{3.94}$$

Autokovarianssilla on seuraava ominaisuus:

$$\gamma_{xx}(0) = \sigma_x^2. \tag{3.95}$$

Sijoittamalla tämä yhtälöön (3.94) nähdään varianssin ja tehospektrin yhteys:

$$\sigma_x^2 = \frac{1}{2\pi}\int_{-\pi}^{\pi} \Gamma(\omega)d\omega. \tag{3.96}$$

Tehospektrin pinta-ala on siis verrannollinen signaalin varianssiin. Jos tehospektri määritellään autokovarianssin Fourier-muunnoksena, niin signaalista ei tarvitse erikseen vähentää keskiarvoa ennen tehospektrin laskentaa, koska tämä tehdään jo autokovarianssia laskettaessa. Tehospektri voidaan määritellä myös muilla tavoilla.

Joissain lähteissä tehospektri on määritelty autokorrelaation

$$a_{xx}(k) = E[x(n)x(n+k)] \tag{3.97}$$

avulla. Tällaisen määritelmän ongelma on, että Fourier-muunnosta ei ole olemassa, ellei signaalin $x(n)$ keskiarvo ole nolla. Tämä johtuu siitä, että signaalin energia

$$E_x = \sum_{n=-\infty}^{\infty} |x(n)|^2 \tag{3.98}$$

ei ole äärellinen [26].

3.4.1 Tehospektrin estimointi

Tehospektrin estimoinnissa perusongelma on se, että käytettävissä on vain äärellisen pituinen näytesekvenssi. Tällöin autokovarianssi joudutaan estimoimaan ja siten myös tehospektristä tulee tilastollinen estimaatti. Jos autokovarianssin estimaattina käytetään biasoitua estimaattia (3.33), niin tämän Fourier-muunnosta kutsutaan periodogrammiksi $P_{xx}(\omega)$ [26]. Periodogrammin ongelma on kuitenkin se, että se ei ole tehospektrin $\Gamma_{xx}(\omega)$ konsistentti estimaatti. Tämä tarkoittaa sitä, että estimaatin varianssi ei lähesty nollaa näytemäärän lähestyessä ääretöntä. Tästä johtuen tehospektrin estimointiin on kehitelty muitakin menetelmiä. Menetelmät voidaan jakaa karkeasti epäparametrisiin ja parametrisiin menetelmiin. Pääasiallisena erona näillä on se, että epäparametriset menetelmät eivät tee mitään oletusta siitä, minkälainen prosessi on generoinut tarkasteltavan näytesekvenssin. Parametrisissa menetelmissä näytejoukkoon sovitetaan jokin kappaleessa 3.2.1 esitellyistä malleista ja tehospektri estimoidaan sen avulla. Lisäksi on joitain menetelmiä, joita ei voida lukea edellisiin kategorioihin, kuten Caponin minimivarianssimenetelmä (ei liity mitenkään minimivarianssisäätöön) ja korrelaatiomatriisin ominaisarvojen ja -vektoreiden analysointiin perustuvat menetelmät. Viimeiseksi mainituilla menetelmillä tutkitaan valkoiseen kohinaan sekoittunutta äärellistä sinikomponenttijoukkoa. Siksi niitä kutsutaan joskus taajuuden estimointimenetelmiksi [26]. Tarkastellaan seuraavaksi hieman parametrisia ja epäparametrisia tehospektrin estimointimenetelmiä.

Epäparametrinen tehospektrin estimointi

Periodogrammin lisäksi muita epäparametrisia tehospektrin estimointimenetelmiä ovat Bartlett-, Welch- ja Blackman-Tukey menetelmät. Yhteistä näille menetelmille on se, että niillä pyritään pienentämään spektriestimaatin varianssia taajuusresoluution kustannuksella. Taajuusresoluutiolla tarkoitetaan pienintä kahden sinikomponentin välistä taajuuseroa $\Delta\omega$, jolla ne voidaan erottaa erillisiksi taajuuskomponenteiksi tehospektrissä. Estimaattien hyvyyttä voidaan kuvata suureilla nimeltä *muuttuvuus* (variability)

$$\nu = \frac{\operatorname{var}\left[P_{xx}(\omega)\right]}{\left\{E\left[P_{xx}(\omega)\right]\right\}^2}, \tag{3.99}$$

joka on estimaatin teholla normalisoitu varianssi ja *arvoluku* (figure of merit)

$$\varpi = \nu\Delta\omega. \tag{3.100}$$

Näin ollen arvoluku kuvaa estimointimenetelmän hyvyyttä varianssin ja taajuusresoluution suhteen. Mitä pienempi ϖ on, sitä parempi menetelmä periaatteessa on, koska estimaatilta haluttuja ominaisuuksia ovat pieni varianssi ja pieni resoluutio. Näillä suureilla mitattuna paras epäparametrinen menetelmä on Blackman-Tukey [26]. Tilanne ei tosin välttämättä ole aivan näin yksioikoinen, koska esimerkiksi Welchin ja Blackman-Tukey menetelmissä käytetään ikkunafunktioita datan tasoittamiseen ja estimaattien varianssit riippuvat käytetystä ikkunafunktiosta. Lisäksi varianssien johtamisessa on tehty joitakin oletuksia, jotka eivät välttämättä aina päde. Joka tapauksessa olennaista on se, että Bartlett-, Welch- ja Blackman-Tukey menetelmät antavat konsistentin estimaatin, eli niiden varianssi pienenee näytemäärän kasvaessa.

Blackman-Tukey menetelmässä ideana on ikkunoida autokovarianssiestimaattia ennen tehospektrin laskentaa. Näin tehdään siksi, että autokovarianssiestimaatti $r_{xx}(k)$ tulee sitä epäluotettavammaksi mitä suurempi k on. Ikkunafunktiolla pyritään siis painottamaan lähellä nollaviivettä olevia arvoja. Tehospektrin estimaatti lasketaan[26]

$$P_{xx}^{\mathrm{BT}}(\omega) = \sum_{k=-(M-1)}^{M-1} r_{xx}(k)w(k)e^{-j\omega k}, \tag{3.101}$$

missä M on autokovarianssista huomioon otettavien näytteiden määrä ja $w(k)$ on ikkunafunktio, jonka tulee täyttää seuraavat ehdot:

1. $0 \leq w(k) \leq w(0) = 1$
2. $w(-k) = w(k)$
3. $w(k) = 0, \qquad |k| > M - 1$

Mikäli ehdot eivät täyty, niin tehospektriestimaattiin saattaa tulla negatiivisia arvoja joillakin taajuuksilla. Estimaatin varianssin kannalta M tulisi olla mahdollisimman pieni. Tällöin kuitenkin taajuusresoluutio huononee. Erään suosituksen mukaan M tulisi olla maksimissaan $N/5$ suuruinen. [26]

Parametrinen tehospektrin estimointi

Parametriset menetelmät perustuvat ajatukseen, että tarkasteltava signaali on syntynyt lineaarisesta prosessista, jonka heräte on valkoista kohinaa. Prosessin mallina käytetään siirtofunktiota, josta käytetään tässä yhteydessä merkintää $H(z)$. Kun tällaista lineaarista aikainvarianttia (LTI) järjestelmää syötetään valkoisella kohinalla $v(n)$, niin lähtösignaalin $x(n)$ tehospektri on

$$\Gamma_{xx}(\omega) = |H(\omega)|^2 \, \Gamma_{vv}(\omega), \tag{3.102}$$

missä $\Gamma_{vv}(\omega)$ on tulosignaalin tehospektri ja $H(\omega)$ on järjestelmän taajuusvaste. Jos tulosignaali on valkoista kohinaa, niin yhtälö yksinkertaistuu muotoon

$$\Gamma_{xx}(\omega) = |H(\omega)|^2 \, \sigma_v^2. \tag{3.103}$$

Ensimmäiseksi dataan on siis sovitettava jokin sopiva malli, jolloin saadaan siirtofunktio $H(z)$. Tehospektri saadaan edellisen yhtälön perusteella siirtofunktion $H(z)$ taajuusvasteen avulla. Taajuusvaste voidaan laskea siirtofunktiosta sijoittamalla $z = e^{j\omega}$. [21]

Minimivarianssia estimoitaessa piti identifioida prosessin suljetun systeemin siirtofunktio häiriöstä v säädettävään suureeseen y. Kun muistetaan vielä, että suljetun systeemin siirtofunktio ja prosessin kokonaisvarianssi voitiin hajottaa toisistaan riippumattomiin osiin yhtälöiden (3.6) ja (3.10) mukaisesti, niin minimivarianssisäädön tehospektri voidaan laskea tämän perusteella

$$\begin{aligned} P_{yy}^{\mathrm{mv}}(\omega) &= \left| H_{\mathrm{mv}}(z^{-1}) \right|_{z=e^{j\omega}}^2 \sigma_v^2 = \left| \sum_{k=0}^{d_{\mathrm{p}}-1} h_{\mathrm{mv}}(k) e^{-j\omega k} \right|^2 \sigma_v^2 \\ &= \left| h_{\mathrm{mv}}(0) + h_{\mathrm{mv}}(1) e^{-j\omega} + ... + h_{\mathrm{mv}}(k-1) e^{-j(d_{\mathrm{p}}-1)\omega} \right|^2 \sigma_v^2. \end{aligned} \tag{3.104}$$

Vastaavasti nykyisen säädön tuottama tehospektri saadaan korvaamalla edellisessä summauksen yläraja $d_{\mathrm{p}} - 1$ äärettömällä. Käytännössä ylärajaksi valitaan jokin tarpeeksi suuri luku, jolla impulssivaste on vaimentunut olemattomiin. Minimivarianssispektriä ja nykyisen säädön spektriä vertaamalla nähdään, millä taajuusalueella suurimmat ongelmat ovat ja miten säätöä tulisi virittää, jotta päästäisiin lähemmäs minimivarianssia [18]. Esimerkiksi matalilla taajuuksilla oleva selkeä piikki voi merkitä, että säädin on viritetty liian hitaaksi. Tämä voidaan korjata esim. kasvattamalla säätimen vahvistusta. Keskitaajuuksilla oleva piikki voi puolestaan kertoa liian suuresta vahvistuksesta.

Tarkastellaan spektrin estimointia esimerkin avulla. Otetaan sama prosessi kuin kappaleen 3.3.2 lopussa esitettiin. Yksinkertaistetaan tätä kuitenkin siten, että jätetään mitattu häiriö w_1 nyt pois. Systeemin lohkokaavio on siis kuvan 3.9 mukainen. Lähtösuureen impulssivaste on tässä tapauksessa sama kuin kuvassa 3.5c. Minimivarianssispektri saadaan laskettua ottamalla huomioon em. impulssivasteesta vain neljä ensimmäistä termiä ja merkitsemällä loput nolliksi.

Prosessista simuloitiin datapisteitä 1000 kappaletta. Kuvissa 3.10a-c on esitetty prosessin lähtösuureen tehospektri ja minimivarianssispektri todellisesta mallista laskettuna, AIC-kriteerillä valitusta AR-mallista laskettuna ja ARMA(4,4) mallista laskettuna. Kuvassa 3.10d on Bartlett-ikkunoidun Blackman-Tukey tehospektriestimaatti autokorrelaatioikkunan pituudella $M = 35$. Kuvissa taajuusakselilla on diskreetti

taajuus, jonka yläraja on Nyquistin taajuus $F_{\mathrm{N}} = \frac{F_{\mathrm{S}}}{2}$, missä F_{S} on näytteenottotaajuus. Blackman-Tukey estimaatti on tasoltaan alempana kuin parametriset estimaatit, koska laskennassa ei oteta huomioon ikkunafunktion aiheuttamaa tehonalenemaa. Olennaisempaa on kuitenkin spektriestimaatin muoto. Spektrivertailuista havaitaan, että säätö aiheuttaa tehopiikin taajuusalueelle $0{,}03F_{\mathrm{S}} - 0{,}1F_{\mathrm{S}}$.

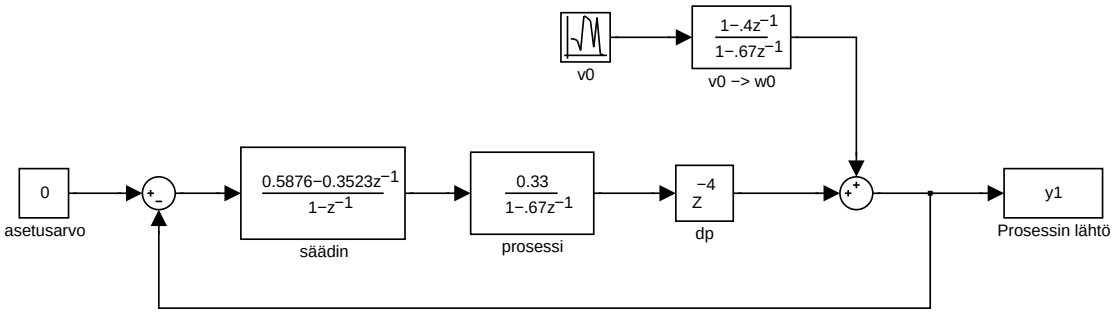

Kuva 3.9 Esimerkkinä käytetyn systeemin lohkokaavio.

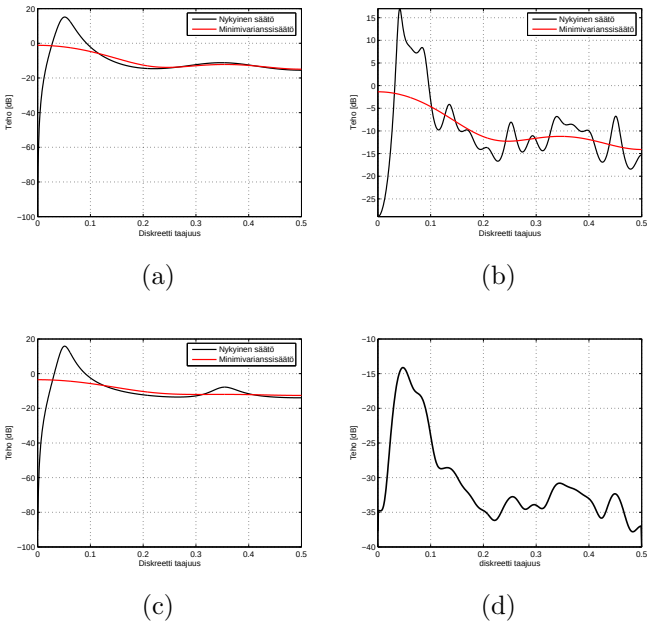

Kuva 3.10 Säädön tehospektrin vertailu minimivarianssispektriin. Kuvassa (a) on siirtofunktioista lasketut spektrit, kuvassa (b) on AIC-kriteerillä valitun AR-mallin perustella estimoidut spektrit, kuvassa (c) on ARMA(4,4) mallin spektriestimaatit ja kuvassa (d) on epäparametrisella Blackman-Tukey menetelmällä (M=35, N=1000) saatu spektriestimaatti prosessin lähtösuureesta.

4 KEITTIMEN SÄÄTÖJEN ANALYSOINTI

Työn ensisijainen tavoite oli selvittää, pystytäänkö kappaluvun vaihtelua vähentämään säädön avulla. Kapan säätö esiteltiin kappaleessa 2.8 ja lohkokaaviona kuvassa 2.7. Prosessia säädetään SISO-systeeminä, joten tarkastellaan aluksi kuinka varianssin kannalta optimaalisesti viritetty takaisinkytketty säätö kykenisi vaimentamaan häiriöt tarkasteltavina ajanjaksoina.

4.1 Tiedonkeruu

Analysointia varten kerättiin dataa prosessin toimiessa normaalissa tuotannossa. Data kerättiin automaatiojärjestelmän Honeywell Infocenter (HIC) prosessitietokannasta Excel-tiedostoihin järjestelmän Trends-työkalulla. HIC:stä saatava data sisälsi näytearvojen lisäksi näytteiden aikaleimat. Varsinainen analyysi tehtiin Matlabilla, joten data piti saada ensin sen ymmärtämään muotoon. Tätä varten tehtiin työkalu Matlabin Graphical User Interface Development Environment (GUIDE) -ympäristöllä, jolla on suhteellisen helppo tehdä graafisia käyttöliittymiä Matlab-funktioille. Työkalun tarkoitus oli helpottaa signaalien siirtoa ja esikäsittelyä, koska käsiteltävien signaalien määrä oli kohtalaisen suuri. Esikäsittelyssä signaaleja oli mahdollista tarkastella aikatasossa ja rajata niistä halutut ajanjaksot tarkempaa analyysia varten parilla napin painalluksella.

HIC:stä saatava data on aina keskiarvotettua. Keskiarvoja tallennetaan seuraavilla näyteväliajoilla: yksi minuutti, 10 minuuttia, 60 minuuttia ja 24 tuntia. Datan keskiarvottaminen tapahtuu siten, että automaatiojärjestelmä kerää dataa edellisiä lyhyemmällä näytevälillä ja laskee keskiarvon kunkin näytevälin aikana saamistaan näytteistä. Periaatteessa on hyvä, että näin tehdään, etteivät nopeammin näytteistetyssä signaalissa mahdollisesti olevat korkeataajuiset komponentit laskostu hitaammin näytteistettyihin ja tallennettaviin signaaleihin. Keskiarvottaminen rajoittaa siis signaalin taajuuskaistaa vaimentaen korkeita taajuuksia eli se on alipäästösuodatin. Samalla tietenkin signaalin varianssi pienenee, koska nopeataajuiset ilmiöt

vaimenevat. Tämän vuoksi kutakin signaalia käsiteltäessä on kiinnitettävä huomiota siihen, millä taajuusalueella pääosa värähtelyistä esiintyy.

Tiedonkeruujärjestelmässä on myös sellainen ikävä piirre, että toisinaan signaaleista jää puuttumaan joitakin näytearvoja. Käytännössä tätä ei ole ilmennyt tuntikeskiarvoissa, mutta lyhyemmillä näyteväliajoilla ongelma on varsin yleinen. Tästä aiheutuu ylimääräistä päänvaivaa signaalia käsiteltäessä, koska signaalista ei periaatteessa voida laskea esimerkiksi autokorrelaatiota puuttuvien näytteiden läheisyydessä. Tämä johtuu siitä, että puuttuvat näytteet muuttavat signaalin ajallista riippuvuutta edellisistä arvoistaan, jota autokorrelaatio siis mittaa. Puuttuvien näytteiden vaikutusta voidaan vähentää korvaamalla ne esim. interpoloiduilla arvoilla. Matlabin System Identification Toolbox:ssa on funktio *misdata*, jolla voidaan estimoida puuttuvat arvot. Näytteet estimoidaan minimoimalla rekonstruoidun signaalin ennustusvirheet [27]. Käytännössä operaatio tehdään siten, että korvataan signaalivektorissa puuttuvat näytearvot NaN-arvolla. Tämän jälkeen datasta tehdään iddata-objekti, joka on funktion käyttämä datamuoto. Paluuarvona saadaan vastaavanlainen iddata-objekti, joka sisältää puuttuvilla arvoilla korjatun vektorin.

Kappaleessa 2.8 käsiteltiin hieman myös kappa-analysaattoria. Siinä todettiin, että analysaattoreilta saatavien näytteiden näyteväli vaihtelee huomattavasti. Tämä ominaisuus on ongelmallinen säätöjärjestelmän analyysin kannalta, koska tässä työssä esiteltyjen menetelmien käyttö edellyttää, että signaalit on näytteistetty tasavälein.

HIC:n toiminta ei myöskään ole mitenkään synkronoitu kappa-analysaattorin näytteistykseen, vaan se kerää näytteitä analysaattorilta omaa tahtiaan. Näin todellisia näytehetkiäkään ei tunneta tarkasti. Minuutin keskiarvodatasta saadaan kuitenkin jo melko tarkka käsitys todellisista näytehetkistä. Minuutin keskiarvo pysyy muuttumattomana tai ainakin lähes muuttumattomana todellisten analysaattorilta saatujen näytteiden välillä, koska analysaattori ei ole tuottanut uutta dataa tänä aikana. Tämän perusteella todellisiksi näytteiksi voidaan poimia muutoshetkien arvot ja niitä vastaavat aikaleimat. Todellisten näytteiden välillä kulunut aika voidaan laskea aikaleimojen avulla. Kuvassa 4.1 on kappa-analysaattorin näytevälejä eräältä ajanjaksolta edellä kuvatulla menetelmällä laskettuna. Asiaa havainnollistaa lisäk-

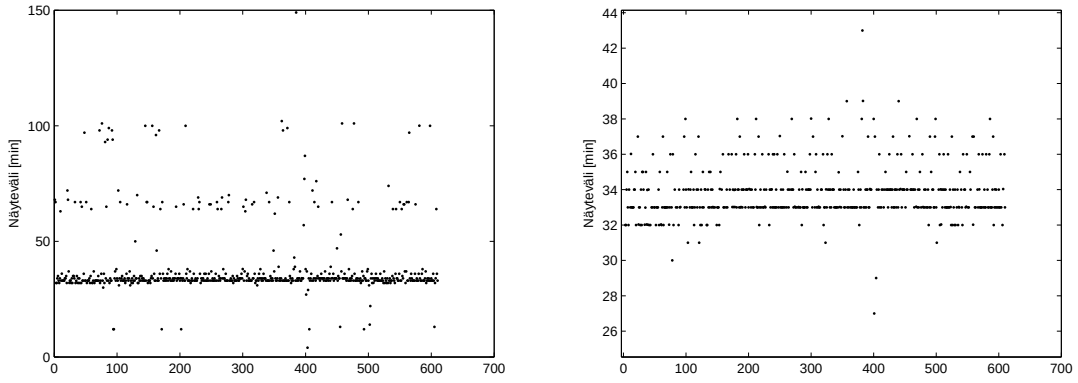

(a) (b)

Kuva 4.1 Kapan näyteväliaikoja aikaväliltä 29.7. - 15.8. 2005. Kuvassa (a) kaikki ajanjakson näytevälit ja kuvassa (b) tarkennus aikavälille 25 - 44 minuuttia, jolla suurin osa näytteistä näyteväleistä näyttää olevan.

si kuva 4.2, jossa on esitetty normalisoidut histogrammit samoista näyteväliajoista. Normalisointi on tehty siten, että kunkin luokitteluvälin näytemäärä on suhteutettu kokonaisnäytemäärään, jolloin palkin korkeudesta nähdään suoraan kyseisellä välillä olevien näytteiden osuus kokonaismäärästä. Kuvista nähdään, että yli 80 % näyteväliajoista on välillä 20–40 minuuttia. Tarkempi tarkastelu osoittaa vielä, että noin 82 % näyteväleistä on välillä 30–40 minuuttia.

Koska näyteväliajat vaihtelevat huomattavasti, niin näitä näytteitä ei voida käyttää sellaisenaan. Yksi vaihtoehto on valita haluttu näyteväliaika, muodostaa tasavälinen näytehetkien vektori ja interpoloida näytteet näinä ajanhetkinä todellisten näytteiden avulla. Mikäli alku- ja loppuhetket halutaan asettaa samoiksi interpoloidussa ja todellisessa näytevektorissa, niin näyteväliajaksi on valittava todellisten näytevälien keskiarvo. Toinen vaihtoehto on käyttää suoraan HIC:n tarjoamia hitaampia keskiarvoja. Kuvaan 4.3 on piirretty edellä tarkastellun aikavälin todelliset näytteet, keskimääräiselle tasaiselle näytevälille (n. 39,6 min) interpoloidut näytteet sekä HIC:n tunnin keskiarvot. Kuvan perusteella voidaan todeta, että hitaat vaihtelut näkyvät tunnin keskiarvodatasta yhtä hyvin kuin interpoloidustakin datasta. Tätä ominaisuutta pyrkii havainnollistamaan myös kuva 4.4, johon on piirretty interpoloidun- ja HIC:n 60 minuutin keskiarvodatan Hamming-ikkunoidut Blackman-Tukey tehos-

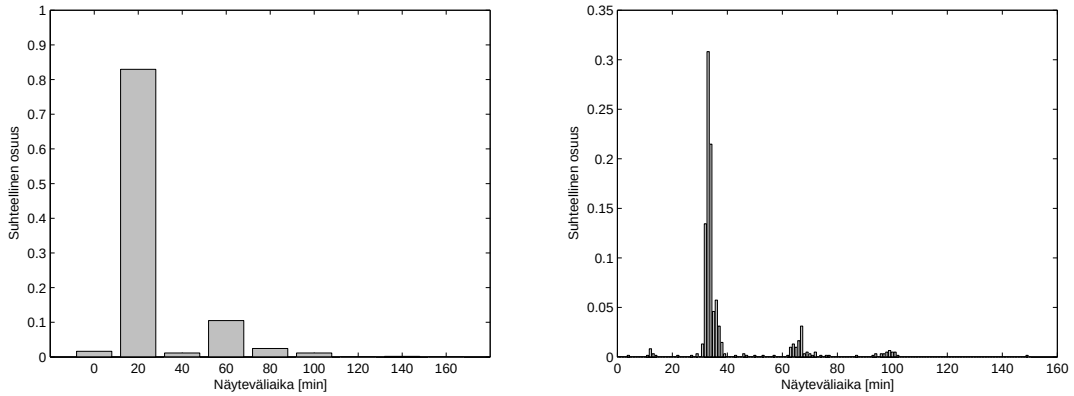

(a) (b)

Kuva 4.2 Näytemäärän perusteella normalisoidut histogrammit. Kuvassa (a) palkin leveys on 20 minuuttia ja kuvassa (b) 1 minuutti. Palkit on piirretty tarkastelurajojen alarajojen kohdalle.

pektriestimaatit. Kuvasta nähdään, että matalilla taajuuksilla tehospektrit ovat hyvin lähellä toisiaan mutta suuremmilla taajuuksilla eroja esiintyy hieman enemmän.

4.2 Takaisinkytketty kappaluvun säätö

Kappaluvun säädön suorituskykyä analysoitiin aluksi HIC:stä saatavan tuntikeskiarvodatan perusteella. Analyysidataksi valittiin 29.7. – 23.9. välinen aika. Tämä aikaväli jaettiin noin kahden viikon mittaisiin tarkastelujaksoihin. Tarkastelujaksojen kappaluku-näytteiden tiedot ja tilastollisten perussuureiden (odotusarvo ja keskihajonta) estimaatit 95 % luottamusväleineen on koottu taulukkoon 4.1. Kuvaan 4.5 on lisäksi piirretty kappaluku, kappaluvun ohjausmuuttuja (keittimen höyrytilan lämpötila) ja tuotantonopeus aikatasossa eri ajanjaksoina.

Ensimmäinen tehtävä oli selvittää kappaluvun säädön suorituskyky. Minimivarianssianalyysiä hankaloittaa kuitenkin hieman se, että systeemin viivettä ei tiedetä tarkasti ja se vaihtelee tuotantonopeuden funktiona. Lisähankaluuksia tuo myös kappaanalysaattorin viive, joka voi ajoittain kasvaa moninkertaiseksi normaaliin verrattuna. Joka tapauksessa viive ohjaussuureesta eli keittimen höyrytilan lämpötilasta kappalukuun, joka mitataan puskulinjasta keittimen jälkeen, on useita tunteja.

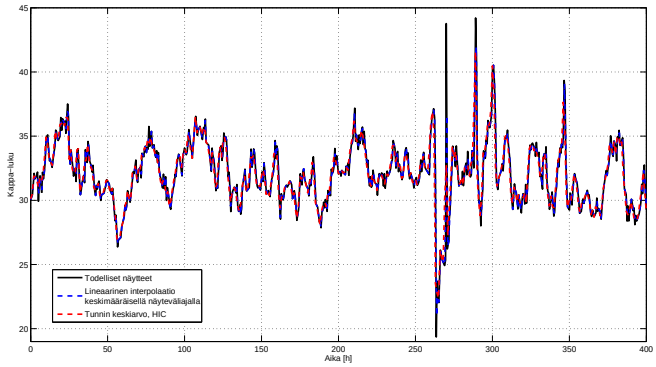

(a)

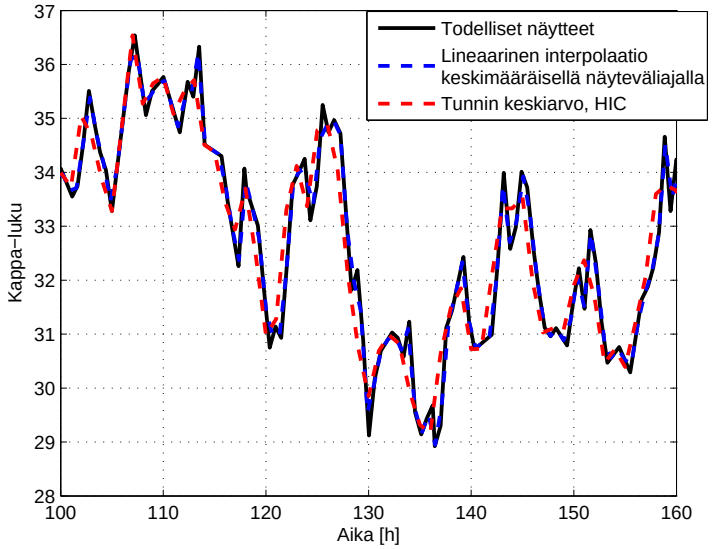

(b)

Kuva 4.3 Eri tavoilla käsiteltyjen kappalukunäytteiden vertailu aikatasossa. Kuva (b) on tarkennus kuvasta (a) lyhyemmälle ajanjaksolle, jotta erot näkyisivät paremmin.

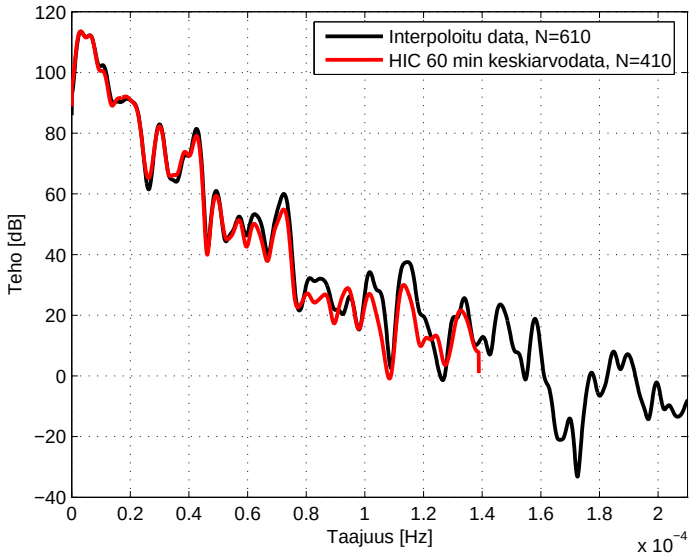

Kuva 4.4 Keskimääräisellä näytevälillä interpoloitujen ja tuntikeskiarvotettujen kappaluku-näytteiden Blackman-Tukey tehospektriestimaatit. Hamming ikkunointi, taajuuspisteitä 4096, autokovarianssin pituus $M = N/5$. Huomaa, että datoilla on eri näytevälit, joten ne pystyvät esittämään eri taajuuskaistan. Ylärajataajuutena kuvassa interpoloidun datan Nyquist-taajuus $210{,}6 \cdot 10^{-6}$ Hz.

Tarkastellaan keittimen höyrytilan lämpötilan ja kappaluvun välistä suljetun systeemin impulssivastetta, joka on esitetty liitteen 1 sivulla 8 (signaali 34, kuva b). Kuvasta nähdään, että höyrytilan lämpötila osoittaa merkittävää negatiivista korrelaatiota eri ajanjaksoilla hieman eri viiveiden jälkeen. Negatiivinen korrelaatio tarkoittaa sitä, että höyrytilan lämpötilan kasvaessa kappaluku laskee, mikä on sinänsä järkevä tulos. Keittimen höyrytilan lämpötila näyttää kuitenkin olevan hyvin epästationaarinen, joten on parempi tarkastella signaalin 34 kuvaa d. Tästä ei kuitenkaan voida nähdä juuri muuta kuin takaisinkytkennän vaikutus, joka näkyy viiveillä $k \leq 0$. Parempi arvio keittimen viipymäajasta saadaan keittimen hakepinnankorkeuden ja kappaluvun välisen suljetun systeemin impulssivasteen avulla. Impulssivasteen pitäisi olla nollasta poikkeava viiveen jälkeen. Liitteen 1 sivulla 5 on esitetty keittimen hakepinnan ja kappaluvun välinen suljetun systeemin impulssivaste kolmella ajanjaksolla (signaali 20, kuva b). Kuvan perusteella viive on luokkaa 3–6 näytettä eli ajassa ilmaistuna 3–6 tuntia.

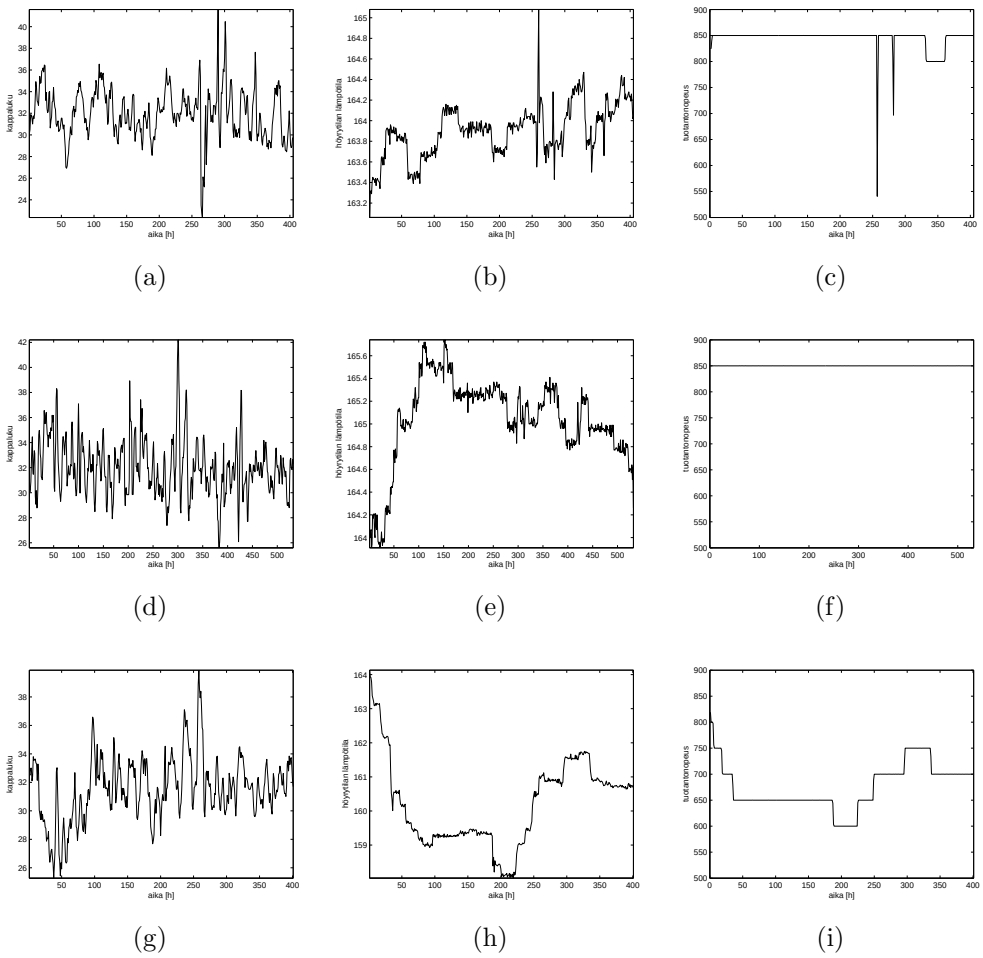

Kuva 4.5 Vasemmassa sarakkeessa on kappaluku ja oikeassa tuotantonopeus taulukon 4.1 tarkasteluajanjaksoina siten, että 1. ajanjakso on ylimpänä, 2. keskimmäisenä ja 3. alimmaisena.

Taulukko 4.1 Takaisinkytketyn kappaluvun säädön arvioinnissa käytetyn mittausdatan tarkastelujaksojen tiedot. Keskiarvon ja keskihajonnan 95 % luottamusvälit on laskettu Matlab-funktiolla *normfit*, joka olettaa datan olevan normaalijakautunutta.

Jakso	Aikaväli	N	$\hat{\mu}$	$\hat{\sigma}$	$\hat{\sigma}$ luottamusväli	$\hat{\sigma}^2$
1	29.7. 16:00 - 15.8. 12:00	405	32,00±0,23	2,32	$2{,}17 < \sigma < 2{,}49$	5,39
2	15.8. 13:00 - 6.9. 16:00	532	32,03±0,19	2,26	$2{,}13 < \sigma < 2{,}40$	5,10
3	6.9. 17:00 - 23.9. 9:00	401	31,58±0,22	2,25	$2{,}11 < \sigma < 2{,}42$	5,07

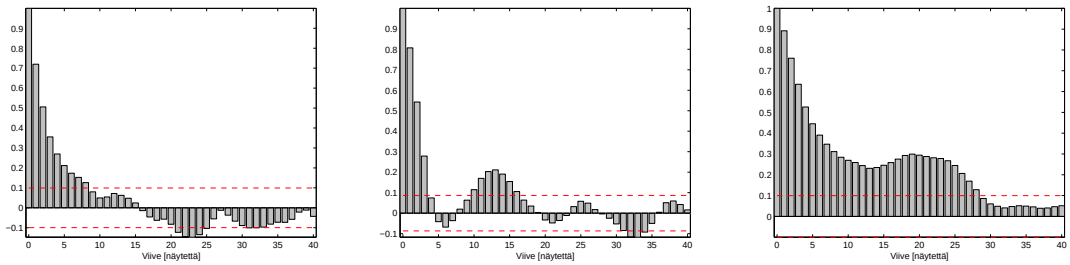

(a) (b) (c)

Kuva 4.6 Kappalukusignaalien autokorrelaatiot 95 % luottamusväleineen eri ajanjaksoilta. Luottamusvälien laskennassa on käytetty yhtälöä (3.37).

Ensimmäinen indikaatio minimivarianssisäädöstä saadaan autokorrelaation avulla. Kuvaan 4.6 on piirretty taulukossa 4.1 esiteltyjen jaksojen autokorrelaatiot. Koska viive kuitenkin vaihtelee, niin mitään kovin täsmällistä näistä kuvista ei voida sanoa. Tarkastellaan autokorrelaatioita viiveellä $d_\mathrm{p} = 5$. Jaksoilla 1 ja 2 autokorrelaatio näyttää vaimenevan varsin nopeasti em. oletuksella. Tosin jaksolla 2 saattaa olla lievää oskillaatiota, joka ilmenee autokorrelaation jaksollisena värähtelynä. Jaksolla 3 sen sijaan näyttää olevan merkittävää autokorrelaatiota vielä vuorokauden jälkeenkin. Se indikoi, että säätö ei kykene kompensoimaan häiriöitä tällä ajanjaksolla erityisen hyvin. Tämä johtunee jaksolla 3 olevista tuotantonopeuden muutoksista.

Tarkastellaan seuraavaksi kappaluvun säätöä tarkemmin identifioimalla kullekin ajanjaksolle AR-aikasarjamalli ja estimoidaan sen impulssivasteen perusteella minimivarianssi. Mallit identifioitiin Matlabin System Identification Toolboxilla ja niiden kertaluvut valittiin AIC-kriteerin perusteella. Mallien sovitusta voidaan tarkastella kuvassa 4.7 olevien residuaalien autokorrelaatioiden sekä testisuureen Q (yhtälö 3.43) avulla. Malleista laskettiin impulssivasteet Matlabin *impulse* funktiolla ja niiden

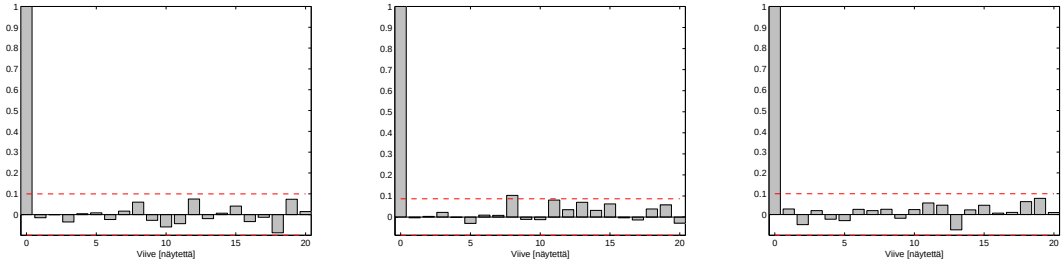

(a) (b) (c)

Kuva 4.7 Kappalukusignaaleista tehtyjen mallien residuaalien autokorrelaatiot 95% luottamusväleineen.

Taulukko 4.2 Identifioitujen suljetun systeemin AR-mallien ominaisuuksia ja niiden perusteella laskettuja kappaluvun säädön ominaisuuksia:$\hat{\sigma}_y^2$ - mallin perusteella laskettu kappaluvun varianssi, $\hat{\sigma}_{\mathrm{mv}}^2$ - kappaluvun minimivarianssi, $\hat{\sigma}_v^2$- herätteenä toimivan valkoisen kohinan varianssin estimaatti (residuaalien varianssi), $\hat{\eta}(5)$ - suorituskykyindeksi viiveen arvolla $d_{\mathrm{p}} = 5$ laskettuna. Q:n alaindeksi ilmaisee laskennassa käytettyjen residuaalien autokorrelaatiotermien lukumäärän. Viimeinen sarake kertoo kriittisen arvon, johon Q:ta verrataan. Jos Q on kriittistä arvoa suurempi niin H_0hylätään. Nollahypoteesina on, että residuaalit ovat valkoista kohinaa.

Jakso	$\hat{\sigma}_y^2$	$\hat{\sigma}_{\mathrm{mv}}^2$	$\hat{\sigma}_v^2$	$\hat{\eta}(5)$	Q_{20}	Testisuureen Q hylkäysraja, kun $\alpha = 0{,}05$
1	5,39	5,15	1,66	0,057	20,7	27,6
2	5,10	5,05	1,32	0,016	20,7	27,6
3	5,07	4,17	0,77	0,183	20,6	28,9

avulla määritettiin minimivarianssit ja η-indeksit. Tulokset on koottu taulukkoon 4.2. Sekä testisuureen Q että kuvassa 4.7 olevien autokorrelaatiofunktioiden perusteella residuaalit näyttävät toisistaan riippumattomilta. Tämän perusteella identifioidut aikasarjamallit mallintavat datan hyvin. Taulukon viidennessä sarakkeessa oleva η on kaikilla jaksoilla pieni. Sekin siis viittaa siihen, että kappaluvun takaisinkytketty säätö toimii lähes optimaalisesti varianssin minimoinnin kannalta. Kuvan 4.8 suljetun systeemin impulssivasteet havainnollistavat tätä seikkaa vielä lisää. Oikeastaan vain jaksolla 3 on joitakin tilastollisesti merkittäviä termejä oletetun 5 tunnin viiveen jälkeen. On kuitenkin huomioitava, että tällä jaksolla tuotantonopeus on pääosin hitaampi kahteen ensimmäiseen jaksoon verrattuna, joten viive on myös pidempi.

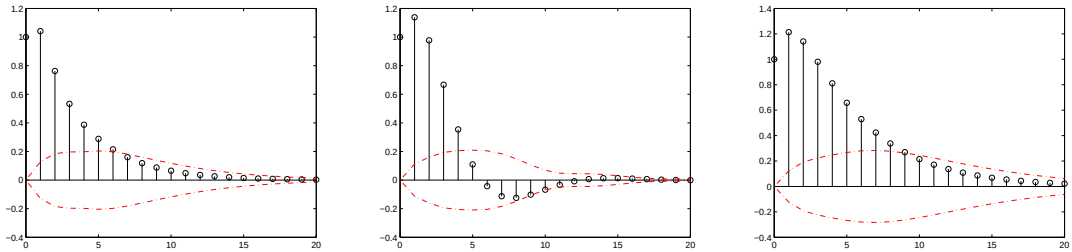

(a) (b) (c)

Kuva 4.8 Suljetun systeemin impulssivasteet tuntemattomasta häiriöstä kappalukuun.

4.3 Kappalukuun vaikuttavien häiriöiden etsintä

Koska säädön takaisinkytkentäosuus näyttää toimivan hyvin lähellä minimivariansin mukaista optimia, niin kyseistä säädintä muuttamalla tai virittämällä häiriöiden vaikutusta kappalukuun ei saada vähennettyä juurikaan tätä paremmin. Tämän vuoksi seuraavassa vaiheessa pyrittiin etsimään mitatuista signaaleista kappalukuun häiriöitä tuottavia tai niitä indikoivia suureita, jotta niitä voitaisiin kompensoida esimerkiksi myötäkytkennällä tai erillisellä takaisinkytketyllä säätöpiirillä.

Mitattujen signaalien vaikutusta kappalukuun tarkasteltiin ensin kappaleessa 3.3.1 esitellyllä normalisoidulla impulssivasteella taulukon 4.1 ajanjaksoilla. Impulssivastekuvat on koottu liitteeseen 1. Kustakin signaalista on esitetty stationaarisuuden tarkastelemiseksi aikasarja ja autokorrelaatio kullakin jaksolla. Koska osa signaaleista on selkeästi epästationaarisia, niin normalisoitu impulssivaste on estimoitu kahdella tulosignaalin differenssin kertaluvulla: nolla ja yksi. Suurin osa liitteen 1 signaaleista on kerätty suoraan HIC:stä, mutta mukana on myös muutama sellainen signaali, jotka on muodostettu muista signaaleista. Tällaisia ovat ostohakkeen osuus kokonaishakemäärästä, kokonaispuskuvirtaus ja -paisuntavirtaus. Ostohakkeen osuus kokonaishakemäärästä arvioitiin hakepurkainten pyörimisnopeuksien avulla

$$\mathrm{OHP}(n) = \frac{s_1(n) + s_3(n)}{s_1(n) + s_2(n) + s_3(n) + s_4(n)}, \tag{4.1}$$

missä $s_i, i = 1,2,3,4$ ovat hakepurkaimen i pyörimisnopeus. Purkaimet 2 ja 4 syöttävät keittämölle tehtaan itse tuottamaa haketta ja purkaimet 1 ja 3 ostettua haketta.

Kokonaispuskuvirtaus laskettiin

$$F_{\text{puv}}^{\text{tot}}(n) = F_{\text{puv}}^{1}(n) + F_{\text{puv}}^{2}(n), \tag{4.2}$$

missä F_{puv}^{1} on puskuvirtaus linjasta 1 ja F_{puv}^{2} linjasta 2. Samaan tapaan laskettiin kokonaispaisuntavirtaus

$$F_{\text{pav}}^{\text{tot}}(n) = F_{\text{pav}}^{\text{y}}(n) + F_{\text{pav}}^{\text{a}}(n), \tag{4.3}$$

missä $F_{\text{pav}}^{\text{a}}(n)$ on alapaisuntavirtaus ja $F_{\text{pav}}^{\text{y}}$ on yläpaisuntavirtaus.

Liitteen 1 kuva 61, jossa sekä tulo- että lähtösignaalina on kappaluku, havainnollistaa estimoidun impulssivasteen ominaisuuksia. Teorian mukaan tällaisen impulssivasteen pitäisi olla $\delta(k)$. Kuvasta 61b havaitaan, että estimaatti pysyy kaikilla viiveillä luottamusvälien sisällä mutta erityisen pieni se on viiveillä -10 – 10. Tämä johtuu esivalkaisusta, jossa on käytetty Matlabin *cra*-funktion oletuskertalukua 10. Kuvassa 61d on kappaluvun 1. differenssin ja kappaluvun välinen normalisoitu impulssivaste. Tällaisen impulssivasteen pitäisi olla positiivisilla viiveillä integraattorin impulssivaste, joka on askelfunktio. Estimoinnin vuoksi integraattori alkaa kuitenkin vaimentua varsin nopeasti.

Seuraavien signaalien impulssivasteissa on nähtävissä selkeitä yhdenmukaisuuksia eri ajanjaksoina (suluissa kyseisen signaalin kuvan numero liitteessä 1):

- keittimen hakepinnankorkeus (20 ja 59)
- puskuvirtaukset (21 ja 62)
- keittimen lipeäpinnankorkeus (24)
- keittimen paisuntavirtaukset (25,26 ja 63)
- puskusakeus (30 ja 42)
- puskun paine-ero (32)
- laskennallinen pesukerroin (27)

- keittimen pohjakaavarin hydrauliikan paine (33)
- lasketut H-tekijät (38, 39 ja 40)
- jäännösalkalipitoisuudet (44, 45 ja 48)
- haihduttamolle menevän mustalipeän kuiva-ainepitoisuus (47)
- paisuntalipeän lämpötilat (50 ja 51)
- pesulipeävirtaus vuopesurilta (56)
- keittimen kokonaispinta (60)

Tähän ei ole listattu ohjausmuuttujaa (höyrytilan lämpötila) ja siihen läheisesti liittyviä signaaleja kuten höyryvirtaus keittimeen (15) ja keittovyöhykkeen lämpötila (36), joissa ilmenee myös vuorovaikutusta kappalukuun. Tämän analyysin perusteella ei voida kuitenkaan päätellä, kuinka voimakas kunkin häiriön vaikutus on kappalukuun. Se kertoo vain, että näiden signaalien vaikutus kappalukuun näyttää olevan tilastollisesti merkittävä.

Arvioidaan seuraavaksi joidenkin edellä listattujen suureiden selittämää osuutta kappaluvun varianssista kappaleessa 3.3.2 esitetyllä menetelmällä. Olisi tietysti mielenkiintoista tuntea kaikkien listalla olevien suureiden vaikutus kappalukuun, mutta se ei käytännössä onnistu, koska useat listatut suureet ovat toisistaan riippuvia. Esimerkiksi hake- ja lipeäpinnat riippuvat selkeästi toisistaan ja siten myös niiden ohjausmuuttujat eli pusku- ja paisuntavirtaukset riippuvat toisistaan. Myös H-tekijöiden laskennassa käytetään hakepintaa hyväksi. Puskuvirtauksen vaihtelut voivat puolestaan näkyä pesukertoimessa ja puskusakeudessa, joka näkyy puolestaan keittimen pohjakaavarin hydrauliikan paineessa ja puskun paine-erossa.

Ensin tarkasteltiin hakepinnankorkeuden vaikutuksen voimakkuutta kappalukuun, koska sen tiedettiin aikaisemman tutkimuksen perusteella olevan merkittävä suure kappaluvun kannalta [5, 6, 7, 8]. Analyysi tehtiin samalle datalle kuin aiemminkin. Tulokset on koottu taulukoihin 4.3–4.6 ja kuviin 4.9–4.12. Taulukoissa on varianssihajotelmat ja kuvat pyrkivät havainnollistamaan identifioitujen mallien ominaisuuk-

sia. Kuvissa on a) mallista laskettu impulssivaste hakepinnan korkeudesta kappalukuun, b) residuaalien autokorrelaatio (ylempi) sekä residuaalien ja häiriösignaalin välinen ristikorrelaatio (alempi) ja c) hakepinnan ja kapan välisen siirtofunktion napa-nollakohtakuvaaja. Kuvissa on luottamusväleinä 99 % rajat. Residuaalien autokorrelaatioissa ei ole piirretty nollaviivettä, koska se on määritelmän mukaan yksi. Näin myös kuvat voidaan skaalata lähemmäs luottamusvälejä.

Analyysin perusteella jaksolla 1 keittimen hakepinnan aiheuttama osuus kappaluvun kokonaisvarianssista on $\frac{1{,}65}{6{,}14} = 0{,}27$ eli 27 %. Optimaalinen takaisinkytkentä poistaisi varianssista osuuden $\frac{0{,}39}{6{,}14} = 0{,}06$. Residuaalien auto- ja ristikorrelaatioiden perusteella malli näyttäisi olevan varsin hyvä vaikkakin pienillä viiveillä olevat autokorrelaatiot voivat merkitä huonoa tuntemattoman häiriön mallinnusta. Myös ristikorrelaatiossa on melko suuria arvoja viiveen 10 lähellä. Napa-nollakohta kuvaajan mukaan ylimallinnusta ei pitäisi olla, koska napojen ja nollien luottamusvälit eivät ole limittäin. Menetelmällä saatu kapan kokonaisvarianssi 6,14 on jonkin verran suurempi kuin näytevarianssi, joka on 5,39. Taulukon 4.1 luottamusvälien perusteella kapan varianssin 95 % ylärajaksi tulee tällä jaksolla 6,2 eli varianssihajotelman kokonaisvarianssi mahtuu näiden luottamusvälien sisään. Häiriösignaalien v_0 ja v_1 ristikorrelaatioksi $r_{v_0 v_1}$ tuli -0,11 ja P-arvoksi 0,025. Tuntematon häiriökomponentti siis korreloi melko suurella todennäköisyydellä hakepinnankorkeuden kanssa, mikä tarkoittaa sitä, että menetelmällä saatuja tuloksia ei voida pitää täysin luotettavina.

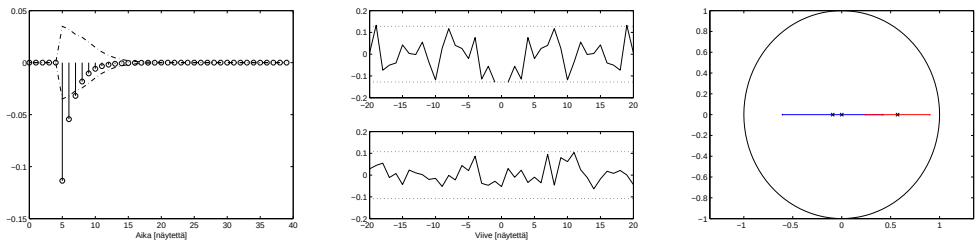

(a) (b) (c)

Kuva 4.9 Hakepintamallin ominaisuuksia jaksolta 1. Malli oli Box-Jenkins tyyppinen. Napa-nollakohtakuvassa luottamusvälit on korostettu erivärisillä viivoilla, joiden päässä on pienet pallot, jottei ne sekoittuisi. Origossa olevilla navoilla ei ole luottamusvälejä, koska ne johtuvat viiveestä.

Taulukko 4.3 Jakson 1 varianssihajotelma. Viiveet d_1 ja d_p hakepinnasta kappalukuun ovat viisi näyteväliä.

Häiriölähde	Varianssin aiheuttaja				Yhteensä
	mv	fb	ff	ff/fb	
tuntematon	4,11	0,39	—	—	4,49
hakepinta	0	—	1,53	0,12	1,65
Yhteensä	4,11	2,04			6,14

Jaksolla 2 keittimen hakepinnan aiheuttama osuus kokonaisvarianssista on $\frac{2{,}06}{6{,}77} = 0{,}30$. Mallin pätevyyttä heikentää pienillä viiveillä olevat hakepinnan merkittävät ristikorrelaatiot residuaalien kanssa. Lisäksi tällä mallilla kokonaisvarianssi 6,77 on huomattavasti suurempi kuin näytevarianssi 5,10. Näytevarianssin 95 % luottamusvälin yläraja on 5,77 ja 99 % yläraja 6,00 joten varianssihajotelman kokonaisvarianssi poikkeaa näytevarianssista merkittävästi. Tämän vuoksi analyysi on esitetty myös toisella mallilla, jonka ominaisuuksia on esitetty kuvassa 4.11 ja taulukossa 4.5. Tällä mallilla residuaalien ristikorrelaatio hakepinnan kanssa nollaviiveen lähellä on parempi kuin edellisellä mallilla, mutta impulssivaste näyttää oudommalta. Hakepinnankorkeuden viiveeksi d_1 kappalukuun on valittu varianssihajotelman laskennassa kaksi näyteväliä ja prosessin viiveeksi d_p viisi näyteväliä. Koska nyt $d_1 < d_p$ niin hakepintakomponentilla on myös minimivarianssitermi. Hakepinnan selittämä osuus kokonaisvarianssista on tässä tapauksessa $\frac{1{,}41}{5{,}41} = 0{,}26$ ja kokonaisvarianssi 5,41 mahtuu nyt näytevarianssin 95 % luottamusväleihin. Häiriöiden v_0 ja v_1 ristikorrelaatio oli ensimmäisellä mallilla 0,14 ja merkitsevyystaso 0,001. Toisella mallilla vastaavat luvut olivat 0,16 ja 0,0002.

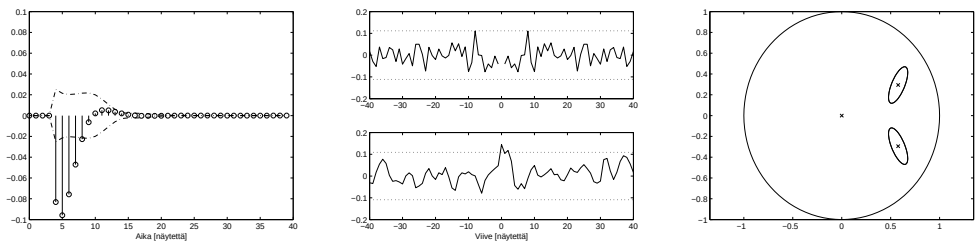

(a) (b) (c)

Kuva 4.10 Hakepintamallin ominaisuuksia jaksolla 2. Mallin tyyppi oli Box-Jenkins.

Taulukko 4.4 Jakson 2 varianssihajotelma. Viiveiksi valittu $d_1 = d_p = 4$.

Häiriölähde	Varianssin aiheuttaja				Yhteensä
	mv	fb	ff	ff/fb	
tuntematon	3,70	1,01	—	—	4,71
hakepinta	0	—	1,68	0,38	2,06
Yhteensä	3,70	3,07			6,77

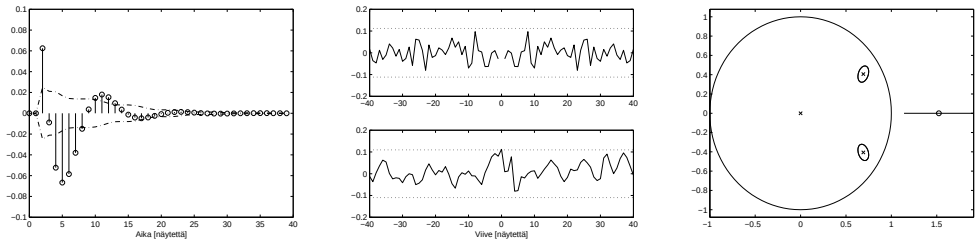

(a) (b) (c)

Kuva 4.11 Jakson 2 vaihtoehtoisen hakepintamallin ominaisuuksia. Tämäkin oli Box-Jenkins tyyppinen, mutta hakepinnan viive on tässä kaksi näyteväliä.

Taulukko 4.5 Jakson 2 toisen mallin perustella laskettu varianssihajotelma.

Häiriölähde	Varianssin aiheuttaja				Yhteensä
	mv	fb	ff	ff/fb	
tuntematon	3,56	0,44	—	—	4,00
hakepinta	0,11	—	0,57	0,73	1,41
Yhteensä	3,67	1,73			5,41

Jaksolla 3 keittimen hakepinnan selittämä osuus kokonaisvarianssista on $\frac{0{,}83}{5{,}09} = 0{,}16$. Tuntematon häiriö näyttäisi mallintuvan hyvin residuaalien autokorrelaation perusteella, mutta hakepinnan vaikutuksen mallintamisessa saattaa olla puutteita, koska residuaalien ja hakepinnan ristikorrelaatiossa on merkittäviä poikkeamia viiveillä 7 ja 8. Näytevarianssi oli 5,07 ja sen ylempi 95 % luottamusraja 5,86 joten mallin perusteella saatu kokonaisvarianssi 5,09 on selkeästi luottamusvälien sisällä. Häiriöiden v_0 ja v_1 ristikorrelaatio oli -0,14 ja merkitsevyystaso 0,005.

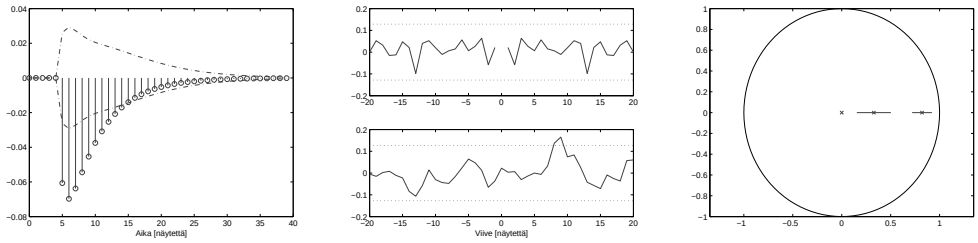

(a) (b) (c)

Kuva 4.12 Hakepintamallin ominaisuuksia jaksolla 3. Malli oli ARX-tyyppinen.

Taulukko 4.6 Jakson 3 varianssihajotelma. Viiveiksi on valittu $d_1 = d_\mathrm{p} = 5$.

Häiriölähde	Varianssin aiheuttaja				Yhteensä
	mv	fb	ff	ff/fb	
tuntematon	3,42	0,84	—	—	4,26
hakepinta	0	—	0,70	0,13	0,83
Yhteensä	3,42	1,67			5,09

Varianssihajotelmien perusteella hakepinnan vaikutus kappaluvun varianssiin näyttäisi olevan luokkaa 20–30 %. Oletuksena oli, että häiriölähteet tuntematon häiriö v_0 ja hakepinnankorkeussignaalin muodostava v_1 ovat toisistaan riippumattomat, mikä ei kuitenkaan näytä tässä tapauksessa pitävän paikkaansa. Sen vuoksi varianssihajotelmiin ei voida luottaa täysin. Tarkastellaan vielä kuitenkin tapausta, jossa häiriölähteinä ovat yhtä aikaa sekä hakepinta että kokonaisjäännösalkalipitoisuus. Tarkastelujaksoksi otettiin jakso kaksi, koska se oli pitkä yhtenäinen tasaisen tuotantonopeuden jakso. Tulokseksi saatiin taulukon 4.7 mukainen varianssihajotelma. Sen mukaan hakepinnan osuus kokonaisvarianssista olisi $\frac{1{,}62}{6{,}15} = 0{,}26$ ja jäännösalkalipitoisuuden osuus $\frac{0{,}39}{6{,}15} = 0{,}063$. Hakepinta selittäisi siis tämän mukaan huomattavasti suuremman osuuden kapan varianssista kuin jäännösalkalipitoisuus. Pohjaa tulokselta kuitenkin vie jälleen häiriölähteiden v_0, v_1 ja v_2 ristikorrelaatioiden tarkastelu: $r_{01} = 0{,}13; r_{02} = -0{,}061$ ja $r_{12} = 0{,}22$. Vastaavat merkitsevyystasot ovat: $P_{01} = 0{,}0023$; $P_{02} = 0{,}89$ ja $P_{12} = 0{,}00000048$. Tämän perusteella siis vain tuntematon häiriö v_0 ja kokonaisjäännösalkalipitoisuus näyttäisivät olevan toisistaan riippumattomia. Kuvassa 4.13 on mallin residuaalien autokorrelaatio ja ristikorrelaatio häiriösignaalien kanssa. Korrelaatiot näyttävät pysyvän 99 % luottamusvälien

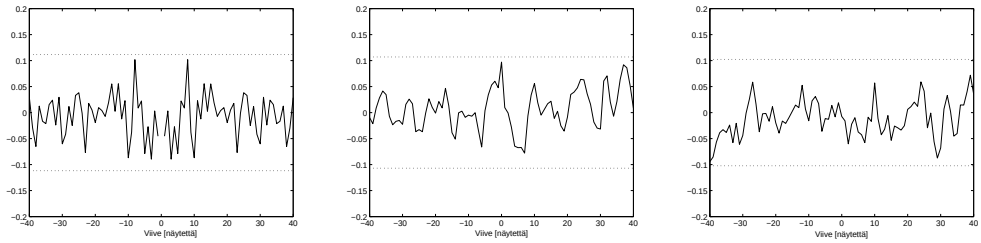

(a) (b) (c)

Kuva 4.13 Residuaalien (a) autokorrelaatio ja ristikorrelaatio (b) hakepinnan sekä (c) kokonaisjäännösalkalipitoisuuden kanssa.

sisällä. Kokonaisvarianssi 6,15 poikkeaa kuitenkin tilastollisesti merkittävästi näytevarianssista, joka oli tällä jaksolla 5,10.

Taulukko 4.7 Varianssihajotelma, jossa häiriösignaaleina keittimen hakepinta ja kokonaisjäännösalkalipitoisuus. Viiveet ovat: $d_\mathrm{p} = 4, d_1 = 3$ ja $d_2 = 4$.

Häiriölähde	Varianssin aiheuttaja				Yhteensä
	mv	fb	ff	ff/fb	
tuntematon	3,22	0,92	—	—	4,14
hakepinta	0,01	—	0,75	0,86	1,62
kokonaisjäännösalkalipitoisuus	0	—	0,22	0,17	0,39
Yhteensä	3,23	2,92			6,15

Kuvassa 4.14 on vielä kappaluvun ja hakepinnan tehospektrit eri ajanjaksoilta. Signaaleista on vähennetty keskiarvo ja ne on jaettu keskihajonnallaan ennen tehospektrin laskentaa. Näin molempien signaalien keskimääräiseksi tehoksi tulee sama, joten tehospektrien vertailu on helpompaa. Tehospektrit on laskettu Blackman-Tukey menetelmällä ja ikkunana on käytetty Bartlett-ikkunaa. Varsinkin jaksolla kaksi, joka on tasaista tuotantoa, hakepinnan ja kappaluvun spektrit näyttävät sisältävän selvästi samoja komponentteja. Tällä jaksolla eniten tehoa näyttäisi olevan kulmataajuudella $\omega = 0{,}15\pi$, joka vastaa tunnin näyteväliajalla noin 13 tunnin jaksonaikaa.

4.4 Keittimen hakepinnankorkeuden säädön arviointi

Edellä saatiin viitteitä, että keittimen hakepinnankorkeudessa ilmenevät värähtelyt voivat näkyä kappaluvussakin. Tarkastellaan seuraavaksi keittimen hakepinnan

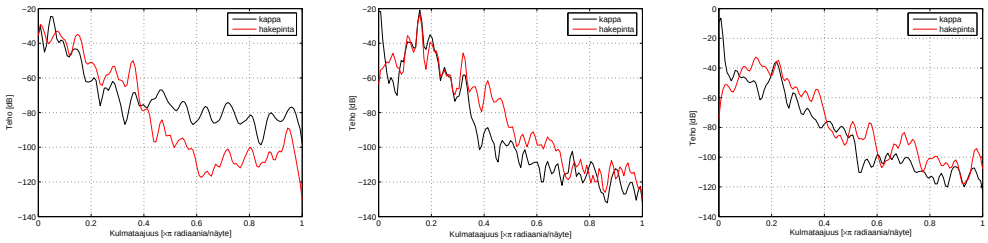

(a) (b) (c)

Kuva 4.14 Normalisoidun kappaluvun ja hakepinnan tehospektrit a) jaksolla 1, b) jaksolla 2 ja c) jaksolla 3.

säätöä ja siihen vaikuttavia tekijöitä. Keittimen hakepintaa säädetään keittimen puskuvirtauksella PI-säätimellä, jonka siirtofunktio on

$$G_{\mathrm{c,hp}}(z^{-1}) = K \cdot \frac{1 - I \cdot z^{-1}}{1 - z^{-1}}, \tag{4.4}$$

missä vakiot K ja I ovat

$$\begin{aligned} K &= \frac{K_{\mathrm{P}}}{100} \\ I &= e^{-\frac{T_{\mathrm{s}}}{60} T_{\mathrm{I}}}. \end{aligned}$$

Vahvistus K_{P} ja integrointiaika T_{I} annetaan Alcont:sta ja näyteväliajaksi T_{s} on valittu 5 s. Säätimelle tulevaa signaalia suodatetaan suodattimella, jonka siirtofunktio on muotoa

$$G_{\mathrm{f,hp}}(z^{-1}) = \frac{a}{1 - (1 - a)\, z^{-1}}, \tag{4.5}$$

missä a on suodatusvakio.

Hakepintasäädön suorituskykyä verrattiin ensin minimivarianssisäätöön. Analyysi tehtiin HIC:n 10 minuutin keskiarvodatalla useilla jaksoilla. Nämä jaksot on esitelty taulukossa 4.8. Hakepinnan asetusarvo on oli aluksi 32 yksikköä ja se muuttui toisella jaksolla 35 yksikköön. Taulukon perusteella voidaan päätellä, että hakepinnan tilastolliset ominaisuudet kuten keskiarvo ja -hajonta vaihtelevat ajan kuluessa. Tämä tarkoittaa sitä, että prosessi ei ole stationaarinen. Taulukosta voidaan havaita myös, että säädin ei kykene pitämään hakepinnankorkeutta keskimäärinkään

asetusarvossaan, koska hakepinnankorkeuden keskiarvo on asetusarvoaan pienempi jokaisella tarkastelujaksolla.

Datalle tehtiin minimivarianssianalyysi, jonka tulokset on koottu taulukkoon 4.9. Viiveeksi on valittu yksi näyteväli, eli 10 minuuttia. Tätä viivettä käyttivät myös Allison ja Dumont [5]. Taulukon perusteella voidaan todeta, että suorituskykyindeksi η on varsin suuri kaikilla tarkastelujaksoilla. Tarkastellaan säädön suorituskykyä vielä liitteen 2 avulla, johon on koottu identifioitujen siirtofunktioiden impulssivasteet, spektrien vertailu minimivarianssisäätöön ja residuaalien autokorrelaatiot kaikilla tarkastelujaksoilla. Impulssivasteista nähdään, että säätö ei kykene kompensoimaan hakepinnankorkeuteen syntyviä häiriöitä kovin nopeasti, koska impulssivasteet vaimenevat hyvin hitaasti. Spektrikuvaajista puolestaan nähdään, että ongelmat ovat matalilla taajuuksilla. Desboroughn ja Harrisin [14] mukaan ongelmaa voidaan yrittää pienentää kasvattamalla säätimen vahvistusta. Hakepinnan säätö on kuitenkin tässä tapauksessa tarkoituksella viritetty melko hitaaksi, jotta nopeista puskuvirtauksen muutoksista ei aiheutuisi muita häiriöitä.

Säätimen viritystä päätettiin kuitenkin kokeilla kasvattamalla vahvistusta K 33 %. Tämän jälkeen kerättiin uusi aineisto, jolle tehtiin minimivarianssianalyysi. Analyysin tulokset ovat taulukossa 4.10. Taulukossa on lisäksi kappalukujen keskihajontojen estimaatit ja niiden 95 % luottamusvälit. Niitä ei kuitenkaan ole mielekästä vertailla sellaisenaan keskenään, koska kappalukuun kohdistuu monia muitakin häiriöitä kuin hakepinnan vaihtelut. Yksi on varmasti hakelaadun vaihtelut, koska keittimellä tehtiin kokeita erilaisilla hakelaaduilla koko tarkastelujakson ajan. Suorituskykyindeksi η on sitä vastoin paremmin vertailukelpoinen. Niidenkään vertailu ei kuitenkaan ole aivan suoraviivaista, koska nekin ovat tilastollisia estimaattoreita. Tarkempaa tarkastelua varten pitäisi siis tuntea niiden luottamusvälit kullakin jaksolla. Jos tarkastellaan indeksin arvoa keskimäärin, niin voidaan todeta, että se on virityksen jälkeen jonkin verran pienempi kuin ennen viritystä. Tämän perusteella hakepinnan säädön suorituskyky näyttäisi siis parantuneen.

Hakepinnan värähtelylle etsittiin myös syytä muista signaaleista korrelaatioanalyysillä. Tässä analyysissä syntyneet impulssivastekuvat on koottu liitteeseen 3. Koska

Taulukko 4.8 Keittimen hakepinnan tarkasteluajanjaksot tilastollisine perussuureineen. Keskiarvolle ja keskihajonnalle on laskettu 95% luottamusvälit olettaen data normaalijakautuneeksi.

Jakso	Aikaväli	N	$\hat{\mu}$	$\hat{\sigma}$	$\hat{\sigma}$ luottamusväli
1	31.7. 15:00 - 5.8. 06:00	667	28,74± 0,32	4,25	$4{,}04 < \sigma < 4{,}49$
2	5.8. 06:00 - 9.8. 08:00	588	28,44± 0,30	3,66	$3{,}46 < \sigma < 3{,}88$
3	10.8. 10:00 - 16.8. 00:00	805	33,08± 0,61	8,83	$8{,}42 < \sigma < 9{,}29$
4	16.8. 00:10 - 20.8. 00:00	576	31,32± 0,47	5,69	$5{,}37 < \sigma < 6{,}03$
5	20.8. 00:10 - 25.8. 00:00	720	32,36± 0,42	5,76	$5{,}47 < \sigma < 6{,}07$
6	14.9. 00:10 - 19.9. 00:00	720	32,18± 0,38	5,21	$4{,}95 < \sigma < 5{,}49$
7	4.10. 12:00 - 8.10. 07:00	547	31,79± 0,41	4,88	$4{,}61 < \sigma < 5{,}19$
8	12.10. 00:00 - 18.10. 05:50	883	32,6± 0,45	6,74	$6{,}44 < \sigma < 7{,}07$
9	18.10. 06:00 - 24.10. 09:00	883	31,56± 0,34	5,10	$4{,}87 < \sigma < 5{,}35$

Taulukko 4.9 Hakepintasäädön minimivarianssianalyysi. Suorituskykyindeksin $\hat{\eta}$ laskennassa on käytetty mallin perusteella saatua varianssia eikä näytevarianssia $\hat{\sigma}_y^2$, joten indeksi voi olla hieman eri suuruinen, jos se lasketaan näytevarianssin avulla. Indeksien suuruusluokat ovat kuitenkin molemmilla laskentatavoilla samat.

Jakso	Q_{50}	Q:n P-arvo	$\hat{\sigma}_y^2$	$\hat{\sigma}_{\mathrm{mv}}^2$	$\hat{\eta}(1)$
1	46,8	0,44	18,08	5,20	0,70
2	47,1	0,43	13,36	4,85	0,63
3	41,3	0,63	78,05	6,10	0,92
4	36,3	0,85	32,32	3,96	0,87
5	42,8	0,61	33,13	6,18	0,84
6	54,7	0,18	27,14	7,38	0,73
7	48,8	0,32	23,80	6,55	0,71
8	40,9	0,39	45,41	7,46	0,84
9	65,0	0,02	26,01	7,42	0,71

Taulukko 4.10 Hakepinnan minimivarianssitarkastelu säätimen vahvistustermin kasvatuksen jälkeen.

		hakepinta				kappaluku	
jakso	aikaväli	N	$\hat{\sigma}_y^2$	$\hat{\sigma}_{\mathrm{mv}}^2$	$\hat{\eta}(1)$	$\hat{\sigma}_y$	$\hat{\sigma}_y$ luottamusväli
10	26.10. 00:00 - 27.10 10:20	207	13,90	4,38	0,69	4,34	$3{,}51 < \sigma < 5{,}68$
11	27.10. 10:30 - 2.11. 10:20	864	12,74	5,99	0,53	2,89	$2{,}59 < \sigma < 3{,}26$
12	2.11. 10:20 - 7.11. 10:20	721	17,90	7,64	0,59	2,09	$1{,}85 < \sigma < 2{,}39$
13	7.11. 10:20 - 12.11. 10:20	721	15,02	5,83	0,61	2,16	$1{,}91 < \sigma < 2{,}47$
14	12.11. 10:20 - 15.11. 2:20	385	20,08	4,37	0,79	1,60	$1{,}37 < \sigma < 1{,}94$
15	16.11. 19:00 - 21.11. 19:00	721	34,12	12,0	0,65	2,21	$1{,}96 < \sigma < 2{,}53$
16	21.11. 19:00 - 26.11. 8:00	655	15,16	5,36	0,66	1,41	$1{,}25 < \sigma < 1{,}63$
17	29.11. 19:00 - 3.12. 17:20	567	10,33	4,47	0,52	3,90	$3{,}41 < \sigma < 4{,}54$
18	3.12. 17:20 - 7.12 16:00	569	24,87	7,27	0,71	2,65	$2{,}32 < \sigma < 3{,}09$

tarkastelujaksoja ja signaaleja on useita, niin ei ole järkevää eikä mahdollista esittää kaikkia kuvaajia erillään. Niinpä samaan kuvaan on piirretty impulssivasteet seitsemältä jaksolta. Kuvista voi olla vaikea nähdä yksittäisiä kuvaajia, mutta se ei olekaan tarkoitus vaan niistä voidaan nähdä, onko jonkin signaalin vasteessa selvää yhdenmukaisuutta eri jaksoilla. Selvästi hakepinnankorkeuteen vaikuttavia tekijöitä näyttävät olevan

- keittimen pohjan olosuhteita kuvaavat suureet: puskusakeus (6), keittimen puskun paine-ero (11) ja keittimen pohjakaavarin hydrauliikan paine (16),
- hakkeen syöttöön liittyvät piirit: imeytystornin pohjakaavarin pyörimisnopeus (13) ja imeytystornin pohjalaimennus (23),
- lipeäpinnankorkeus (7) ja sen ohjausmuuttuja paisuntalipeävirtaus (4).

Myös haihduttamolle menevän mustalipeän kiintoainepitoisuuden (27) värähtelyt voivat näkyä jossain määrin hakepinnassa. Lisäksi on tietysti hakepinnan ohjausmuuttuja puskuvirtaus (2), jossa näkyy kausaalisen vuorovaikutuksen lisäksi voimakas takaisinkytkennän vaikutus viiveillä $k \leq 0$. Joissain muissakin piireissä on nähtävissä saman tyyppinen vuorovaikutus. Näissä tapauksissa vuorovaikutus on siis molemmin suuntaista, eli myös hakepinnankorkeus vaikuttaa tarkasteltavaan signaaliin. Tällaisia tapauksia näyttäisivät olevan esimerkiksi paisuntavirtaukset, puskusakeus

ja keittimen lipeäpinnankorkeus. Koska myös keittimen lipeäpinnankorkeutta halutaan säätää, niin analyysin perusteella säätöongelma näyttää MIMO-tyyppiseltä. Hake- ja lipeäpintojen säätöjen vuorovaikutusta tarkasteltiin myös niiden ohjausmuuttujien avulla. Kuvaan 4.15a on piirretty molempien piirien ohjausmuuttujien aikatason kuvaajat jaksolla yksi. Kuvasta nähdään, että ohjausmuuttujat ovat likimain vastakkaisvaiheisia jatkuvasti. Tämä piirre vahvistaa sen, että säätöpiirit ovat jollain tavalla kytköksissä toisiinsa. Kuvassa 4.15 on myös molempien ohjausmuuttujien impulssivaste-estimaatit toistensa suhteen. Kuvan 4.15b perusteella molemmat ohjausmuuttujat näyttävät vaikuttavan toisiinsa, mutta kuvan 4.15c perusteella vain paisuntavirtaus näyttäisi vaikuttavan puskuvirtaukseen, koska estimaatti poikkeaa nollasta tilastollisesti merkittävästi vain negatiivisilla viiveillä.

Nykyinen säätöjärjestelmä ei ota huomioon hake- ja lipeäpinnan voimakasta ristikytkentää vaan molempia suureita säädetään itsenäisillä säätäjillä. Tämän vuorovaikutuksen edes jonkinlainen huomioiminen saattaisi parantaa säätötulosta.

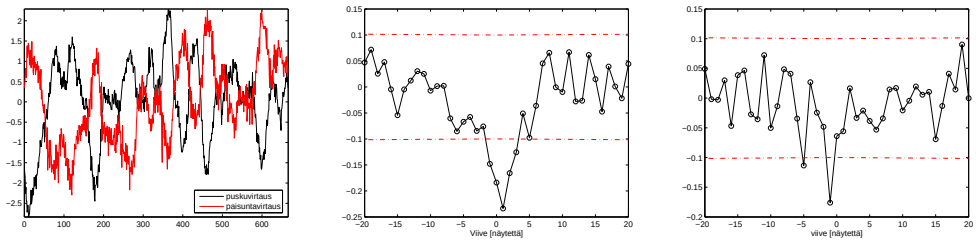

(a) (b) (c)

Kuva 4.15 Hake- ja lipeäpinnan normalisoitujen ohjausmuuttujien vertailua jaksolla 1. Kuvassa (a) on molemmat aikatasossa ja kuvissa (b) ja (c) on molempien impulssivaste-estimaatit toistensa suhteen. Kuvassa (b) selitettävänä signaalina (lähtönä) on puskuvirtaus ja selittävänä signaalina (tulona) on paisuntavirtaus ja kuvassa (c) ne ovat päinvastoin. Signaalien normalisointi on tehty vähentämällä niistä keskiarvo ja jakamalla ne keskihajonnallaan, jolloin varianssiksi tulee yksi.

4.4.1 Hakepinnankorkeuden ja puskuvirtauksen välisen siirtofunktion identifiointi

Hakepinnansäädön uudelleen järjestelemiseksi tarkoituksena oli identifioida siirtofunktio eri suureista hakepinnankorkeuteen. Kiinnostuksen kohteina olivat pusku-

virtauksen, imeytystornin pohjakaavarin pyörimisnopeuden ja pohjalaimennuksen vaikutukset hakepintaan. Lisäksi haluttiin selvittää hakeruuvin pyörimisnopeuden vaikutus imeytystornin hakepintaan. Ajanpuutteen vuoksi päätettiin kuitenkin identifioida tässä työssä vain puskuvirtauksen ja hakepinnan välinen siirtofunktio.

Keittimen toimintaa haluttiin häiritä mahdollisimman vähän kokeen aikana, joten identifiointi päätettiin tehdä suljetussa piirissä säädön toimiessa normaalisti. Suljetussa piirissä prosessin tuloon kytkeytyy suoraan myös eliminoitava häiriö. Jotta identifiointi suljetussa piirissä olisi mahdollista, niin prosessin ohjaukseen eli tässä tapauksessa puskuvirtaukseen on kytkettävä ulkoinen häiriösignaali [28, s. 428 - 432]. Koe suoritettiin siten, että puskuventtiilin ohjaukseen kytkettiin kolmen minuutin välein päivittyvä tasajakautunut nollakeskiarvoinen satunnaisluku, jonka vaihteluväliksi oli valittu [−3,3]. Satunnaisluvut generoitiin Alcont:n RAND-funktiolla. Dataa kerättiin sovellusasemalla 5 sekunnin näyteväliajalla noin 6 tunnin ajan. Kuvaan 4.16 on piirretty hakepinnankorkeus ja puskuvirtaus koko mittausjaksolla ajan funktiona. Ennen identifiointia tarkasteltiin jälleen näytteistyksen ajoituksen tarkkuutta. Näytehetkistä laskettiin erotukset, jolloin saatiin näytteiden oton välillä kulunut aika ja ne piirrettiin kuvaan 4.17. Kuvasta havaitaan, että välillä näytteitä tulee useita samalta hetkeltä. Tämän vuoksi kaikki kerätyt datat interpoloitiin ennen identifiointia lineaarisella interpoloinnilla tasaiselle 5 s näyteväliajalle. Kuvassa 4.18 on verrattu interpoloitua puskuventtiilin ohjausarvoa todelliseen mittausdataan, jonka aikaleimat ovat Alcont:sta saatuja. Lisäksi kuvaan on piirretty, miltä puskuventtiilin ohjausarvo näyttäisi, jos mittausdata oletettaisiin tasaisella 5 s näytevälillä näytteistetyksi. Kuvasta nähdään, että ilman interpolointia signaalinkäsittelyn tulokset vääristyisivät selvästi, koska tasaväliseksi oletettu mittausdata näyttää aivan erilaiselta kuin todellinen mittausdata.

Häiriö siis kytkettiin suoraan puskuventtiilin ohjaukseen. Tavoitteena oli kuitenkin löytää siirtofunktio puskuvirtauksesta hakepintaan. Siirtofunktiota ei ole oikeastaan mielekästäkään etsiä suoraan puskuventtiilin ohjauksesta, koska venttiilillä on aina jonkinlainen välys. Se on siis epälineaarinen toimilaite, joten sitä ei ole syytä ottaa mukaan lineaarisen siirtofunktion identifiointiin. Interpoloidun puskuvirtauksen ja

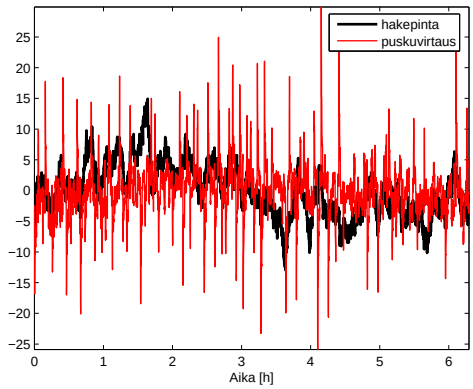

Kuva 4.16 Hakepinnankorkeus ja puskuvirtaus ajanfunktiona. Molemmista on poistettu keskiarvo vertailua helpottamaan.

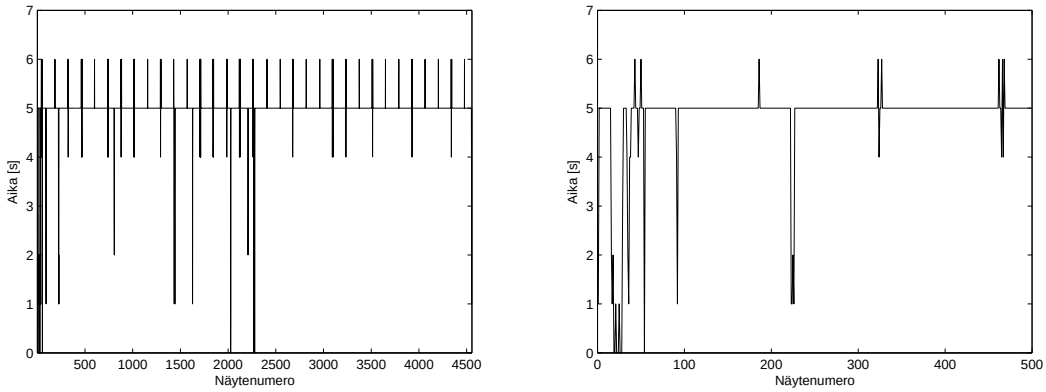

(a) (b)

Kuva 4.17 Näyteväliajat eri näytteiden välillä. Kuvassa (a) on koko mittausjakso ja kuvassa (b) 500 ensimmäistä näytettä. Ajoittain näytteitä tulee jopa samalta näytehetkeltä useita.

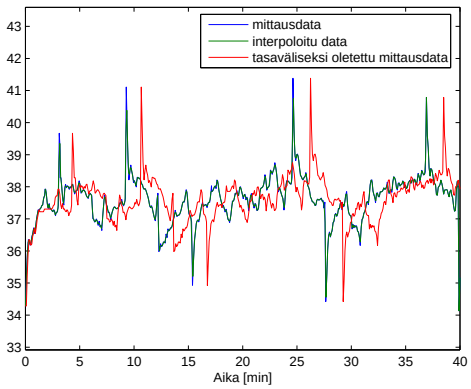

Kuva 4.18 Mitatun puskuventtiilin ohjausarvon vertailu interpoloituun ja tasaväliseksi oletettuun mittausdataan. Kuvaan on piirretty vertailun helpottamiseksi vain mittausdatan alkuosa.

hakepinnankorkeuden välille identifioitiin erilaisia malleja. Aikasarjamalleista paras sovitus saatiin Box-Jenkins mallilla, jonka parametrit olivat

$$\begin{aligned} y(n) &= \frac{-0{,}009744}{1-0{,}9996q^{-1}}q^{-5}u(n)+w(n) \\ w(n) &= \frac{1+0{,}0233q^{-1}-0{,}1373q^{-2}-0{,}07769q^{-3}-0{,}03837q^{-4}-0{,}107q^{-5}}{1-1{,}103q^{-1}+0{,}107q^{-2}}v(n). \end{aligned} \tag{4.6}$$

Käytännössä siis hakepinta näyttää integroivan puskuvirtausta, koska siirtofunktiossa oleva napa on niin lähellä yksikköympyrää. Matlab R14 mukana tulevalla System Identification Toolboxilla on mahdollista identifioida prosessimalleja myös suoraan Laplace-tasossa. Edellisen mallin perusteella dataa sovitettiin myös malliin, joka oli muotoa

$$Y(s) = \frac{K}{s}e^{-d_{\mathrm{p}}s}U(s) + \frac{C(s)}{D(s)}V(s). \tag{4.7}$$

Viiveeksi valittiin sama kuin Box-Jenkins mallillakin (25 s), koska sillä saatiin paras sovitus. Kertoimen K arvoksi saatiin -0,0010. Häiriömalliksi saatiin

$$\frac{C(s)}{D(s)} = \frac{s+1{,}248}{s+0{,}006}. \tag{4.8}$$

Kuvassa on esitetty kyseisten mallien residuaalien tarkastelu. Residuaalien perusteella näyttää siltä, että Box-Jenkins malli sovittaa datan paremmin, koska jatkuva-aikaisen mallin residuaalien autokorrelaatio poikkeaa merkittävästi nollasta pienillä k:n arvoilla. Parempi sovitus johtuu siitä, että Box-Jenkins mallin häiriösiirtofunktion kertaluku on huomattavasti suurempi kuin jatkuva-aikaisessa mallissa.

Mallien pätevyyttä matalilla taajuuksilla kuitenkin heikentää se, että ohjaussignaalissa ei ollut kovin matalia taajuuksia. Tämä voidaan havaita kuvasta 4.20, jossa on esitetty puskuvirtauksen spektri kokeen ajalta. Systeemiin lisätty häiriö näkyy voimakkaimmin taajuusalueella $1 \cdot 10^{-3} - 4 \cdot 10^{-3}$ Hz, vaikka aivan pienilläkin taajuuksilla näyttäisi olevan tehoa. Spektriestimaatin luottamusvälit alkavat kuitenkin leviämään taajuudella $0{,}5 \cdot 10^{-3}$ Hz, joten matalataajuinen komponentti voi olla harhaa. Toisaalta se voi olla myös takaisinkytketystä hakepintasäädöstä aiheutuva komponentti. Häiriösignaalin kytkeytymistaajuus oli $5{,}6 \cdot 10^{-3}$ Hz. Häiriön maksimi-

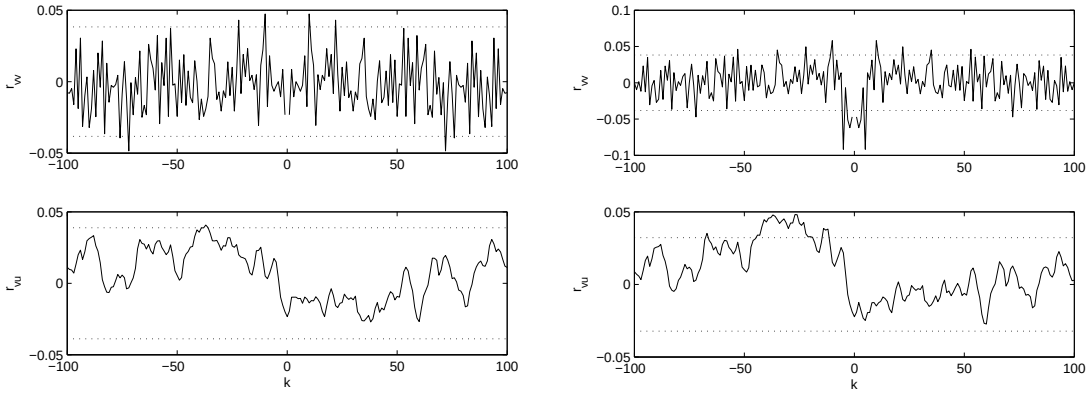

(a) (b)

Kuva 4.19 Hakepinnankorkeuden ja puskuvirtauksen välisten mallien residuaalien tarkastelu auto- ja ristikorrelaation avulla. Kuvassa (a) on yhtälössä (4.6) esitetyn diskreetin Box-Jenkins mallin residuaalien korrelaatiot ja kuvassa (b) yhtälössä (4.7) esitetyn jatkuva-aikaisen mallin residuaalien korrelaatiot.

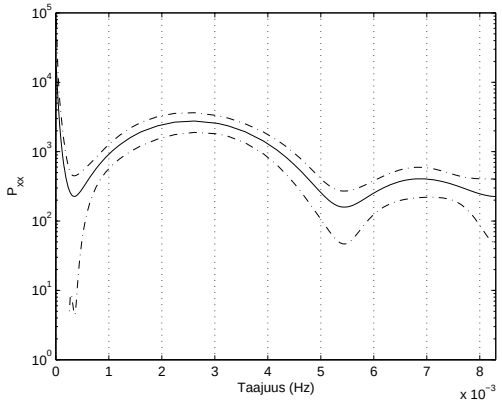

Kuva 4.20 Puskuvirtauksen parametrinen tehospektrin estimaatti identifiointikokeessa. Kuvassa on myös estimaatin 95 % luottamusvälit.

taajuus (Nyquistin taajuus) oli siis $2{,}8 \cdot 10^{-3}$ Hz, joka sattuu kuvassa 4.20 lähes huipun kohdalle. Identifioinnin kannalta olisi ollut toivottavaa, että puskuvirtaukseen olisi saatu luotua mahdollisimman paljon matalia taajuuksia, koska ongelmatkin ovat niillä taajuuksilla. Sisemmän tason puskuvirtauksen säätö vaimensi ne kuitenkin pääosin pois. Parempi identifiointitulos olisi saavutettu kytkemällä häiriösignaali puskuvirtauksen asetusarvoon. Näin menetellen ei myöskään puskuvirtaukseen olisi syntynyt niin voimakkaita hetkellisiä piikkejä kuin tässä kokeessa.

5 JOHTOPÄÄTÖKSET JA YHTEENVETO

Työn tarkoituksena oli selvittää, toimiiko sellukeiton kappaluvun säätö hyvin vai voidaanko sitä parantaa. Toinen tavoite oli löytää yleisiä menetelmiä säädön suorituskyvyn analysoimiseen. Tarkasteltuja menetelmiä olivat minimivarianssisäätöön perustuvaa minimivarianssianalyysi, syy-seuraussuhteita paljastava korrelaatioanalyysi sekä tehospektri.

Ensin tarkasteltiin kappaluvun säädön takaisinkytkentäsäädintä ja havaittiin, että se toimi melko lähellä minimivarianssisäätöä eri tarkastelujaksoilla. Takaisinkytkentää virittämällä ei siis voida juurikaan vähentää kappaluvun vaihteluja. Rajoittavan tekijän tämän säädön suorituskyvylle muodostaa pitkä viive. Viivettä voisi olla mahdollisesti lyhentää ns. Midpoint-kappalukumittauksella, joka mitataan keittovyöhykkeen jälkeen paisuntasihtien alapuolelta [2]. Midpoint-kappalukumittaus ei kuitenkaan ole aivan ongelmaton, koska hake ei ole vielä välttämättä kuituuntunut mittauspisteessä. Siksi se pitäisi kuiduttaa ensin.

Seuraavaksi tutkittiin, voisiko kappaluvun vaihteluita selittää muilla signaaleilla. Ensimmäinen karsinta tehtiin epäparametrisilla suljetun systeemin impulssivasteestimaateilla. Niiden avulla löydettiin joukko suureita, jotka näyttivät selvästi toimivan häiriöinä kappaluvulle. Tällaisia olivat monet keittimen hakepatsaan liikkumiseen vaikuttavat tai sitä kuvaavat tekijät sekä jotkin keittolipeän ominaisuudet. Näistä signaaleista valittiin tarkempaan tarkasteluun keittimen hakepinnankorkeuden vaihtelut, koska aikaisemman tutkimustiedonkin perusteella sen tiedettiin vaikuttavan kappalukuun. Varianssihajotelmien perusteella hakepinta näyttäisi selittävän kappaluvun varianssista eri määrän eri tarkastelujaksoilla. Toisaalta näiden arvojen suora vertaaminen ei olekaan järkevää, koska tuotanto-olosuhteet olivat tarkastelujaksoilla erilaiset. Kahdella ensimmäisellä jaksolla, joilla tuotantonopeus oli pääosin tasaista, hakepinnan selittämä osuus oli noin 30 %. Myös tehospektreissä nähtiin selkeitä yhteneväisyyksiä kappaluvun ja hakepinnan välillä.

Täytyy kuitenkin muistaa, että varianssihajotelmat ovat vain suuntaa-antavia, koska ne perustuvat mittausdatan perusteella identifioitujen aikasarjamallien ominaisuuksiin, jotka puolestaan riippuvat käytettävän datan laadusta ja määrästä. Mallien pä-

tevyyttä tarkasteltiin residuaalien ja napa-nollakohtakuvaajien avulla. Myös analysoinnissa käytetyn datan ominaisuuksia tarkasteltiin. Selkeä ongelma analyysin kannalta on kappaluvun vaihteleva näytteenottoväli, joka voi ajoittain kasvaa moninkertaiseksi normaaliin näyteväliaikaan verrattuna. Tämä on samalla myös ongelma takaisinkytketylle säädölle, koska prosessin viive kasvaa tällöin huomattavasti jo muutenkin pitkän viiveen lisäksi. Analyysiviiveen vaihteluita voisi mahdollisesti pienentää ottamalla käyttöön vain keittimen puskukappaa mittaava kappa-analysaattori, koska puskulinjasta otetun kappalukunäytteen epäonnistumisen seurauksena ei tarvitsisi odottaa muiden näytelinjojen analysointia, vaan voitaisiin ottaa heti uusi näyte puskulinjasta.

Hakepinnankorkeuden säädön suorituskyky selvitettiin myös, koska hakepinnan havaittiin vaikuttavan kappalukuun. Säädössä havaittiinkin ongelmia, joista suurin oli kappaluvun kannalta noin 10 tunnin jaksonajalla ilmenevät värähtelyt. Analyysin jälkeen värähtelyjä pyrittiin vaimentamaan säätimen vahvistuksen kasvatuksella, minkä seurauksena suorituskykyindeksi η näytti pienentyneen, eli säädön suorituskyky näytti parantuneen. Hakepinnan värähtelyiden pienentäminen tapahtui kuitenkin puskuvirtauksen muutoksia kasvattamalla. Ehkä parempi ratkaisu olisi käyttää mallipohjaista säädintä, jossa yhtenä selittävänä tekijänä (tilamuuttujana) olisi hakepinnankorkeus, koska ei ole varmaa, onko hakepinnan vaihtelu syy kappaluvun vaihteluihin vai johtuuko hakepinnan vaihtelut ennemminkin jostain toisesta häiriöstä, joka vaikuttaa myös kappalukuun. Tämän tapaista kappaluvun säätöä ehdottivat myös Amirthalingam ja Lee[8].

Jotta työssä käsiteltäviä menetelmiä voidaan käyttää hyödyksi, on oltava riittävä määrä mahdollisimman laadukasta ja edustavaa dataa käytössä. Tämä seikka voi rajoittaa hyvin katkonaisesti toimivien prosessien analysointia. Esiteltyjen menetelmien käyttöä laajojen ja monimutkaisten prosessien analysointiin hankaloittaa myös se, että käytetyt menetelmät eivät ota huomioon tarkasteltavien suureiden välisiä ristikkäisvaikutuksia.

Viitteet

[1] J. Gullichsen & C-J. Fogelholm. Chemical Pulping. Papermaking Science and Technology. osa 6A. Helsinki: Fapet. 1999.

[2] Knowpulp 2.4. [verkkodokumentti] saatavissa: LTY:n sisäverkossa. [viitattu 24.8.2005]

[3] K. Leiviskä. Process Control. Papermaking Science and Technology. osa 14. Helsinki: Fapet. 1999.

[4] T.M. Grace, E.W. Malcom, toim. Alkaline Pulping. Pulp and Paper Manufacture. osa 5. 3. painos. Atlanta: Tappi. 1989.

[5] B.J. Allison, G. A. Dumont et al. Adaptive-Predictive Control of Kamyr Digester Chip Level: Industrial results. Proceedings of the 76th Annual Meeting of the Technical Section, Canadian Pulp and Paper Association. Montreal, Quebec, Canada. ss A275-A284. 1990

[6] B.J. Allison, G. A. Dumont ja L. H. Novak. Multi-input adaptive-predictive control of Kamyr digester chip level. Canadian Journal of Chemical Engineering. Vol. 69, No. 1, ss. 111- 119. Feb 1991.

[7] T. Lindgren, T. Gustafsson et al. Model predictive control of the chip level in continuous pulp digester, a case study. Control Systems conference 2004, preprints. ss. 5-11. June 14.-18. Quebec, Canada. 2004.

[8] R. Amirthalingam ja J.H. Lee. Inferential Control of A Continuous Pulp Digester In the Presence of Chip Level Variations. Control Systems Conference 2000, preprints. Victoria, BC, Canada. ss. 123-126. May 2000.

[9] B. Gough ja J.T. Kay. Kraft continuous digester cooking control. Pulp & Paper Canada. Vol 97, no 7. ss. 56 - 60. 1996.

[10] Honeywell Oy. ACS-säätöjen toimintakuvaus versio 6.1. 2001.

[11] P.A. Wisnewski & F.J.Doyle. Model-Based Predictive Control Studies for a Continuous Pulp Digester. IEEE Transactions on Control Systems Technology, Vol. 9, No. 3, ss. 435 - 444. May 2001.

[12] R. Michaelsen, T. Christensen et al. Model Predictive Control of a Continuous Kamyr Digester at SCA-Nordliner, Munksund, Sweden. Pulp & Paper Canada. vol 95. No. 12. Dec 1994.

[13] T. J. Harris. Assessment of Control Loop Performance. The Canadian Journal of Chemical Engineering. vol 67. Oct, 1989.

[14] L. Desborough & T. J. Harris. Performance Assessment Measures for Univariate Feedforward/Feedback Control. The Canadian Journal of Chemical Engineering. vol 71. nro 4. ss. 605 - 616. 1993.

[15] T. J. Harris, F. Boudreau & J. F. MacGregor. Performance Assessment of Multivariable Feedback Controllers. Automatica. vol 32. No 11. ss. 1505-1518. 1996.

[16] B. Huang, S. L. Shah & E. K. Kwok. Good, Bad or Optimal? Performance Assessment of Multivariable Processes. Automatica. Vol 33. No 6. ss. 1175-1183. 1997.

[17] T. J. Harris, C. T. Seppala & L. D. Desborough. A review of performance monitoring and assessment techniques for univariate and multivariate control systems. Journal of Process Control. vol 9. ss 1-17. 1999.

[18] L. Desborough & T. Harris. Performance Assessment Measures for Univariate Feedback Control. The Canadian Journal of Chemical Engineering. vol 70. nro 6. ss. 1186 - 1197. 1992.

[19] G. E. Box & G. M. Jenkins. Time series analysis: forecasting and control. 2. painos. San Francisco: Holden-Day. 1976.

[20] O. Aumala et al. Mittaussignaalien käsittely. 3. uudistettu painos. Tampere: Pressus. 1998.

[21] J.G. Proakis, D.G. Manolakis. Digital Signal Processing: principles, algorithms and applications. 3. painos. New Jersey: Prentice Hall. 1996.

[22] S. Parviainen. Tilastomatematiikan perusteet, luentomoniste. Lappeenrannan teknillinen yliopisto. 2002.

[23] T. Söderström & P. Stoica. System Identification. Cambridge:Prentice Hall. 1989.

[24] K.J. Åström & B. Wittermark. Computer Controlled Systems: theory and design. 3. painos. New Jersey:Prentice Hall. 1997

[25] N. Stanfelj, T.E. Marlin, and J.F. MacGregor. Monitoring and Diagnosing Process Control Performance: The Single-Loop Case. Ind. Eng. Chem. Res. vol 32, nro 2, ss. 301-314, 1993

[26] J. Luukko. Digitaalisen signaalinkäsittelyn erikoiskurssi, luentomoniste. Lappeenrannan teknillinen yliopisto. 2005.

[27] The Mathworks Inc. System Identification toolbox:n käyttöohje.

[28] L. Ljung. System Identification: Theory for the User. Upper Saddle River (NJ): Prentice Hall. 1999.

Liite 1. Normalisoituja impulssivasteita kappalukuun

Seuraavissa kuvissa esitetään eri signaalien suljetun systeemin impulssivasteita kappalukuun. Kutakin signaalia kohti on neljä eri kuvaa, jotka on merkitty kirjaimin a–d. Tarkasteltava signaali on ilmoitettu kuvasarjan alapuolella. Kuvissa käsitellään kaksi tapausta: tulosignaalin differenssin kertaluku nolla (kuvat a ja b) ja differenssin kertaluku yksi (kuvat c ja d). Varsinaiset impulssivasteet ovat kuvissa b ja d. Kuvissa a ja c on vasemmassa sarakkeessa tulosignaalin aikasarja eri tarkasteluajankohtina ja oikeassa sarakkeessa on vastaavan signaalin autokorrelaatio. Eri ajanjaksot on ilmaistu kuvissa a ja c kuvien vasemmalla puolella olevilla numeroilla, jotka viittaavat taulukon (4.1) ajanjaksoihin. Impulssivastekuvissa eri ajanjaksot on esitetty eri väreillä, joiden selitykset ovat kuvissa itsessään. Signaalien aikasarjat ja autokorrelaatiot on esitetty siksi, että voitaisiin arvioida tulosignaalin stationaarisuutta, joka on yksi menetelmän oletuksista. Epästationaarisuus ilmenee aikasarjoissa esimerkiksi ajoittain muuttuvana keskiarvona ja autokorrelaatiossa hyvin hitaana vaimenemisena [19]. Esimerkiksi tuotantonopeus (signaali 1) näyttää olevan selkeästi epästationaarinen jaksolla 3. Ensimmäinen differenssi muuttaa sen kuitenkin stationaariseksi.

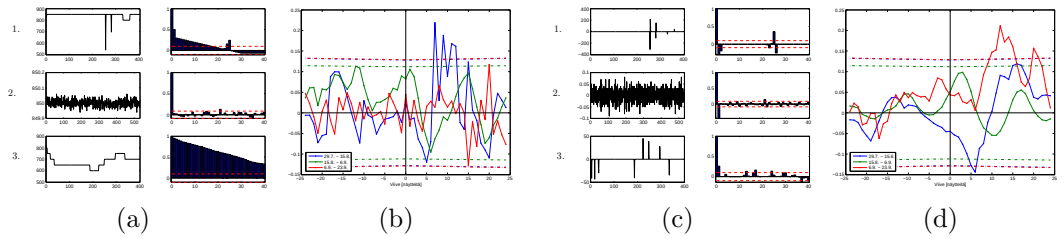

(a) (b) (c) (d)

Signaali 1. tuotantonopeus (MM1PRORATE.MES)

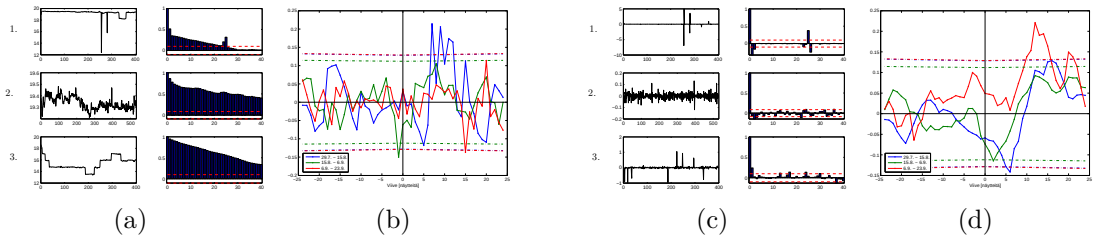

(a) (b) (c) (d)

Signaali 2. hakeruuvin pyörimisnopeus (VK1-SC003)

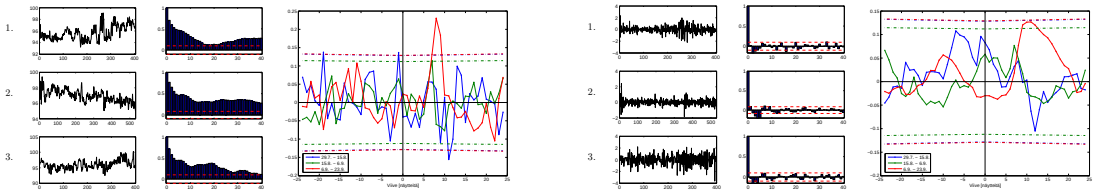

(a) (b) (c) (d)

Signaali 3. hakeruuvin täyttöaste (VK1-FI017)

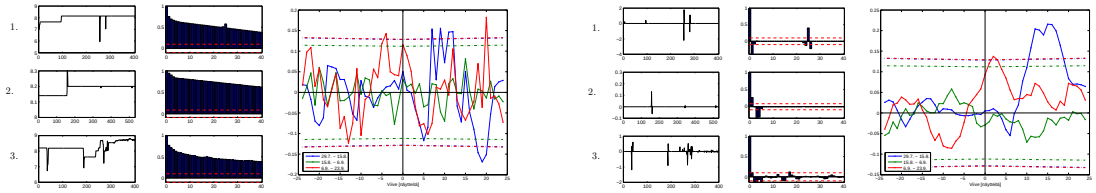

(a) (b) (c) (d)

Signaali 4. korkeapainekiikin pyörimisnopeus (VK1-SC004)

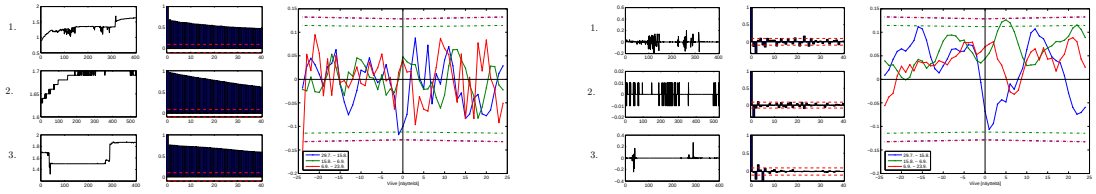

(a) (b) (c) (d)

Signaali 5. pasutusastian kaasaus (VK1-FC026)

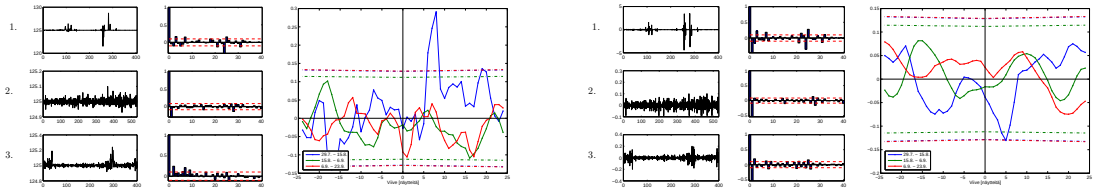

(a) (b) (c) (d)

Signaali 6. pasutusastian paine (VK1-PC083)

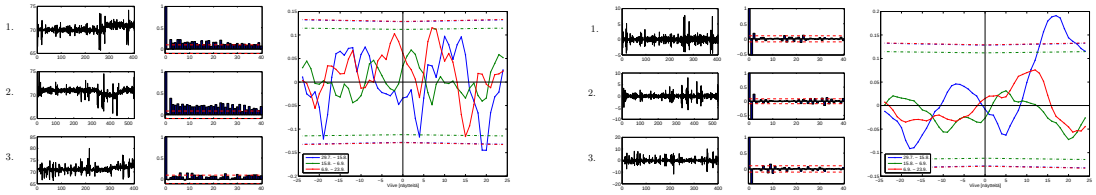

(a) (b) (c) (d)

Signaali 7. hakesiilon pinnankorkeus (VK1-LC007)

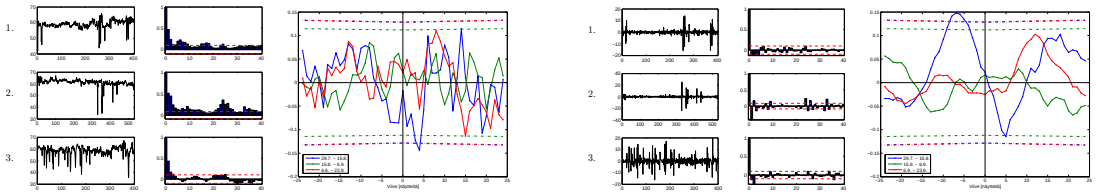

(a) (b) (c) (d)

Signaali 8. hakesiilon paino (VK1-WC003)

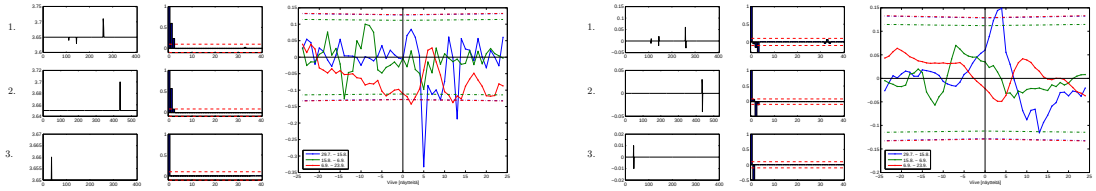

(a) (b) (c) (d)

Signaali 9. neste/puu -suhde (KL2 MM1LIQ_WOO.MES)

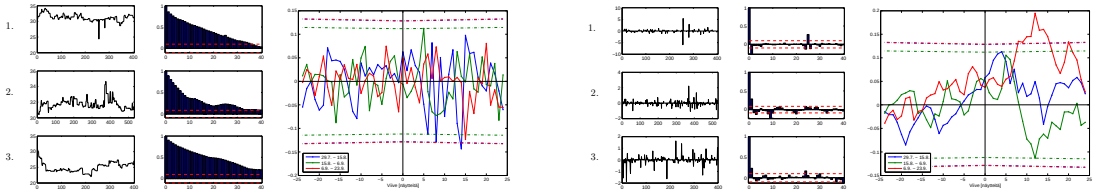

(a) (b) (c) (d)

Signaali 10. EVA keittimeen (VK1-FC003)

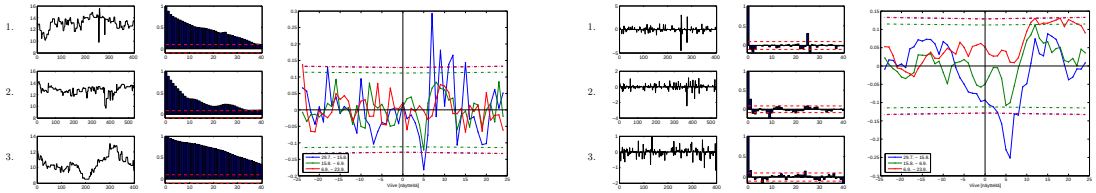

(a) (b) (c) (d)

Signaali 11. kuitusuotimen rejektivirtaus keittimeen(VK1-FC074)

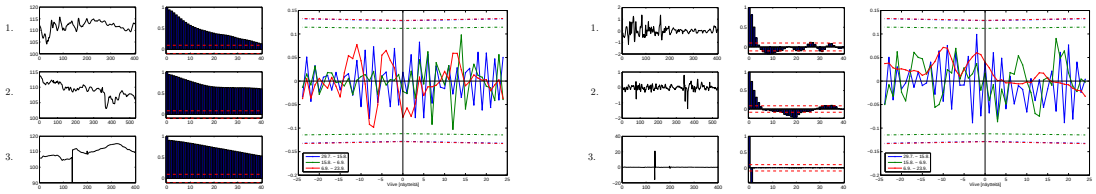

(a) (b) (c) (d)

Signaali 12. valkolipeän väkevyys (VK3-QI007)

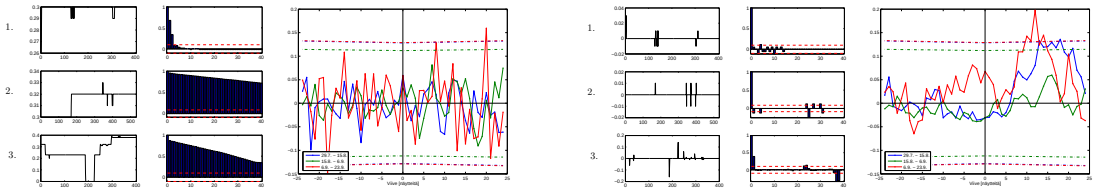

(a) (b) (c) (d)

Signaali 13. HMP hakesiiloon (VK1-FI042)

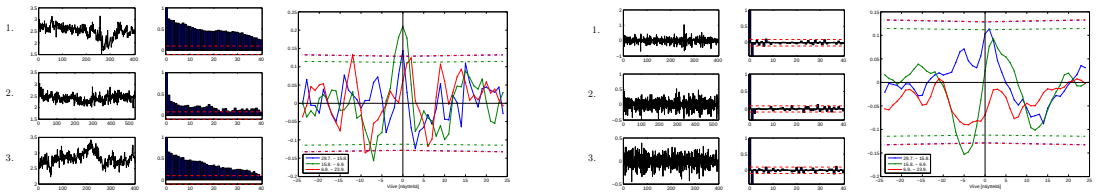

(a) (b) (c) (d)

Signaali 14. HMP keittämölle (VK1-FI001)

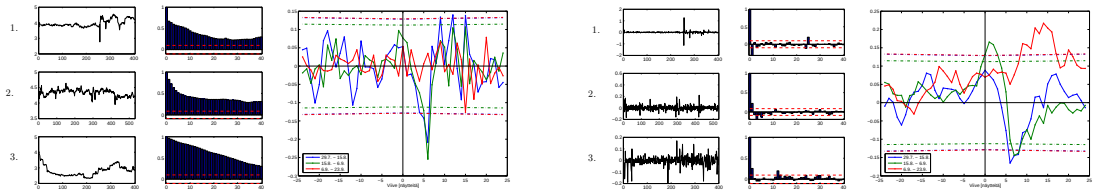

(a) (b) (c) (d)

Signaali 15. HKP keittimeen (VK1-FC027)

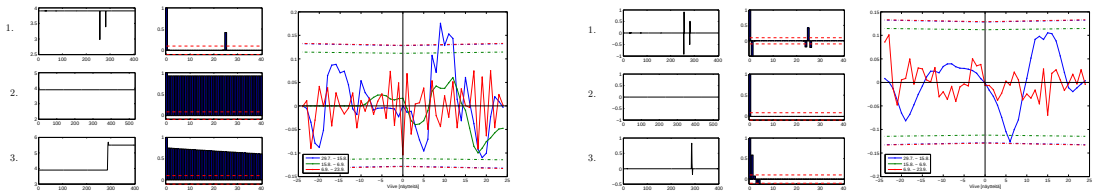

(a) (b) (c) (d)

Signaali 16. huuhtelulipeä korkeapainekiikkiin (VK1-FC028)

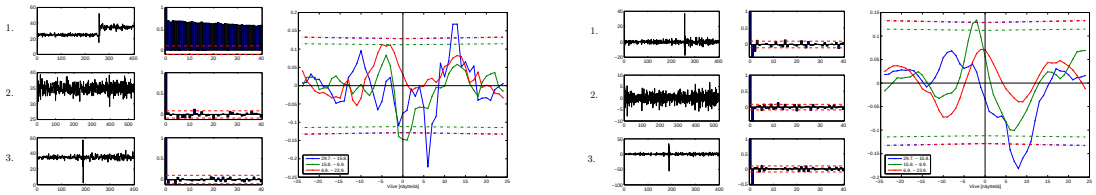

(a) (b) (c) (d)

Signaali 17. imeytystornin hakepinnankorkeus (VK1-LI090)

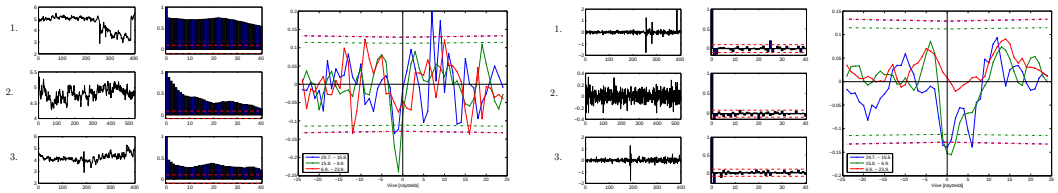

(a) (b) (c) (d)

Signaali 18. imeytystornin pohjakaavarin pyörimisnopeus (VK1-SC005)

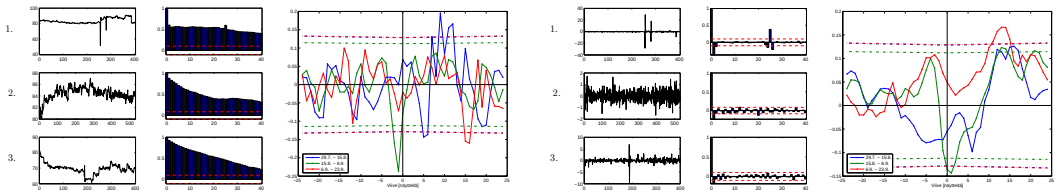

(a) (b) (c) (d)

Signaali 19. imeytystornin pohjalaimennus (VK1-FC015)

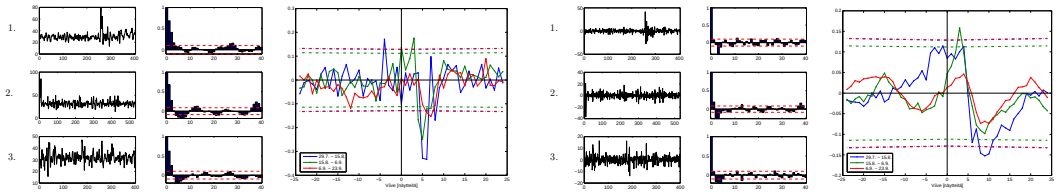

(a) (b) (c) (d)

Signaali 20. keittimen hakepinnankorkeus (VK1-LI044)

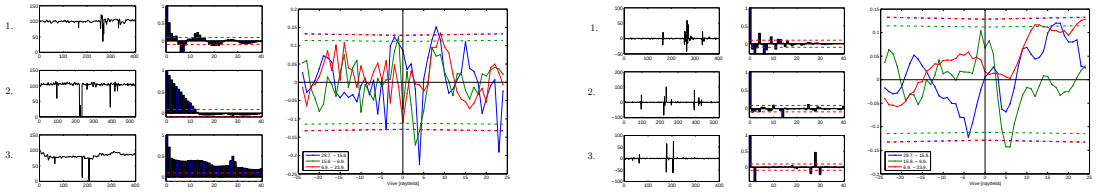

(a) (b) (c) (d)

Signaali 21. puskuvirtaus keittimestä, linja 1 (VK1-FC009)

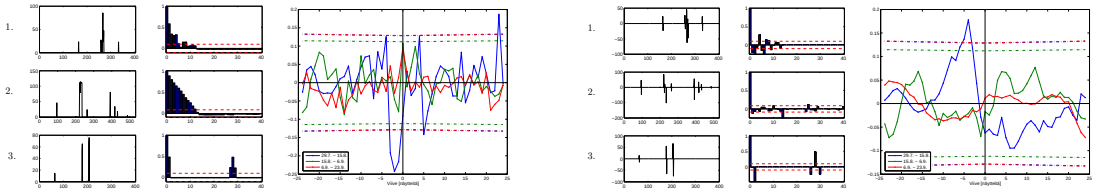

(a) (b) (c) (d)

Signaali 22. puskuvirtaus keittimestä, linja 2 (VK1-FC010)

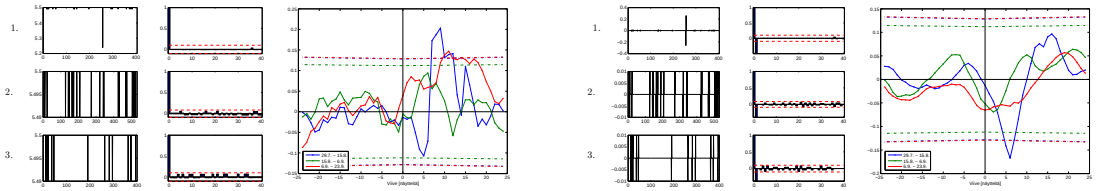

(a) (b) (c) (d)

Signaali 23. keittimen pohjakaavarin pyörimisnopeus (VK1-SC006)

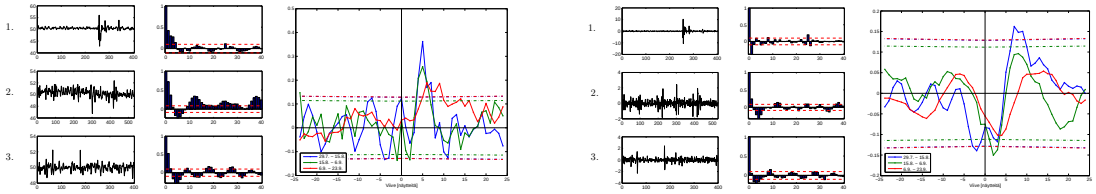

(a) (b) (c) (d)

Signaali 24. keittimen lipeäpinnankorkeus (VK1-LI011)

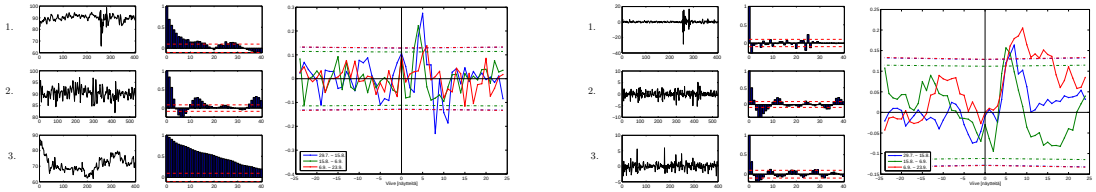

(a) (b) (c) (d)

Signaali 25. yläpaisuntavirtaus (VK1-FC021)

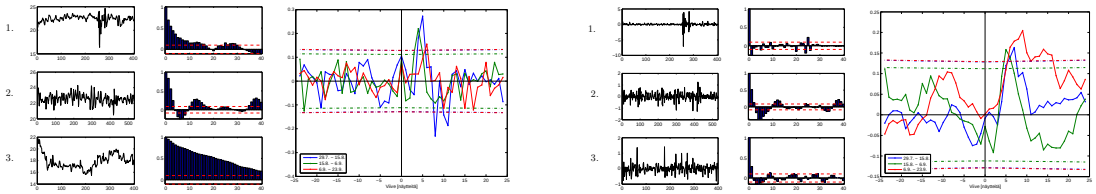

(a) (b) (c) (d)

Signaali 26. alapaisuntavirtaus (VK1-FC022)

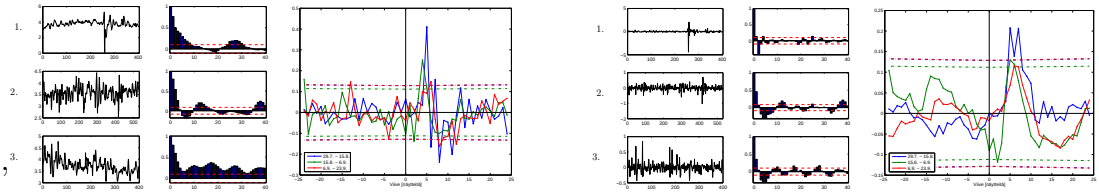

(a) (b) (c) (d)

Signaali 27. pesukerroin (KL2 MMI1DIGDILF.MES)

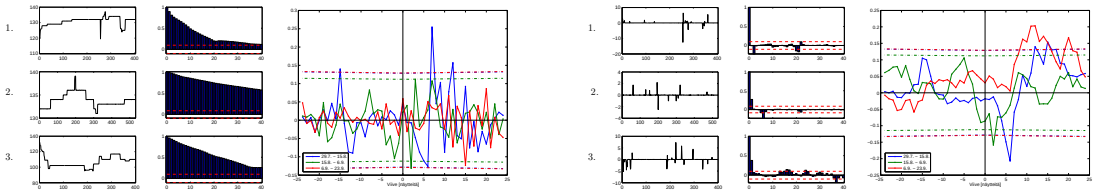

(a) (b) (c) (d)

Signaali 28. pesulipeävirtaus keittimeen (VK1-FC006)

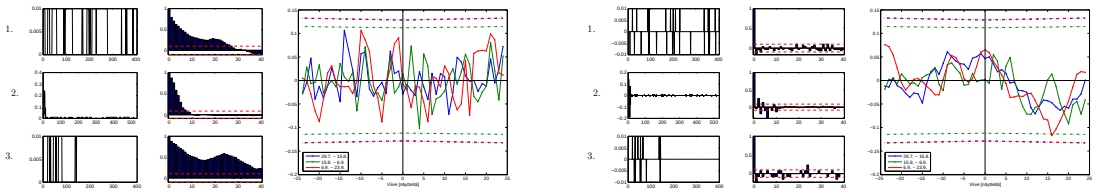

(a) (b) (c) (d)

Signaali 29. puskulaimennusvirtaus (VK1-FC075)

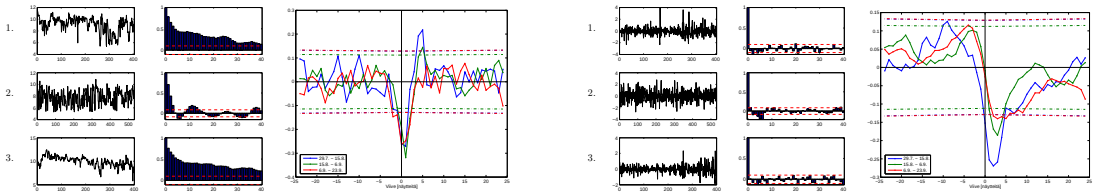

(a) (b) (c) (d)

Signaali 30. ACS:n laskema puskusakeus (KL2 MM1BLOCON.MES)

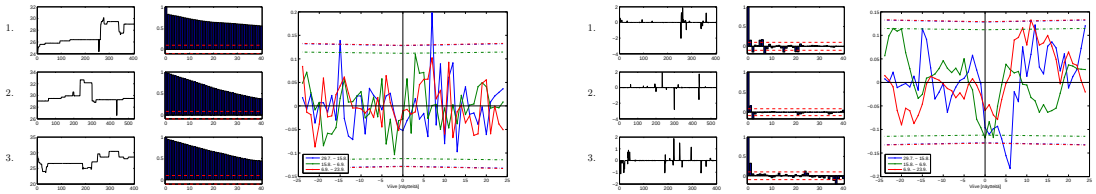

(a) (b) (c) (d)

Signaali 31. keittimen pohjalaimennusvirtaus (VK1-FC020)

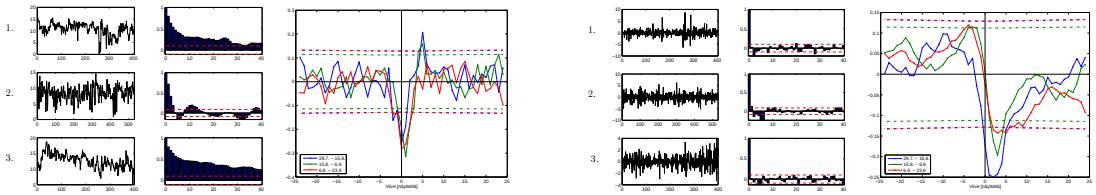

(a) (b) (c) (d)

Signaali 32. keittimen puskun paine-ero (VK1-PD069)

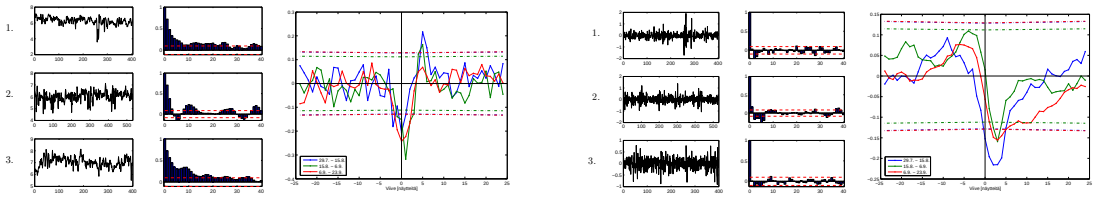

(a) (b) (c) (d)

Signaali 33. keittimen pohjakaavarin hydrauliikan paine (VK1-PC124)

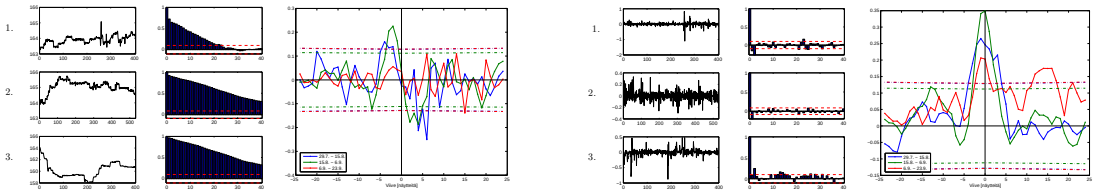

(a) (b) (c) (d)

Signaali 34. keittimen höyrytilan lämpötila (VK1-TC010)

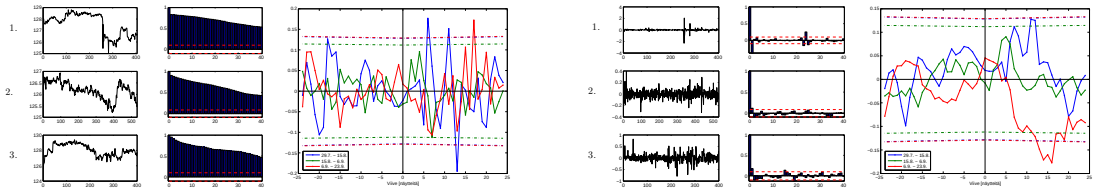

(a) (b) (c) (d)

Signaali 35. keittimen syöttökierron lämpötila (VK1-TI007)

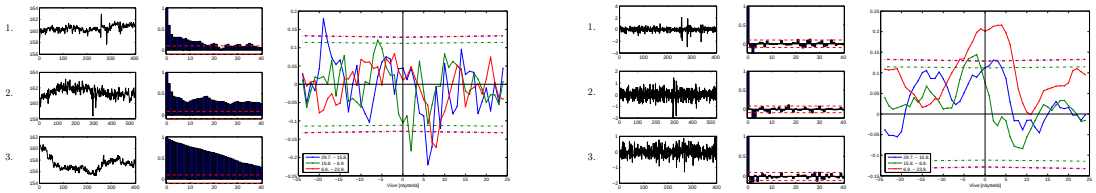

(a) (b) (c) (d)

Signaali 36. keittovyöhykkeen lämpötila (VK1-TI011)

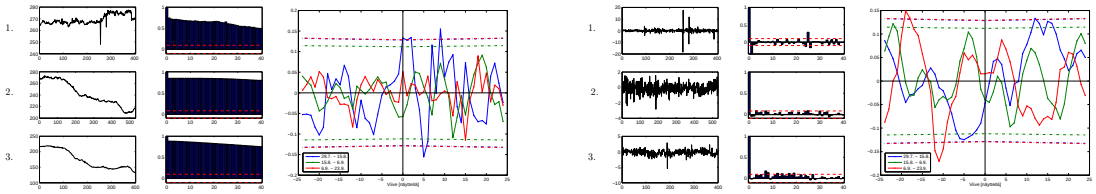

(a) (b) (c) (d)

Signaali 37. keittimen syöttökierron virtaus (VK1-FI018)

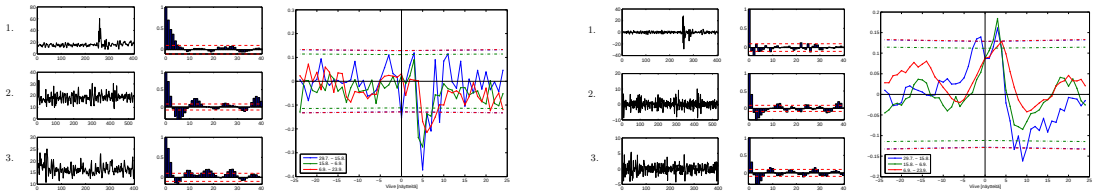

(a) (b) (c) (d)

Signaali 38. höyryfaasin H-tekijä (KL2 MM1KAPPA.HFU)

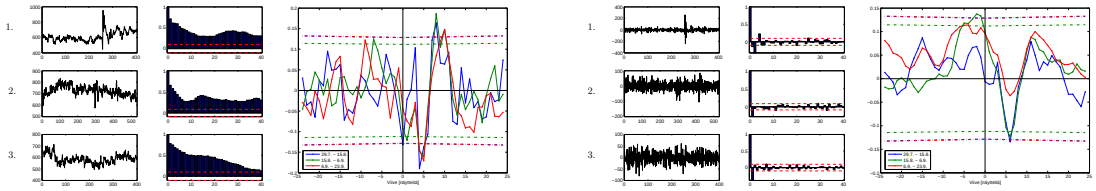

(a) (b) (c) (d)

Signaali 39. nestefaasin H-tekijä (KL2 MM1KAPPA.HFL)

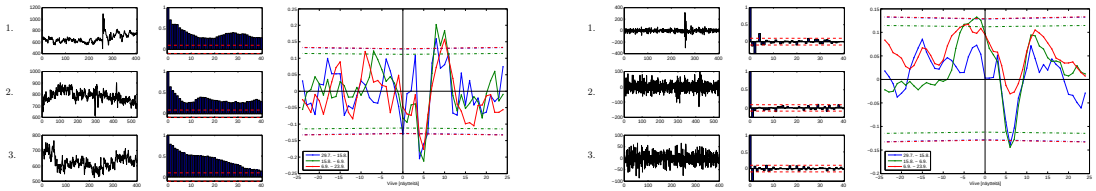

(a) (b) (c) (d)

Signaali 40. kokonais-H-tekijä (KL2 MM1KAPPA.HFT)

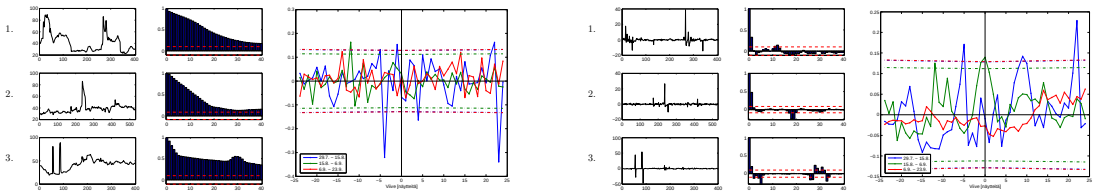

(a) (b) (c) (d)

Signaali 41. suodoksen johtokyky saostimelta 3 (LA1-QI013)

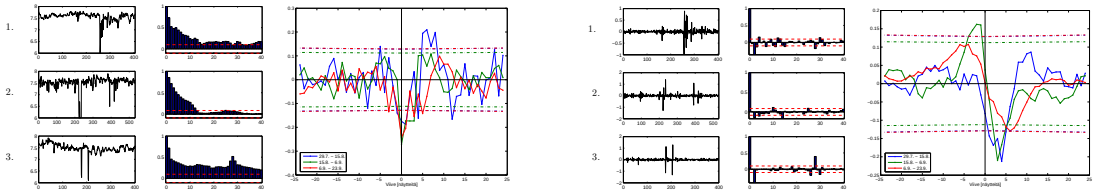

(a) (b) (c) (d)

Signaali 42. puskulinjan 1 sakeus (VK1-QI003)

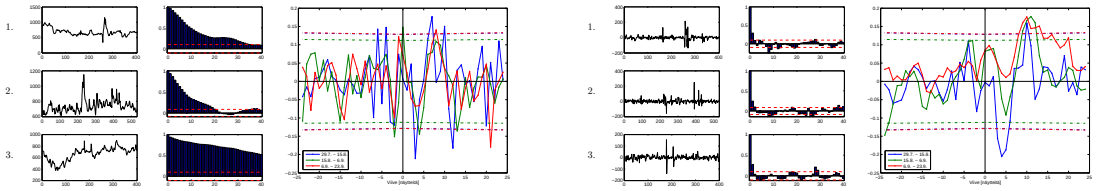

(a) (b) (c) (d)

Signaali 43. vuopesurilta tulevan pesulipeän johtokyky (VK1-QI101)

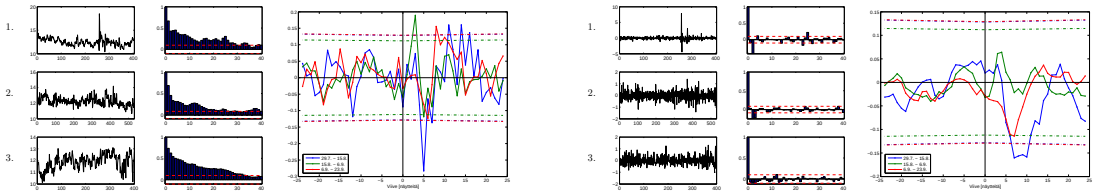

(a) (b) (c) (d)

Signaali 44. yläpaisunnan jäännösalkalipitoisuus (VK1-041)

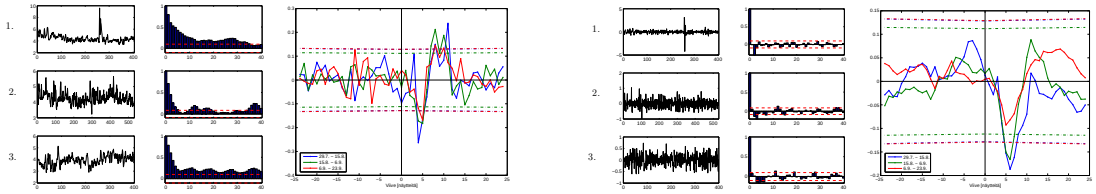

(a) (b) (c) (d)

Signaali 45. alapaisunnan jäännösalkalipitoisuus (VK1-045)

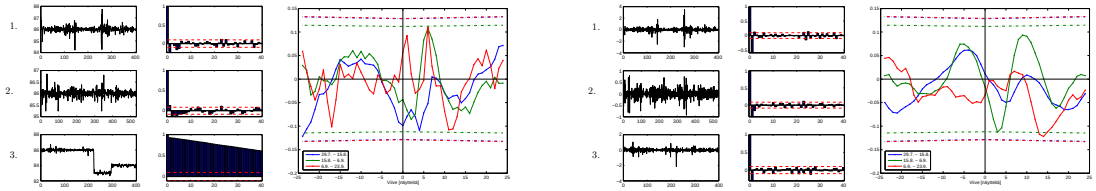

(a) (b) (c) (d)

Signaali 46. EMU haihduttamolle lämpötila (VK1-TC024)

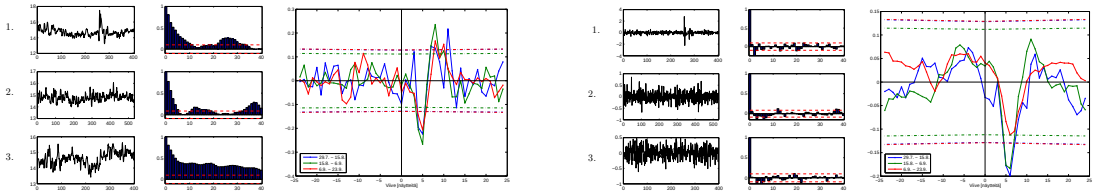

(a) (b) (c) (d)

Signaali 47. EMU haihduttamolle kuiva-ainepitoisuus (VK1-QI023)

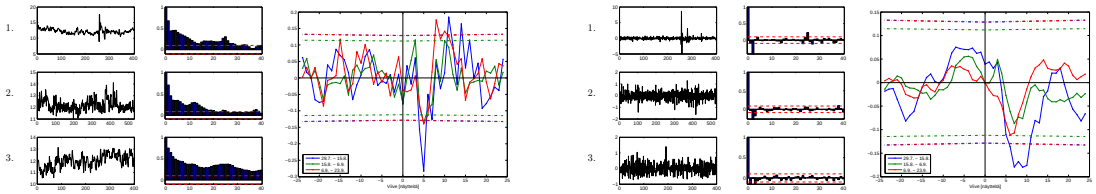

(a) (b) (c) (d)

Signaali 48. EMU haihduttamolle jäännösalkalipitoisuus (VK1-QI021)

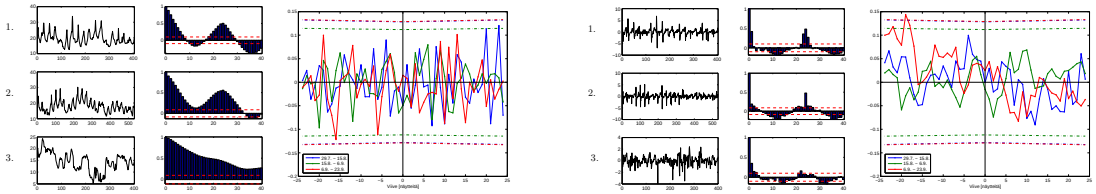

(a) (b) (c) (d)

Signaali 49. ulkolämpötila (VKA-TI408)

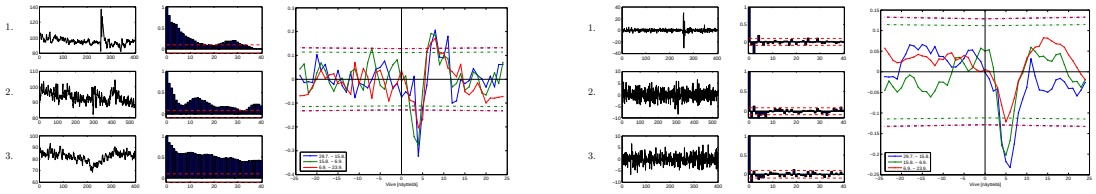

(a) (b) (c) (d)

Signaali 50. alapaisunnan lämpötila (VK1-TI076)

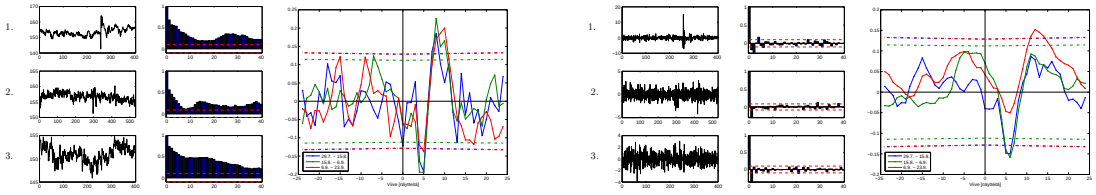

(a) (b) (c) (d)

Signaali 51. yläpaisunnan lämpötila (VK1-TI014)

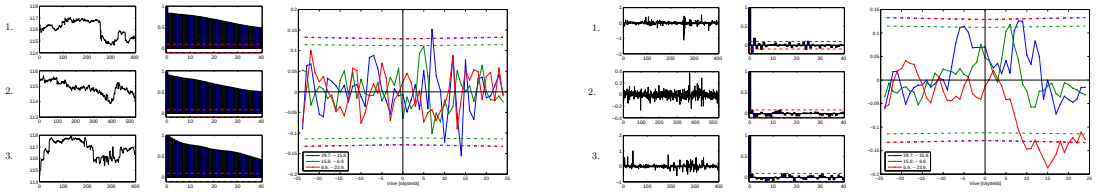

(a) (b) (c) (d)

Signaali 52. imeytystornin syöttökierron lämpötila (VK1-TC005)

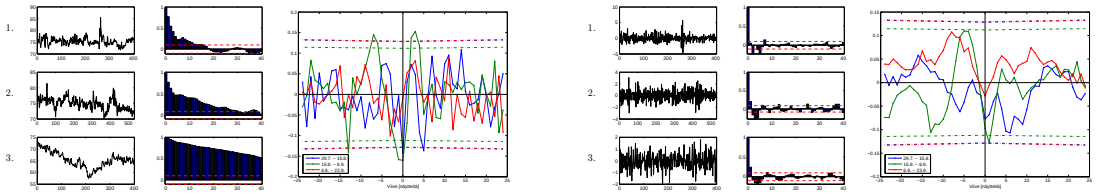

(a) (b) (c) (d)

Signaali 53. keittimen pesukierron lämpötila ennen kalorisaattoria (VK1-TI013)

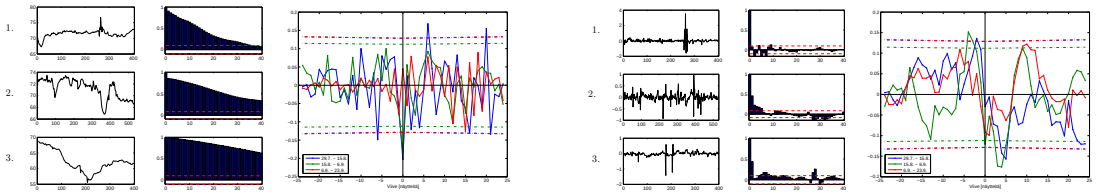

(a) (b) (c) (d)

Signaali 54. puskuputken lämpötila (VK1-TC016)

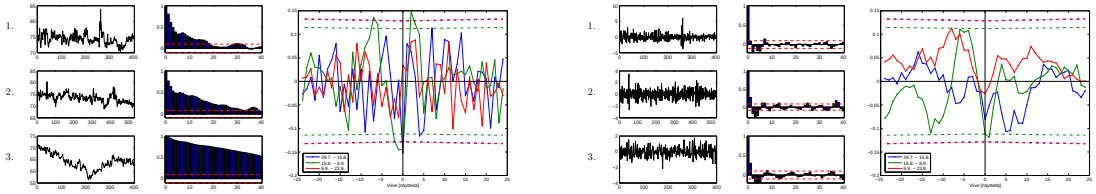

(a) (b) (c) (d)

Signaali 55. pesukierron lämpötila kalorisaattorin jälkeen (VK1-TC080)

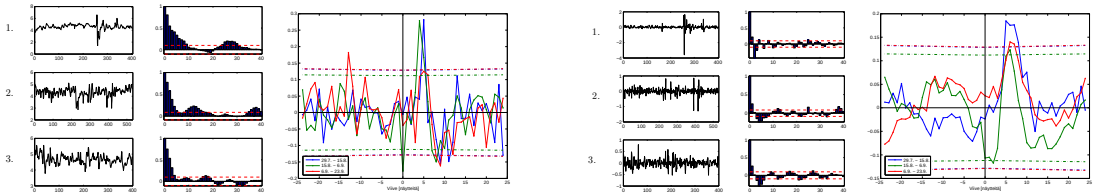

(a) (b) (c) (d)

Signaali 56. EPE vuopesurilta (VK1-XF102)

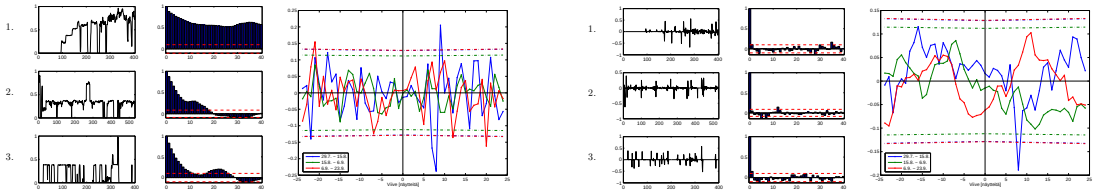

(a) (b) (c) (d)

Signaali 57. ostohakkeen osuus kokonaishakemäärästä

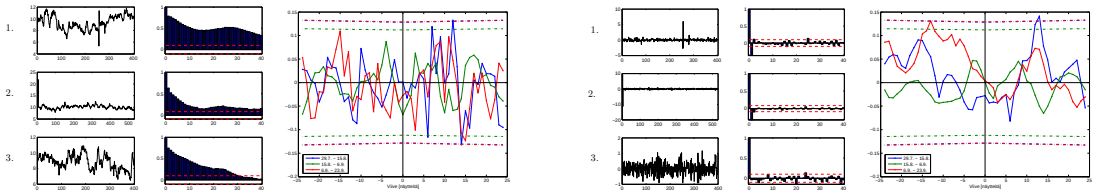

(a) (b) (c) (d)

Signaali 58. imeytystornin hakepinnankorkeus (VK1-LI008)

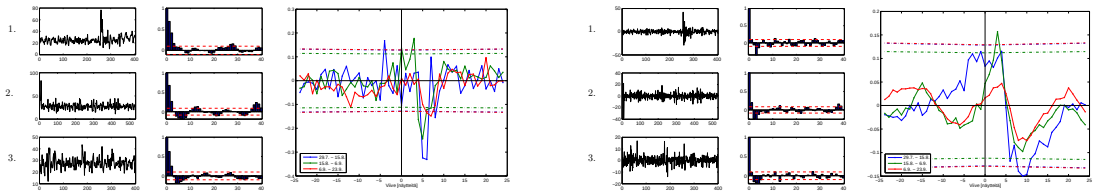

(a) (b) (c) (d)

Signaali 59. keittimen hakepinnankorkeus (VK1-LI043)

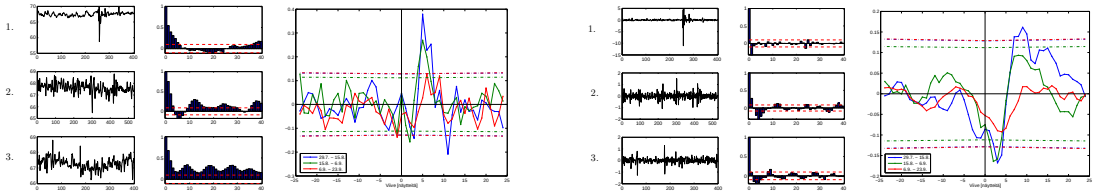

(a) (b) (c) (d)

Signaali 60. keittimen kokonaispinta (VK1-LI014)

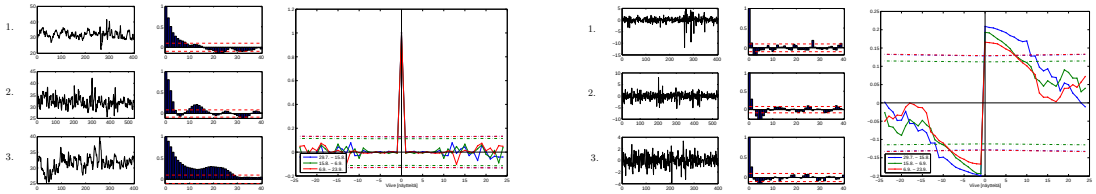

(a) (b) (c) (d)

Signaali 61. molemmista puskulinjoista yhdistetty kappaluku (VK1-XC009)

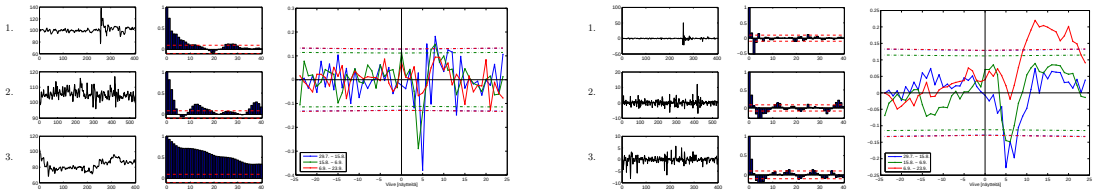

(a) (b) (c) (d)

Signaali 62. kokonaispuskuvirtaus (VK1-FC009 + VK1-FC010)

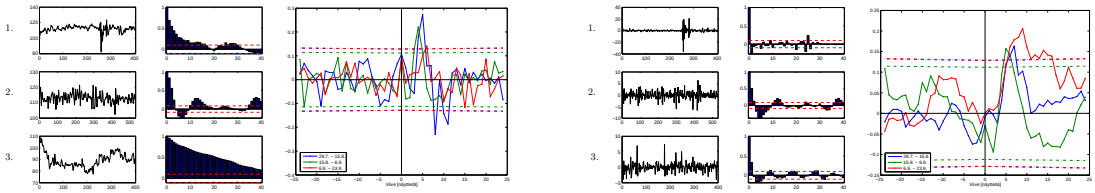

(a) (b) (c) (d)

Signaali 63. kokonaispaisuntavirtaus (VK1-FC021 + VK1-FC022)

Liite 2. Hakepinnankorkeuden minimivarianssianalyysin kuvat

Seuraavissa kuvissa esitetään minimivarianssianalyysin tuloksena syntyneet a) suljetun systeemin impulssivasteet, b) tehospektriestimaatit ja c) identifioidun mallin residuaalien autokorrelaatiot. Kuvien numerointi on sama kuin taulukossa (4.8).

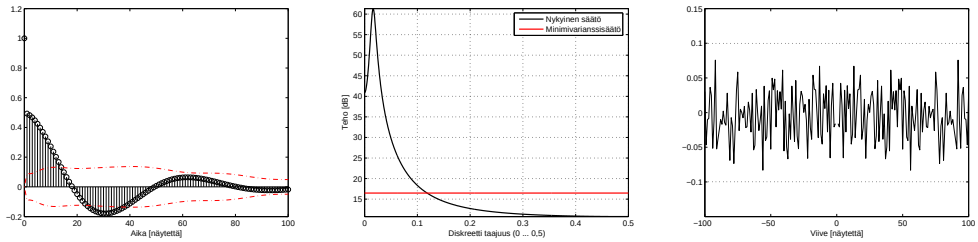

(a) (b) (c)

Jakso 1.

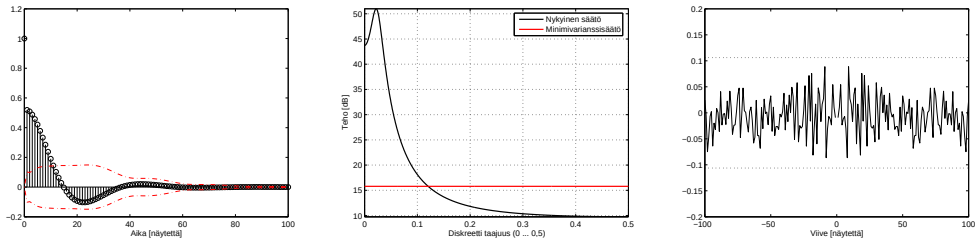

(a) (b) (c)

Jakso 2.

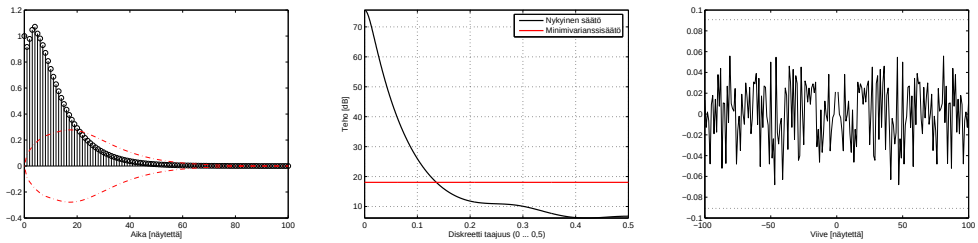

(a) (b) (c)

Jakso 3.

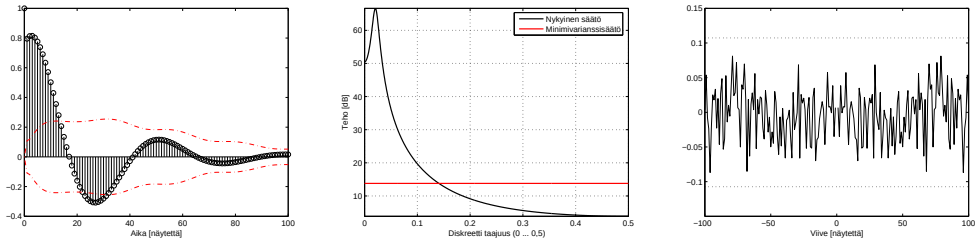

(a) (b) (c)

Jakso 4.

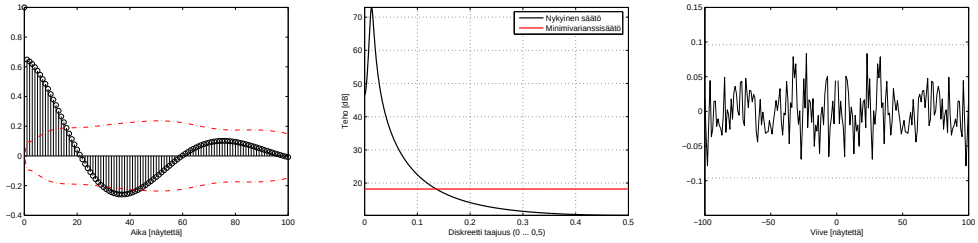

(a) (b) (c)

Jakso 5.

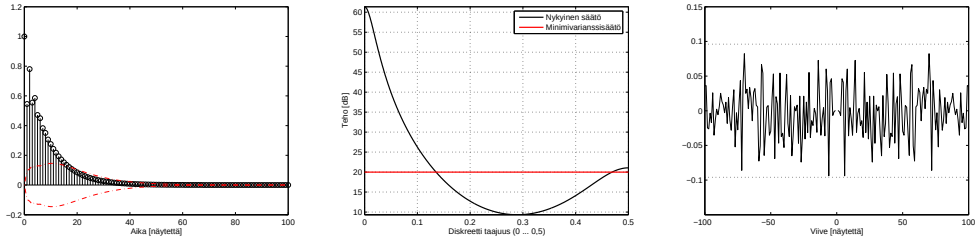

(a) (b) (c)

Jakso 6.

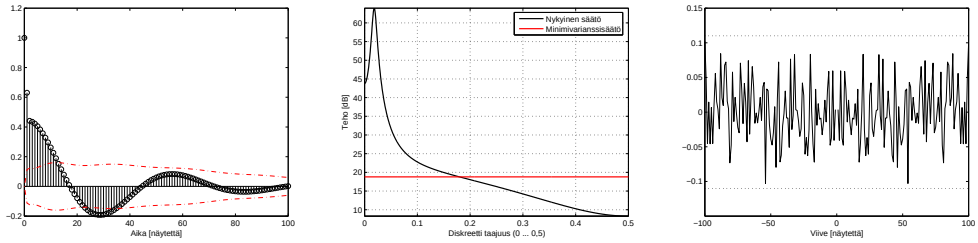

(a) (b) (c)

Jakso 7.

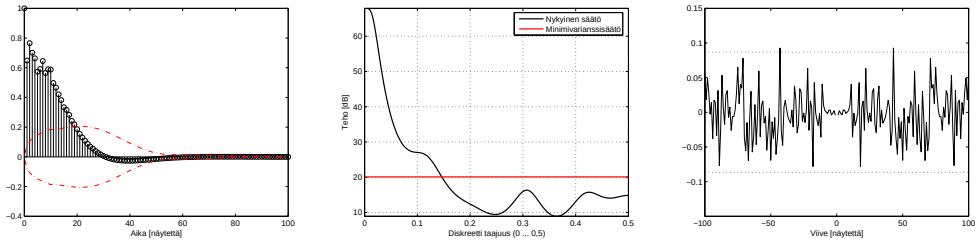

(a) (b) (c)

Jakso 8.

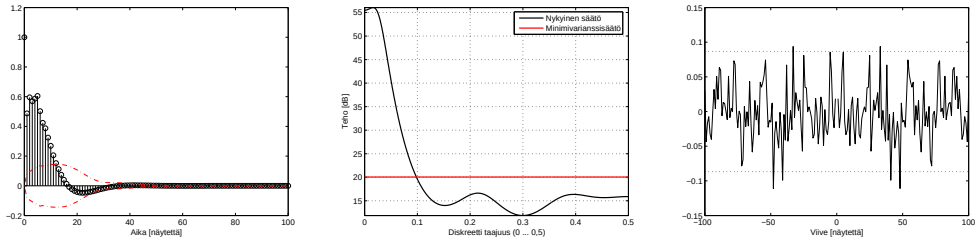

(a) (b) (c)

Jakso 9.

Liite 3. Normalisoituja impulssivasteita hakepinnan korkeuteen

Tässä liitteessä esitetään eri signaalien vaikutus keittimen hakepinnankorkeuteen estimoitujen normalisoitujen impulssivasteiden avulla. Kussakin kuvassa on kyseinen impulssivaste seitsemältä ajanjaksolta, jotta voitaisiin paremmin todeta vuorovaikutuksen olemassaolo.

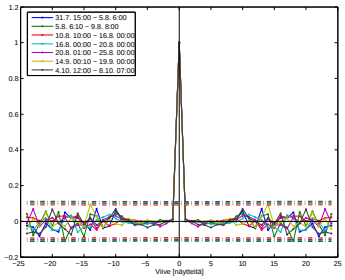

Kuva 1. keittimen hakepinnan korkeus (VK1-LI044)

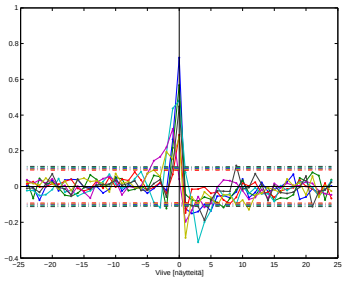

Kuva 2. kokonaispuskuvirtaus keittimestä (VK1-FC009 + VK1-FC010)

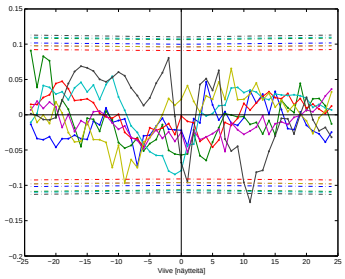

Kuva 3. keittimen pohjakaavarin pyörimisnopeus (VK1-SC006)

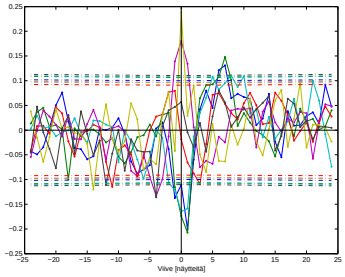

Kuva 4. kokonaispaisuntavirtaus (VK1-FC021 + VK1-FC022)

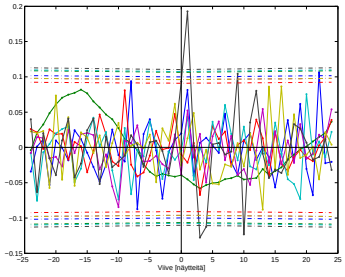

Kuva 5. pesulipeävirtaus keittimeen (VK1-FC006)

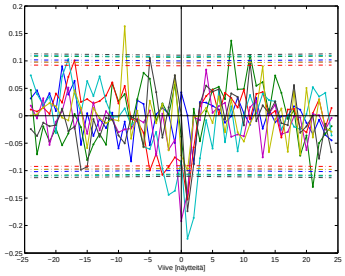

Kuva 6. puskusakeus, linja 1 (VK1-QI003)

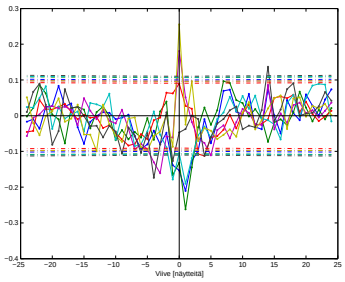

Kuva 7. keittimen lipeäpinnankorkeus (VK1-LI011)

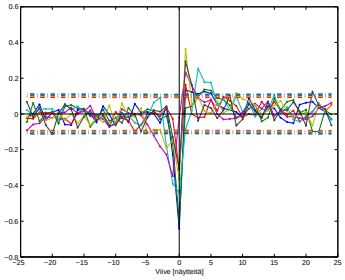

Kuva 8. pesukerroin (KL2 MM1DIGDILF.MES)

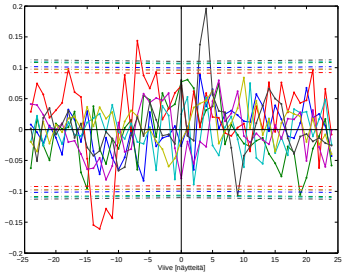

Kuva 9. puskulaimennusvirtaus (VK1-FC075)

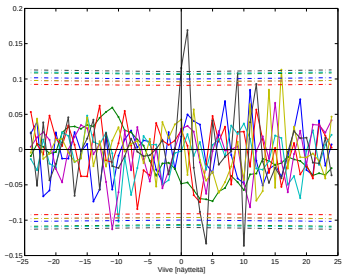

Kuva 10. keittimen pohjalaimennus (VK1-FC020)

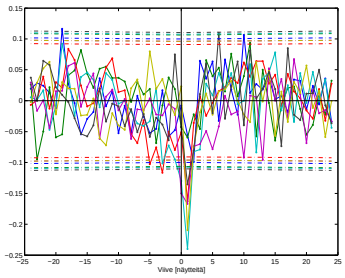

Kuva 11. keittimen puskun paine-ero (VK1-PD069)

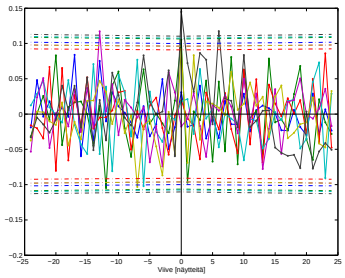

Kuva 12. keittimen yläpaisunnan paine-ero (VK1-PD095)

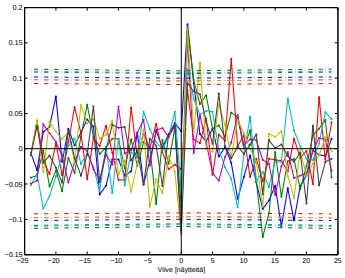

Kuva 13. imeytystornin pohjakaavarin pyörimisnopeus (VK1-SC005)

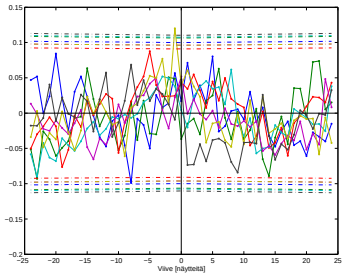

Kuva 14. imeytystornin pohjakaavarin hydrauliikan paine (VK1-PI166)

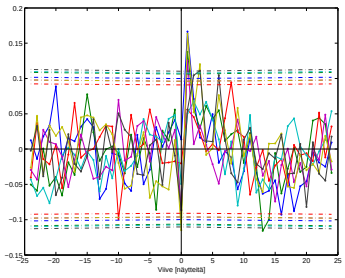

Kuva 15. imeytystornin pohjakaavarin pyörimisnopeus (VK1-SC005) × hydrauliikan paine (VK1-PI166)

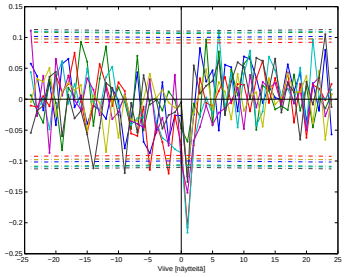

Kuva 16. keittimen pohjakaavarin hydrauliikan paine (VK1-PC124)

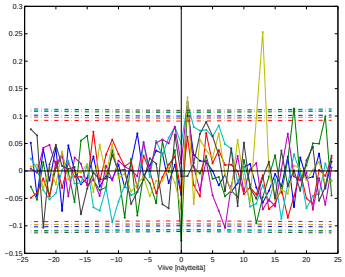

Kuva 17. keittimen syöttökierron virtaus (VK1-FI018)

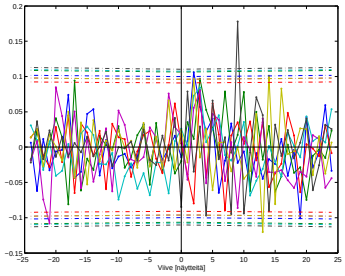

Kuva 18. hakeruuvin pyörimisnopeus (VK1-SC003)

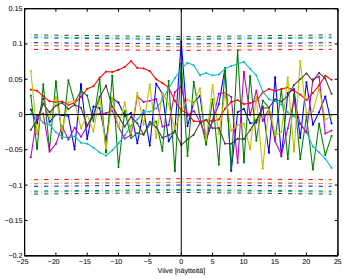

Kuva 19. korkeapainekiikin pyörimisnopeus (VK1-SC004)

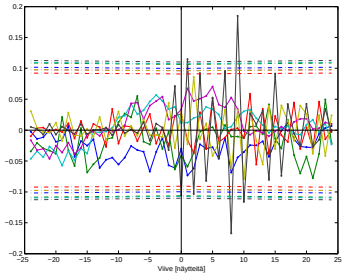

Kuva 20. tuotantonopeus (MM1PRORATE.MES)

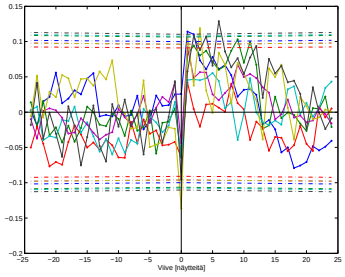

Kuva 21. imeytystornin hakepinnankorkeus (VK1-LI090)

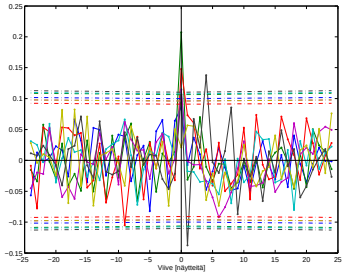

Kuva 22. hakeruuvin täyttöaste (VK1-FI017)

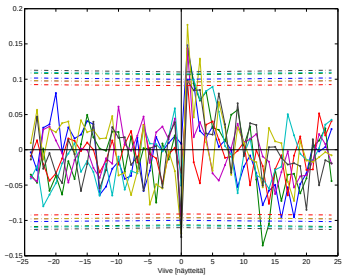

Kuva 23. imeytystornin pohjalaimennusvirtaus (VK1- FC015)

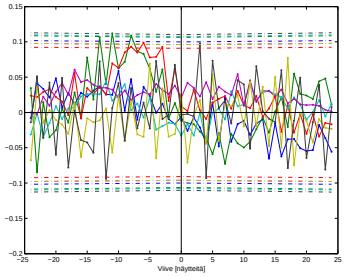

Kuva 24. hakesiilon pinnankorkeus (VK1-LC007)

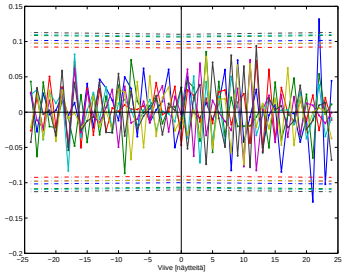

Kuva 25. hakesiilon paino (VK1-WC003)

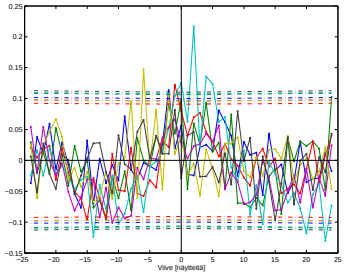

Kuva 26. yläpaisunnan jäännösalkalipitoisuus (VK1-QI041)

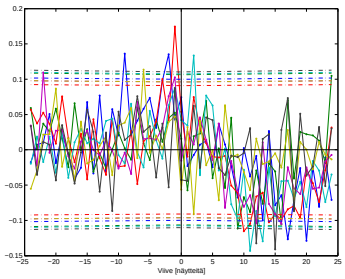

Kuva 27. haihduttamolle menevän mustalipeän kuiva-ainepitoisuus (VK1-QI023)