



TEKNILLINEN TIEDEKUNTA

Soft sensorit paperi- ja selluteollisuudessa

Roosa Kolehmainen

Prosessitekniikka

Kandidaatintyö

Heinäkuu 2021

TIIVISTELMÄ

Soft sensorit paperi- ja selluteollisuudessa

Roosa Kolehmainen

Oulun yliopisto, Prosessitekniiikan tutkinto-ohjelma

Kandidaatintyö 2021, 27 s.

Työn ohjaajat yliopistolla: TkT Aki Sorsa, TkT Jari Ruuska

Työn tarkoituksena on tutustua soft sensoreiden perusteisiin sekä niiden yleisiin käyttökohteisiin prosessiteollisuudessa ja erityisesti tutkitaan mahdollisuuksia paperi- ja selluteollisuudessa. Tavoitteena on hahmottaa erilaisten soft sensoreiden hyötyjä ja haasteita. Soft sensorit voidaan muodostaa kolmella tavalla: datapohjaisesti, ilmiöpohjaisesti tai näitä yhdistelemällä. Pääosin työ painottuu datapohjaisten soft sensoreiden tarkasteluun niiden yleisyyden vuoksi. Eri soft sensor -malleissa on omat hyötynsä ja haasteensa. Ilmiöpohjaisissa malleissa haasteena on niiden monimutkaisuus ja datapohjaisissa malleissa puolestaan datan laadun varmistaminen. Yleisimpiä käyttökohteita soft sensoreille prosessiteollisuudessa ovat esimerkiksi laatuominaisuuksien ennustaminen, prosessimuuttujien estimointi, prosessimuutosten havainnointi ja prosessin seuranta sekä mittausarvon korjaaminen. Jotta kehitetyt soft sensor -mallit tuottavat luotettavaa arviota prosessista, niitä täytyy ylläpitää. Mallin päivittäminen tasaisin väliajoin on siis erittäin tärkeää. Sellu- ja paperiteollisuudessa soft sensoreita käytetään useissa sovelluskohteissa. Erityisesti laatuominaisuuksiin vaikuttavien tekijöiden reaaliaikainen estimointi ja valmiin tuotteen laadun ennustaminen ovat tärkeitä soft sensorin käyttökohteita. Työssä esitettyjen tutkimusten perusteella soft sensor -malleja muodostettaessa käytetään pääosin datapohjaista mallinnusta, sillä puhtaasti ilmiöpohjaista mallinnusta käytäviä tutkimuksia ei tähän työhön löydetty. Sellu- ja paperiteollisuudesta löytyy useita muuttujia, joista ei yleensä ole saatavilla reaaliaikaista mittausta. Lisäksi paperin laatuominaisuuksia mitataan usein vasta valmiista tuotteesta, jolloin mahdollinen poikkeama prosessissa on edennyt jo tuotteeseen asti. Tällaisiin ongelmiin voidaan löytää ratkaisu soft sensor -teknologialla. Työn lopussa esitetään katsaus valmiista kaupallisista ratkaisuista ja soft sensor -työkaluista.

Asiasanat: soft sensori, selluteollisuus, paperiteollisuus

ALKUSANAT

Tämä kandidaatintyö on tehty yhteistyössä ABB:n kanssa. Työn tarkoituksena oli selvittää soft sensorien yleistä teoriaa ja teknologiaa, sekä esitellä niiden yleisimpiä käyttökohteita prosessiteollisuudessa. Tarkastelun kohteeksi otettiin erityisesti käyttö paperi- ja selluteollisuudessa.

Haluan osoittaa kiitokset ABB:lle mahdollisuudesta kandidaatintyön tekemiseen sekä työn ohjaajia avusta ja tsemppaamisesta. Työn ohjaajina toimi Aki Sorsa ja Jari Ruuska yliopiston puolelta sekä Kimmo Kaasinen ja Juha Alamäki ABB:n puolelta.

Helsinki, 14.07.2021

Roosa Kolehmainen

SISÄLLYSLUETTELO

TIIVISTELMÄ

ALKUSANAT

SISÄLLYSLUETTELO

1 Johdanto	4
2 Erilaiset soft sensorit	5
2.1 Soft sensoreiden toimintaperiaatteet	5
2.2 Datapohjaiset soft sensorit	6
2.3 Ilmiöpohjaiset soft sensorit	8
2.4 Grey-box- soft sensorit.....	9
2.5 Mallinnustekniikoita havainnollistava esimerkki	10
2.6 Soft sensoreiden hyödyt ja haasteet	11
3 Soft sensoreiden käyttö prosessiteollisuudessa	12
3.1 Käyttökohteet	12
3.2 Soft sensoreiden ylläpito	13
4 Käyttökohteet sellu- ja paperiteollisuudessa	14
4.1 Soft sensorit sellun valmistuksessa	14
4.2 Soft sensorit paperin- ja kartongin valmistuksessa	16
4.3 Kaupallinen tarjonta	20
5 Pohdinta	22
6 Yhteenveto	24

LÄHDELUETTELO

1 JOHDANTO

Tämän työn aiheena on soft sensoreiden hyödyntäminen prosessiteollisuudessa. Työssä tarkastellaan erityisesti paperi- ja selluteollisuudessa esiintyviä mahdollisia käyttökohteita. Työ on kirjallisuustutkielma ja siinä on hyödynnetty erilaisia tutkimuksia sekä ABB:n tietämystä asiasta. Työn tavoitteena on perehtyä yleisesti soft sensoreiden teoriaan ja selvittää mallien muodostamisen sekä ylläpidon periaatteita. Tavoitteena on lisäksi esitellä prosessiteollisuudesta löytyviä ongelmia ja haasteita, joita voidaan ratkoa soft sensoreiden avulla. Pääpaino on paperi- ja selluteollisuuden soft sensor -ratkaisujen tutkimisessa.

Soft sensoreiden tuottaman virtuaalisen ja ennustavan mittauksen avulla voidaan saada tietoa niistä prosessimuuttujista, joista ei ole saatavilla reaaliaikaista mittausta. Reaaliaikaisen mittauksen puutteeseen voi olla monia eri syitä. Varsinkin valmiin tuotteen laadun ja laatuun voimakkaasti vaikuttavien suureiden arvioiminen on tärkeää. Kun tuotantolaitokselta saadaan tehokkaasti laatuominaisuuksiltaan hyvää tuotetta, säästetään aikaa ja ympäristöä sekä pienennetään kustannuksia.

Virtuaalisen mittauksen isona etuna on sen lähes rajattomat käyttömahdollisuudet ja pienet kustannukset fyysiseen mittariin verrattuna. Erilaisia soft sensor -mallien muodostustapoja on kolme. Näiden avulla pystytään kehittämään juuri tiettyihin haluttuihin kohteisiin räätälöityjä malleja.

Paperi- ja selluteollisuudessa on runsaasti potentiaalisia soft sensoreiden sovelluskohteita. Vaadittavia laatuominaisuuksia on erilaisia, riippuen aina valmistettavasta tuotteesta.

2 ERILAISET SOFT SENSORIT

Soft sensorit ovat ennustavia malleja, joiden avulla voidaan arvioida ja ennustaa halutun prosessimuuttujan mittausarvoa ilman fyysistä anturia. Mallit rakennetaan prosessista saadun suuren datamäärän ja/tai prosessin teoreettisen taustan pohjalta. Käsite soft sensor muodostuu sanasta ”software” (ohjelmisto), sillä yleensä mallit ovat tietokoneohjelmia, sekä sanasta ”sensor” (sensori, anturi), sillä mallin tarkoitus on tuottaa samaa informaatiota kuin fyysiset anturit tuottaisivat. Muita yleisesti käytettyjä nimityksiä soft sensorille ovat esimerkiksi virtuaalinen sensori (virtual sensor) ja johdettu sensori (inferential sensor), mutta tässä työssä käytetään virtuaaliselle mittaukselle termiä soft sensor. (Kadlec *et al.* 2009)

Teollisuudessa suurena haasteena on tiettyjen tärkeiden prosessimuuttujien sekä valmiin tuotteen laatuominaisuuksien reaaliaikainen mittaaminen. Joko näitä on mahdotonta mitata fyysisellä anturilla, määrittäminen onnistuu vain pitkällä näytteenottovälillä, tarvittavaa analysointia ei ole olemassa markkinoilla tai perinteisten mittareiden käyttö on taloudellisesti kannattamatonta suurien käyttö- ja ylläpitokustannusten vuoksi. Fyysisen anturin käyttö voi olla mahdotonta esimerkiksi vaikeiden prosessiolosuhteiden vuoksi, jolloin anturia ei voida asentaa tiettyyn paikkaan eikä se myöskään kestäisi siellä (hyvin korkean lämpötilan paikat, pölyiset ja likaiset tilat, korkea paine tai vahvat kemikaalit). Reaaliaikaisen mittauksen puute kriittisestä prosessimuuttujasta voi johtaa siihen, että lopputuote ei vastaa sille asetettuja laatuvaatimuksia. Soft sensorin tarkoitus on tuottaa matemaattisten mallien ja helposti mitattavien prosessisuureiden avulla tarkkoja arvioita näistä kriittisistä muuttujista, joista ei ole saatavilla reaaliaikaista mittausta prosessista. (Amazouz *et al.* 2005), (Sarimveis 2001)

2.1 Soft sensoreiden toimintaperiaatteet

Yleisesti soft sensorit voidaan jaotella kahteen eri tyyppiin niiden mallinnustavan mukaisesti – datapohjaisiin soft sensoreihin, joista puhutaan myös black-box-malleina sekä ilmiöpohjaisiin soft sensoreihin, joita puolestaan kutsutaan white-box-malleiksi. Näiden kahden lisäksi on myös käytössä niin sanottu grey-box-malli, joka yhdistelee ominaisuuksia kahdesta edellä mainitusta soft sensor -tyypistä. (Ahmad *et al.* 2020)

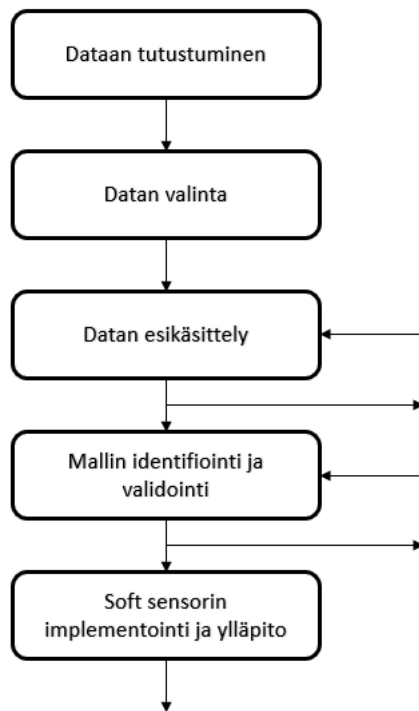
2.2 Datapohjaiset soft sensorit

Datapohjaiset (black-box) mallit perustuvat tuotantolaitokselta mitattuun dataan. Black-box-mallit pystyvät kuvaamaan monimutkaisia prosesseja, jotka ovat ilmiöpohjaisille malleille (white-box) vaikeita käsitellä. Termi black-box viittaa siihen, että kartoitetaan tulo- ja lähtösuureiden välisiä riippuvuuksia datasta eikä sen matemaattinen rakenne välttämättä perustu prosessin teoreettisiin ominaisuuksiin. (Ahmad *et al.* 2019), (Kadlec *et al.* 2009)

Black-box mallin tietämättömyyttä prosessin biologisista, fysikaalisista ja kemiallisista taustoista voidaan pitää heikkoutena, mutta se myös antaa mahdollisuuden mallintaa haluttua prosessia ilman syvempää tietämystä taustalla olevasta prosessidynamiikasta. (Kadlec *et al.* 2008)

Kadlec *et al.* (2008) mukaan voidaan ajatella, että datapohjaiset soft sensorit perustuvat paremmin todellisuuteen ja kuvaavat prosessien olosuhteita realistisemmin verrattuna ilmiöpohjaisiin soft sensoreihin. Koska datapohjaiset mallit ymmärtävät paremmin todellisia olosuhteita prosessille, niiden paikkansapitävyyttä voidaan pitää luotettavampana. Datapohjaisia malleja onkin hyödynnetty prosessiteollisuudessa huomattavasti enemmän. (Ahmad *et al.* 2020)


Abonyi *et al.* (2014) esittävät tutkimuksessaan tärkeimmät datapohjaisen mallin muodostusvaiheet. Nämä vaiheet on esitetty kuvassa 1. Ensimmäisenä askeleena on dataan tutustuminen, jonka jälkeen voidaan siirtyä datan valintaan. Kun data on valittu, se täytyy esikäsitellä ennen identifiointia ja validointia. Näiden vaiheiden jälkeen luotu malli (soft sensori) on valmis implementoitavaksi. Lisäksi jatkuva ylläpito on muistettava, jotta mallin tuottama tulos pysyy luotettavana. Muodostusvaiheissa sekä mallia ylläpidettäessä voidaan joutua palaamaan takaisin aikaisempiin vaiheisiin ja tekemään muutoksia malliin tarpeen mukaan.



Kuva 1. Datapohjaisen mallin muodostusvaiheet. Mukailten lähteestä (Abonyi *et al.* 2014).

Datapohjaisia malleja rakennettaessa on hyödynnetty laajasti tilastollista päättelyä sekä koneoppimistekniikoita. Eräitä käytetyimpiä mallinnustekniikoita, joita datapohjaisten mallien rakentamisessa on käytetty apuna ovat pääkomponenttianalyysi (PCA, Principal Component Analysis), osittainen pienimmän neliösumman regressio (PLSR, Partial Least Squares Regression), keinotekoiset neuroverkot (ANN, Artificial Neural Networks), neurosumeat järjestelmät (NFS, Neuro-Fuzzy Systems) sekä tukivektorikone (SVM, Support Vector Machine). (Kadlec *et al.* 2009)

Kadlec *et al.* (2009) esittelivät tutkimuksessaan tyypillisimpien datapohjaisissa soft sensoreissa käytettävien mallinnustekniikoiden yleisyyttä. Kuvasta 2 voidaan päätellä, että suosituimpia soft sensorin muodostustekniikoita ovat PCA, monikerrosneuroverkko (MLP, Multi-Layer Perceptron) ja PLSR, jotka kattavat tässä yli puolet käytetyistä tekniikoista (MLP 18 %, PCA 23 % ja PLSR 15 %). Muut kaaviossa mainitut tekniikat ovat vastavirtaneuroverkko (RNN, Recurrent Neural Network), radiaalikanta-funktioneuroverkko (RBFNN, Radial Basis Function Neural Network), itseorganisoidut kartat (SOM, Self Organizing Maps), neurosumeat järjestelmät (NFS, Neuro-Fuzzy System), monimuuttujaregressio (MLR, Multiple Linear Regression) sekä 10 % muut tekniikat.



Kuva 2. Suosituimpien soft sensorin muodostustekniikoiden jakauma. Mukailleen lähteestä (Kadlec *et al.* 2009).

2.3 Ilmiöpohjaiset soft sensorit

Ilmiöpohjaiset (white-box) mallit perustuvat fysikaalisiin, kemiallisiin ja biologisiin ilmiöihin kuten reaktiokinetiikkaan, termodynamiikkaan, nesteiden ominaisuuksiin ja säilymlakeihin ja niiden teoreettiseen kuvaamiseen. White-box-mallit muuttavat tiedon tapahtuvista prosesseista matemaattiseen muotoon. White-box-mallin yhtälöt muodostuvat tavallisista tai osittaisista differentiaaliyhtälöistä, joille on asianmukaisesti määritelty alku- ja raja-arvot. (Ahmad *et al.* 2020)

Lähteessä (Kadlec *et al.*, 2009) kerrotaan, että white-box-mallit on kehitetty ensisijaisesti tuotantolaitosten suunnitteluun ja mitoittamiseen, jolloin keskitytään lähinnä ihanteelliseen vakio-tilassa olevaan prosessiin eikä niinkään todellisiin vallitseviin prosessiolosuhteisiin. White-box-mallien ennustustarkkuus ei välttämättä ole tarpeeksi hyvä, joka on yksi rajoittava tekijä niiden soft sensor -käytölle teollisuudessa. Kadlec *et al.* (2009) kertovat myös, että monimutkaisten prosessien dynamiikkaa on hankalaa kuvata differentiaaliyhtälöillä, jonka vuoksi white-box-malleja käytetään yleensä vain tasapainotilojen tarkasteluun. Myös Abonyi *et al.* (2014) kertovat, että on vaikeaa rakentaa white-box-malli, joka osaisi kertoa, mistä syystä tuotteeseen syntyy laatu-epäsuoruuksia. Ilmiöpohjaisten mallien rakentaminen vaatii resursseja ja asiantuntijan

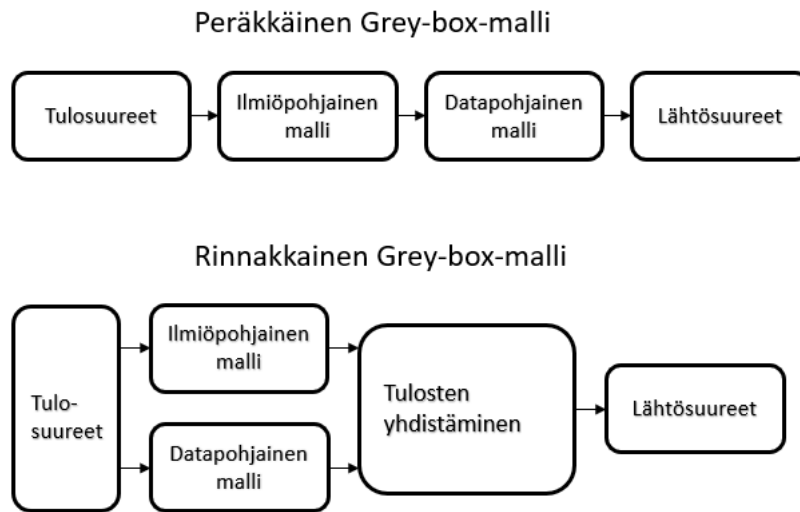
vakaata tietämystä prosesseista, sillä se on todella haastava ja myös aikaa vievä menettelytapa.

2.4 Grey-box- soft sensorit

Grey-box-mallit pyrkivät yhdistämään datapohjaisista sekä ilmiöpohjaisista malleista parhaat ominaisuudet prosessien ongelmien ratkomiseksi. Grey-box-malli voi olla yksi malli, jonka muodostamisessa on käytetty molempia aiemmin esitettyjä lähestymistapoja tai se voi muodostua kahdesta keskenään erilaisesta mallista. Grey-box-malleja hyödynnetään teollisuudessa esimerkiksi suunnittelussa, estimoinnissa, ohjauksessa ja valvonnassa. (Ahmad *et al.* 2020)

Grey-box mallit voidaan jaotella Ahmad *et al.* (2020) mukaan kolmeen eri kategoriaan niiden toimintaperiaatteen perusteella: rinnakkaiseen-, peräkkäiseen- ja yhdistettyyn grey-box-malliin. Rinnakkaisessa grey-box-mallissa erilliset mallit summataan yhteen. Voidaan esimerkiksi käyttää black-box-mallia kompensoitaessa white-box-mallista syntyvää virhettä. Tällaisessa tapauksessa black-box-malli ei siis vaikuta white-box-mallin sisäiseen rakenteeseen. Peräkkäinen grey-box-malli rakentuu kahdesta peräkkäisestä mallista, joista ensimmäisen mallin lähtösuure syötetään toisen mallin tulosuureeksi. Tällaista grey-box-mallia voidaan käyttää parametrien päivittämiseen prosessiolosuhteiden mukaisesti. Tarkoituksena on tunnistaa tärkeät fysikaaliset parametrit, jotka liittyvät prosessin muuttujiin ja sitä kautta muodostaa malli, jolla on parempi kyky ymmärtää prosessin dynamiikkaa. Tällainen kahden mallin yhdistelmä voi olla myös muodostettu kahdesta keskenään erilaisesta black-box-mallista tai puolestaan kahdesta keskenään erilaisesta white-box-mallista. (Ahmad *et al.* 2020)

Kuvassa 3 on esitetty rinnakkaisen- ja peräkkäisen grey-box-mallin muodostustavat. Kuvan peräkkäisessä grey-box-mallissa datapohjainen malli on ilmiöpohjaisen mallin perässä, jolloin voidaan ajatella, että se korjaa white-box-mallin virhettä. Toki nämä mallit voivat olla myös toisinpäin.



Kuva 3. Grey-box-mallin muodostustapoja

2.5 Mallinnustekniikoita havainnollistava esimerkki

Laiho (2020) tutki työssään Outokummun Tornion terästehtaan sulaton 2-linjan liikusulkimen säätöpiiriä ja sen optimointia. Tehtaalla esiintyi haluttua enemmän välialtaan pinnankorkeuden vaihtelua, ja tutkimuksen tavoitteena oli löytää kehityskohteita, joiden avulla välialtaan painonvaihtelu saataisiin minimoituksi, sekä liikusulkimen liikekertojen mahdollinen vähentäminen. Tutkimuksessa yhdeksi pinnankorkeuden vaihtelua aiheuttavaksi tekijäksi löydettiin säätöpiiriin sisältyvä viive. Ongelman ratkaisuksi esitettiin mallipohjaista säätöä (Smith-prediktori), jolloin prosessia voitaisiin säätää viiveettömänä.

Välialtaan mallinnuksessa Laiho (2020) käytti white-box-mallia, jonka perustana oli prosessin kokonaisuus. Kokonaisuudessa tuntemattomana suureena oli teräksen tiheys, joka tutkimuksessa määritettiin datan pohjalta. Kokonaisuutena tutkimuksessa käytettävä malli oli siis grey-box-malli.

Tutkimuksessaan Laiho (2020) rakensi grey-box-mallin pohjalta simulaattorin ja testasi siellä erilaisia säätötapoja. Simuloinneista saadut tulokset olivat huomattavasti parempia käytössä olevaan systeemiin verrattuna. Simulointitulosten perusteella todettiin, että paras tulos saatiin Smith-prediktorilla käyttämällä. Laiho (2020) kertoo, että mallipohjaista säätöä hyödyntämällä voisi olla mahdollista saavuttaa tasaisempi välialtaan paino verrattaessa perinteiseen PID-säätöön.

2.6 Soft sensoreiden hyödyt ja haasteet

Merkittävimpiä hyötyjä, joita soft sensorien käytöllä voidaan saavuttaa ovat muun muassa tuotteen laadun- ja prosessin suorituskyvyn parantaminen, käyttökustannusten ja ympäristökuormituksen vähentäminen sekä turvallisuuden parantaminen. Ennustavan mittauksen etuna on reaaliaikaisesti tapahtuva arvio, jonka avulla tieto on jatkuvasti käytettävissä ja tämän johdosta voidaan edistää prosessin ohjausta ja optimointia sekä saavuttaa edellä mainittuja merkittäviä hyötyjä eri osa-alueilla. (Amazouz *et al.* 2005), (Abonyi *et al.* 2014)

Hyötyjen lisäksi soft sensor -menetelmissä on myös omat haasteensa. Datapohjaisissa malleissa haasteita luovat suuren ja pitkältä ajanjaksolta olevan datamäärän tarve prosessista, jotta malleista saadaan luotettavia ja toimivia. Useimmat soft sensor -mallit ovat räätälöityjä ja datapohjaisia, jolloin niiden käyttö usein muuttuvissa prosesseissa on haastavaa. Tällöin olisi tarpeellista kehittää mallia jatkuvasti uudelleen tai tehdä jokaiselle tuotantolaadulle oma mallinsa. (Amazouz *et al.* 2005) Datapohjaisia malleja luotaessa on myös erityisen tärkeää muistaa pitää huolta datan edustavuudesta ja luotettavuudesta, jotta mallista tulee käyttökelpoinen. Prosessidatassa voi esiintyä esimerkiksi puuttuvia arvoja, poikkeavia arvoja ja virheellisiä mittaustuloksia esim. ryöminnästä tai rikkinäisestä anturista johtuen. Tästä syystä on kannattavaa suorittaa aikaisemmin työssä esitetyt datapohjaisen mallin rakennusvaiheet huolellisesti. (Kadlec *et al.* 2009)

Ilmiöpohjaisten mallien haasteena on erityisesti niiden suuri ja vaativa työmäärä. Niin kuin aikaisemmin jo todettiin, white-box-mallien muodostaminen on haastavaa ja näin ollen myös niiden uudistaminen ja ylläpito on vaikeaa. White-box-mallien monimutkaisuudesta johtuen, niiden kehitystyö on myös hyvin kallista ja aikaa vievää. (Kadlec *et al.* 2009)

3 SOFT SENSOREIDEN KÄYTTÖ PROSESSITEOLLISUUDESSA

Soft sensoreita pystytään hyödyntämään prosessiteollisuudessa hyvin laajasti erilaisissa kohteissa ja tehtävissä. Soft sensor -sovellukset ovat yleensä hyvin räätälöitävissä haluttuun prosessiin ja tarkoitukseen. Niin kuin fyysisetkin anturit myös soft sensorit menettävät tehokkuuttaan ja luotettavuuttaan, mikäli niitä ei ylläpidetä. Soft sensoreiden tapauksessa ylläpito tarkoittaa mallin päivittämistä muuttuvan prosessin mukana. (Kadlec *et al.* 2009) , (Ge ja Song 2010), (Chen *et al.* 2015)

3.1 Käyttökohteet

Yleisimmin soft sensoreita on käytetty ja käytetään tärkeiden prosessimuuttujien reaaliaikaiseen estimointiin ja laatuominaisuuksien ennustamiseen, kun niitä ei pystytä mittaamaan reaaliaikaisesti tai niiden näytteenottoväli on liian pitkä. Syynä reaaliaikaisen mittauksen puuttumiseen voi olla joko liian korkeat kustannukset tai hankalat prosessiolosuhteet, jolloin fyysistä anturia ei pystytä asentamaan haluttuun paikkaan. Mikäli näytteenottoväli puolestaan venyy liian pitkäksi, se ei enää kuvaa prosessin sen hetkistä tilaa, vaan mahdollinen poikkeama tuotannossa on voidut edetä jo lopputuotteeseen asti. Prosessinäytteitä ei pystytä edes saamaan kaikista halutuista paikoista tai edustavan näytteen saaminen voi olla haasteellista monesta eri syystä. (Kadlec *et al.* 2009)

Toinen tärkeä sovellusalue on prosessimuutosten havainnointi sekä prosessin seuranta. Soft sensorin tehtävänä on siis tarkkailla prosessin tilaa ja ilmoittaa mahdollisista poikkeamista sekä tunnistaa poikkeaman mahdollinen syy. Soft sensorien prosessin valvonta perustuu historiadataan, jonka avulla voidaan muodostaa haluttuja prosessin tilaa kuvaavia suureita ennustavia monimuuttujamalleja. Tämä soft sensorien hyödyntämistapa on apuna erityisesti prosessioperaattoreille auttamalla ja tukemalla päätöksenteossa silloin, kun prosessin tila poikkeaa normaalista. Prosessin valvonnassa käytettävät mallit pohjautuvat yleensä PCA:han tai itseorganisoituihin karttoihin (SOM). (Kadlec *et al.* 2009)

Soft sensoria voidaan käyttää mitta-arvon korjaamiseen ja anturivikojen havaitsemiseen. Jos ja kun yleensä tuotantolaitoksella jokin anturi menee vikatilaan, voidaan soft sensorin

avulla tuottaa arvioitua mittaustietoa fyysisen anturin puolesta, sillä aikaa kun sitä korjataan. Soft sensori toimii ikään kuin varavaihtoehtona alkuperäiselle anturille ja joissain tilanteissa voidaan huomata, ettei fyysiselle anturille ole tarvetta ja se voidaan korvata täysin soft sensorilla. Soft sensorin ylläpito voi osoittautua helpommaksi eikä se vikaannu mekaanisesti, mistä johtuen se todennäköisesti on myös taloudellisesti kannattavampi vaihtoehto. (Kadlec *et al.* 2009)

3.2 Soft sensoreiden ylläpito

Kun on kehitetty toimiva ja hyvä soft sensori, on myös tärkeää muistaa ylläpitää sitä sen suorituskyvyn ja luotettavuuden takaamiseksi. Kun prosessiin tehdään merkittäviä muutoksia tai syötettävän raaka-aineen ominaisuudet muuttuvat merkittävästi, mallien täytyy olla tietoisia tehdyistä muutoksista. Soft sensorin päivittäminen tasaisin väliajoin on tarpeen, vaikka suuria muutoksia prosessiin ei tehtäisikään. Jos malliin ei tehdä päivityksiä tai säätimen säännöllistä huoltoa ei tehdä, soft sensorin antama tulos alkaa heikentyä. Monissa teollisissa prosesseissa laitteiden ominaisuuksia ja muuta prosessikäyttäytymistä muutetaan usein. Tällaisia muutoksia ovat esimerkiksi katalyytin deaktivointi ja raaka-ainemuutokset, joiden jälkeen soft sensoria tulee päivittää. Myös laitteiston ikääntyminen vaikuttaa päivitystarpeeseen. Erilaiset rekursiiviset menetelmät pystyvät mukauttamaan soft sensorin mallin uuteen toimintatilaan itsestään, mutta ne eivät pysty sopeutumaan äkillisiin prosessin muutoksiin, jolloin niiden vaikutus näkyy vasta tietyn ajan kuluttua. Rekursiivisia menetelmiä ovat esimerkiksi rekursiivinen PLS ja rekursiivinen SVR. Lisäksi on kehitetty erilaisia online-adaptointi tekniikoita soft sensoreiden mallien suorituskyvyn heikkenemisen estämiseksi. (Ge ja Song 2010), (Chen *et al.* 2015)


Kadlec *et al.* (2009) kertovat tutkimuksessaan, että suurimmassa osassa soft sensoreista ei ole automaattista mekanismia niiden ylläpitoon vaan ne vaativat manuaalista päivittämistä. Toinen puute ylläpidossa voi syntyä, jos käytössä ei ole mitään objektiivista mittaria soft sensorin toiminnan laadusta. Tällöin mallin toiminnan arviointi riippuu vain käyttäjän havainnoista ja tulkinnoista.

4 KÄYTTÖKOHTEET SELLU- JA PAPERITEOLLISUUDESSA

Amazouz *et al.* (2005) esittelivät tutkimuksessaan paperi- ja selluteollisuuden tärkeitä muuttujia, joita voidaan ennustaa soft sensorien avulla ja siten saavuttaa merkittäviä hyötyjä. Näitä muuttujia ovat mm. kappaluku, viskositeetti, vaaleus, jäykkyys, lujuus, freeness, elastinen kerroin, karheus, läpikuultavuus, huokoisuus, ominaispinta-ala ja märänpään kemia. Näitä muuttujia mallintamalla voidaan saavuttaa mm. pienempi määrä hylkyyn menevää tuotantoa sekä lyhyemmät tuotannon siirtymäajat. Lisäksi voidaan optimoida energiankulutusta paremmin ja seurata ennakoivasti kattilapäästöjä, sekä ennustaa ratakatkoja.

4.1 Soft sensorit sellun valmistuksessa

Kuvassa 4 on esitelty sulfaattisellun valmistusprosessiin liittyviä vaiheita. Puunkäsittelyssä puu käsitellään valmiiksi keittoa varten. Keitossa on tarkoitus poistaa puusta ligniiniä mahdollisimman paljon. Massan valkaisu alkaa pesussa ja happidelignifioinnissa ja lopullinen vaaleus saadaan aikaan valkaisuissa. Haihduttamo, soodakattila, kaustisointi ja meesanpoltto ovat kemikaalikierron osia. (Knowpulp, 2021)



Kuva 4. Sellun valmistusprosessi. Mukailten lähteestä (ABB, 2021)

Selluteollisuudessa yksi hyödyllinen soft sensorien käyttökohteita keittovaiheessa on kappaluvun ennustaminen. Kappaluku kertoo massassa olevan ligniinipitoisuuden ja on siis tärkeä tuotteen laatuun vaikuttava tekijä. Mitä suurempi kappaluku on, sitä tummempaa massa on ja se vaatii lisää valkaisukemikaaleja. Kappaluku voidaan määrittää tehtaassa kappa-analysointin avulla sekä laboratoriokokeena, mutta täysin reaaliaikaista analyysiä siitä ei pystytä tekemään. Hyödyntämällä soft sensoreita

kappaluvun ennustamiseen voitaisiin mahdollisesti vähentää energia- ja kemikaalikustannuksia sekä hylkyyn menevän tuotteen määrää. (Amazouz *et al.* 2005)

Kappaluvun ennustaminen keittoliuoksen avulla

Oulun yliopiston säätötekniikan laboratorion ja ABB:n vuonna 1998 tekemässä yhteistyötutkimuksessa tutkittiin ABB:n CLA 2000 (Cooking liquor analyzer) käyttöä kappaluvun ennustamiseen. Mallien rakennuksessa käytettyjä menetelmiä olivat PLSR ja neuroverkot. Tutkimuksessa tehtiin kokeita eri tehtaissa eräkeittimille ja jatkuvatoimisille keittimille, sekä havupuulle että lehtipuulle.

Kokeet paljastivat merkittäviä korrelaatioita johtokyvyn mittauksen ja alkalikonsentraation välillä sekä taitekertoimen mittauksen ja kiintoainepitoisuuden välillä. Ennustetun ja analysoidun kappa-arvon yhteys todettiin selvästi paremmaksi, kuin pelkkien perinteisten analysointitapojen käyttö. Tutkimuksessa päästiin siihen tulokseen, että kyseisiä malleja hyödyntäen on mahdollista ennustaa kappaluku ennen eräkeiton loppua tai muuttaa keitto-olosuhteita jatkuvassa keitossa halutun kappaluvun saavuttamiseksi. Kappaluvun ennustamisen lisäksi CLA 2000 -analysointia voitiin käyttää myös alkalien annostuksessa sekä jäännösalkalien valvonnassa.

Sumea klusterointi kierrätyspaperiteollisuudessa

Ökopap 2000 projektissa tavoitteena oli kehittää painotuotteiden elinkaarta parantamalla kierrätyspaperimassan laatua ja vähentämällä päästöjä. Tarkastelualueena tässä oli erityisesti siistausosan optimointi. Siistauksessa on tarkoitus poistaa mustepartikkelit kierrätettävästä kuitumassasuspensiosta. Projektissa käsiteltiin kolmea ongelmaa, jotta siistausprosessi saataisiin optimoitua:

- siistausprosessista saatavat datavirrat olivat liian suuria sellaisenaan tehokkaasti käsiteltäväksi
- prosessissa esiintyi ei-toivottuja materiaalin laadun ja tuotannon tehokkuuden vaihteluita riippuen syöttömateriaalista ja operaattorin toiminnasta
- ominaisimpia muuttujia, jotka täytyisi saada optimoitua (vaaleus, väri ja musteen poisto), voitiin mitata vain laboratoriossa.


Näistä ongelmista viimeisimpään löydettiin ratkaisu rakentamalla soft sensori. (Runkler *et al.* 2001)

Muodostettu soft sensori perustui sumeaan klusterointiin (fuzzy clustering) ja se pohjautui prosessista saatuun mittaus- ja laboratoriodataan. Mallin opetusvaiheessa käytettiin laboratoriomittauksista saatua dataa sekä vastaavia mittauksia automaatiojärjestelmän historiakannasta. Sumeasääntöpohjainen järjestelmä tuotti arvioita vaaleudesta siistaamattomalle ja siistatulle sellulle virheen keskineliön neliöjuuren (RMSE, Root mean squared error) ollessa 0,48 ja 0,12 vastaavasti. (Runkler *et al.* 2001)

Tutkimuksessa todettiin, että on tarpeellista muodostaa kaksi erilaista soft sensoria siistauksen tehokkuuden määrittämistä varten: toinen ennen ensimmäistä vaahdotuskennoa ja toinen viimeisen vaahdotuskennon jälkeen. Molemmissa soft sensoreissa oli tulosuureina suspension parametrit ja RGB- heijastumat ja lähtösuureina vaaleuden arvio. Mallin tarkkuus oli tutkimuksen mukaan riittävä molemmille soft sensoreille ja erityisesti flotaatioprosessin jälkeinen vaaleusarvio osoittautui hyväksi. Tämä ratkaisu integroitiin Siemensin automaatiojärjestelmään ja visualisointityökaluun. (Runkler *et al.* 2001)

4.2 Soft sensorit paperin- ja kartongin valmistuksessa

Paperinvalmistuksen vaiheet alkavat perälaatikosta, josta paperiraina syötetään viiralle, tämän jälkeen puristinosa poistaa mahdollisimman paljon vettä rainasta. Kuivatusosa jatkaa vedenpoistoa haihduttamalla. Jälkikäsittelyn osat riippuvat valmistettavasta tuotteesta ja lajista. Jälkikäsittelyyn voi sisältyä esimerkiksi pintaliimaus, päällystys, pituusleikkaus, rullaukset ja kalanterointi. Kuvassa 5 on esitetty paperikoneen yleinen rakenne. (Knowpap, 2021)



Kuva 5. Paperin valmistusprosessi. Mukailten lähteestä (ABB, 2021)

Paperiteollisuudesta löytyy useita monimutkaisia ilmiöitä, joita voi olla vaikea hallita tai seurata, mutta niiden merkitys tuotantoon on suuri. Yleensä näissä tapauksissa ei ole saatavilla reaaliaikaista mittausta, vaan tarkastelu keskittyy ainoastaan valmiin tuotteen ominaisuuksiin. Paperin- ja kartongin valmistuksessa soft sensoreita voidaankin käyttää erityisesti tuotteen kriittisten laatuominaisuuksien ennustamiseen, jolloin tuotannon laatua voidaan seurata reaaliaikaisesti. (Raffaele ja Ondruch 2020)

Päättelevät anturit pehmopaperikoneen laatuominaisuuksien reaaliaikaiseen seurantaan

Pehmopaperin valmistuksessa tuotteen laatuominaisuudet ovat erityisen tärkeitä, sillä pehmopaperia käytetään pääasiassa hygieniatuotteisiin, joiden yksi tärkeimmistä laatuominaisuuksista on pehmeys. Yleensä tuotteen pehmeyttä on seurattu keräämällä näytteitä harvakseltaan ja lähettämällä ne laboratorioon analysoitavaksi. Tämä prosessi voi kestää useita tunteja ja mikäli todetaan, että tuote ei täydy haluttuja laatuominaisuuksia, täytyy se kierrättää takaisin tuotantoon. Tässä ajassa on hukattu sekä aikaa että energiaa. (Sarimveis 2001)

Tutkimuksessa lähestyttiin laatuominaisuuksien mittaamista rakentamalla malleja, jotka päättelevät haluttuja arvoja automaatiojärjestelmästä kerättyjen prosessisuureiden avulla. Muuttujat, joita tutkimuksessa lähdettiin ennustamaan, olivat pehmeys, vetolujuus (Cross Directional Tensile strength, CDT) ja koneensuuntainen venytys (Machine Directional Stretch, MDS). Tutkimuksessa tuotteen pehmeys oli vaikein ennustaa eikä pehmeysmittausten rajoitusten vuoksi onnistuttu kehittämään soft sensoria, joka päätelisi arvon suoraan reaaliaikaisesti mitattavista muuttujista. Pehmeydelle onnistuttiin luomaan ennuste kehittämällä malli käyttäen muita laatumuuttujia tulomuuttujina. CDT ja MDS puolestaan onnistuttiin selkeästi ennustamaan soft sensor -tekniikalla. Tutkimuksessa

myös todettiin, että tilastollinen analyysi mallista, joka ennustaa pehmeyttä, osoittaa että pehmeys on voimakkaasti korreloiva CDT:n kanssa, jolloin voidaan saada reaaliaikaista arviota pehmeystä CDT:n käyttäytymistä seuraamalla. (Sarimveis 2001)

Paperinvalmistuksen jätevedenkäsittelyprosessin laadun seuranta

Paperi- ja selluteollisuudesta syntyvät jätevedet ovat suurimpia teollisuudesta peräisin olevia saasteita, joiden puhdistaminen on haasteellista jäteveden kompleksisen koostumuksen vuoksi. Sellu- ja paperiteollisuudesta jätevesiä syntyy useasta eri lähteestä ja niiden koostumus vaihtelee. Mikäli jätevesi ei täytä vaadittuja päästörajoja ennen kuin sitä johdetaan takaisin ympäristöön, se aiheuttaa merkittäviä ympäristövaikutuksia. (Yang *et al.* 2021)

Yang *et al.* (2021) mukaan eräs indikaattori, joka kertoo paperinvalmistuksessa syntyvän jäteveden laadusta, on kemiallinen hapenkulutus (COD, Chemical Oxygen Demand). Yleensä tieto tällaisien indikaattoreiden arvoista perustuu laboratoriomittauksiin ja määrittäisiin, mikä puolestaan johtaa haasteisiin prosessin seurannassa. Mikäli COD-arvosta saadaan viiveellistä tietoa, muutoksia voidaan jätevedenpuhdistusprosessiin tehdä vain viiveellä, jolloin ympäristöön on mahdollisesti jo laskettu päästörajat ylittävää vettä. Puhdistusjärjestelmän tilan määrittämisen kannalta on erityisen tärkeää, että prosessista saadaan täsmällistä tietoa lyhyellä vasteajalla.

Jätevedenpuhdistuksesta kerättiin prosessidataa kiinalaiselta jätevedenpuhdistamolta, jossa käsitellään paperinvalmistuksesta syntyvää jätevettä. Tiedot mitattiin kolmesti päivässä saaden yhteensä 1095 näytettä. Näistä 900 näytettä käytettiin mallin kehitykseen ja loppuja käytettiin testidatana.

Tutkimuksessa suositeltiin dynaamista PLSR-mallia vikojen havaitsemiseen. Dynaamisen PLSR-mallin avulla saatiin reaaliaikainen ennuste prosessin COD-arvosta ja pystyttiin vähentämään virheen havaitsemisen viivettä. Mallin avulla voitiin myös paikantaa vikoja paremmin kuin muilla malleilla. Dynaamisen PLSR-mallin avulla saatiin erinomaisia tuloksia. erityisesti vian havaitseminen parantui 35,93 %. (Yang *et al.* 2021)

Lainerikartongin puristus- ja puhkaisulujuuden on-line-estimointi soft sensoria käyttäen

Tutkimuksen tavoitteena oli selvittää, voidaanko kartongin puristuslujuutta ennustaa datapohjaisen soft sensorin avulla. Lujuusominaisuudet ovat kartongille tärkeitä laatua kuvaavia suureita ja erityisesti pahvilaatikoissa usein käytettävä aaltopahvi tulee olla

kestävää ja lujaa sen käyttötarkoitusten vuoksi. Mallinnusmenetelmäksi tässä tutkimuksessa valittiin lineaarinen regressio ja sekä puristus- että puhkaisulujuudelle muodostettiin lajikohtaiset mallit kolmesta eri kartonkilajista. (Viitamäki 2016)

Puristuslujuuden mallien selitysasteet (R^2 -arvo) olivat opetusdatalle yli 70 % ja puhkaisulujuuden mallien selitysaste oli 56-78 %. Mallinnustulosten validoinnissa puristusindeksin selitysaste laski 4-8 % ja puhkaisuindeksin selitysaste puolestaan pysyi ennallaan tai laski 4 %. Puhkaisuindeksin mallinnuksessa luotettavimmaksi lujuuden indikaattoriksi osoittautui kierrätyskuitumassasta tuleva tuhkapitoisuus, jonka havaittiin vaikuttavan merkittävästi puhkaisuindeksin suuruuteen. Soft sensorin estimaatti pysyi tutkimuksessa pääosin mittauksen 95 %:n luottamusvälin sisäpuolella. Tutkimuksessa todettiin soft sensorin avulla puristus- ja puhkaisuindeksin arvon estimoinnin onnistuvan, mikäli rajoittavat tekijät muistetaan ottaa huomioon. (Viitamäki 2016)

4.3 Kaupallinen tarjonta

Alla olevassa taulukossa 1 on esitelty katsaus tällä hetkellä tarjolla olevista soft sensor -ratkaisuista. Tämä katsaus ei kata koko saatavilla olevaa tarjontaa, sillä soft sensor -teknologiaan pohjautuvia tuotteita löytyy varmasti paljon enemmän, kuin mitä tässä työssä pystytään esittämään.

Taulukko 1. Kaupallisia soft sensoreihin perustuvia tuotteita sekä työkaluja soft sensoreiden muodostamiseen

Toimittaja	Tuote	Ominaisuudet
ABB	Strength Virtual Measurement, Weight Virtual Measurement	Paperin lujuusominaisuuksien reaaliaikainen mittaaminen, paperin neliömassan reaaliaikainen mittaaminen
Andritz	Metris Digital Twin	Virtuaalisia mittauksia eri sovelluskohteisiin
Honeywell	Profit® SensorPro	Työkalu soft sensor -mallien rakentamista varten
IntelliDynamics	Intellect-tuoteperhe	Työkaluja virtuaalisen mittauksen rakentamiseen ja visualisointiin
Siemens	Virtual sensor	Moottorin sisälämpötilan ennustus
Siemens	INCA Sensor	Työkalu soft sensoreiden suunnitteluun, parametrisointiin ja käyttöön
Valmet	Valmet Online Quality Predictor	Työkalu, jonka avulla voidaan rakentaa räätälöityjä soft sensoreita paperin, kartongin ja pehmopaperin laatuominaisuuksien ennustamiseen
Voith	OnEfficiency.Strength	Soft sensor -teknologia osana APC-konseptia, paperin lujuusominaisuuksien ennustamiseen
Voith	OnView.VirtualSensor Builder	Sovellus virtuaalisten sensoreiden rakentamiseen

5 POHDINTA

Aikaisemmin työssä todettiin, että monimutkaisten prosessien järkevä mallintaminen ilmiöpohjaista mallinnusta hyödyntäen on erittäin haastavaa, jonka vuoksi niitä käytetään datapohjaisia vähemmän teollisuudessa. Tähän syynä on varmasti muitakin kuin kappaleessa 2.3 kerrotut ilmiöpohjaisen mallin rajoitteet. Ilmiöpohjaisten mallien rakentamien vaatii paljon aikaa, resursseja ja rahaa, jolloin niiden käyttäminen ei välttämättä ole aina mahdollinen vaihtoehto. Mikäli ilmiöpohjaisia malleja on kuitenkin onnistuneesti kehitetty, on niissä takana niin suuri työ, ettei onnistunutta ratkaisua välttämättä julkaista. Tästä syystä niistä luultavasti ei ole saatavilla tutkimustietoa samalla tasolla kuin datapohjaisista ratkaisuista.

Toisaalta yksinkertaisiin taseisiin perustuvia ilmiöpohjaista mallinnusta hyödyntäviä ratkaisuja saattaa olla käytössä jonkin verran. Esimerkiksi työssä mainitussa tutkimuksessa (kappale 2.5) mallin muodostamisessa käytettiin yksinkertaista massatasetta ja luotiin lopulta grey-box-malli. Grey-box-mallit voivatkin olla hyviä mahdollisuuksia käyttää ilmiöpohjaista mallia datapohjaisen mallin tukena.

Soft sensoreiden käyttökohteita löytyy laajasti ja todennäköisesti jokaiselle teollisuuden alalle löytyy omia juuri niiden tarpeet täyttäviä ratkaisuja. Eräs mahdollinen sovelluskohde työssä mainittujen lisäksi, voisi olla tuotannon tilan ennustaminen esimerkiksi alasajojen ja seisakkien jälkeen. Näissä tilanteissa tuotannon saaminen haluttujen raja-arvojen sisään voi viedä aikaa, jolloin siinä välissä tehtaasta valmistuva tuote ei välttämättä vielä vastaa laatuvaatimuksia. Ylösajon aikana valmiin tuotteen laadusta ei ole vielä mittaustietoa, mutta muiden prosessimuuttujien avulla voitaisiin estimoida tuotteen laatua. Tällöin soft sensoreita soveltamalla pystytään tekemään prosessiin nopeammin tarvittavia muutoksia, jolloin tuotanto saadaan nopeammin valmistamaan laatuvaatimukset täyttävää tuotetta.

Joidenkin laatu- ja prosessisuureiden reaaliaikaiseen mittaamiseen on saatavilla analysaattoreita. Analysaattoreiden avulla saadaan arvokasta tietoa prosessin etenemisestä nopeammin kuin laboratorioanalyysillä. On-line-analysaattorit pystyvät tuottamaan tietoa myös reaaliaikaisesti. Analysaattorit ovat kuitenkin kalliita, jolloin niiden sijasta soft sensori voi tulla halvemmaksi sekä hankkia että ylläpitää. Analysaattori vaatii huoltoa, sillä se voi vikaantua. Analysaattoria ei voida sijoittaa fyysisesti prosessin

välittömään läheisyyteen, joka puolestaan rajoittaa saatavilla olevia prosessinäytteitä. Yleensä analysaattorit eivät analysoi näytteitä jatkuvasti, vaan analysaattori ottaa prosessista näytteen tietyn ajan välein ja analysoi sen. Tästä syntyy viive näytteenottohetken ja valmiin tuloksen välille eikä analysaattorin tuottama tieto ole heti saatavilla. Näytteenottojen välillä prosessissa voi ehtiä tapahtua muutoksia, jotka huomataan vasta seuraavan näytteen analysoinnin jälkeen. Soft sensoreilla pystytään tuottamaan reaaliaikaista tietoa eivätkä mallit vikaannu mekaanisesti. Toki soft sensor -malleja täytyy ylläpitää, jotta niiden tuottama arvio pysyy luotettavana, mutta soft sensorin yhtäkkisestä vikaantumisesta ei tarvitse huolehtia. Analysaattorista saatava tieto kertoo prosessin sen hetkisestä tilasta, mutta soft sensoreiden avulla on sen lisäksi mahdollista ennustaa prosessin etenemistä.

Kaupallista tarjontaa tutkiessa huomio kiinnittyy siihen, että valmiiden sovellusten sijaan tarjolla on enemmän soft sensoreiden muodostamiseen tarkoitettuja työkaluja. Työkalut mahdollistavat käyttäjän luoda omia räätälöityjä malleja ongelmien ratkaisuun. Valmiiden mallien puuttuessa työkalun käyttäjältä vaaditaan enemmän osaamista kuin valmiin soft sensor -ratkaisun hankinnassa. Soft sensoreiden muodostustyökalussa voi olla toisaalta haasteita. Koska valmista ratkaisua ja mallia ei ole esitellä asiakkaalle, asiakkaan voi olla vaikea muodostaa konkreettista mielikuvaa tuotteesta ja sen hyödyistä. Varsinkin jos soft sensor -teknologia on asiakkaalle vieras, sitä voi olla vaikea lähestyä pelkän työkalun avulla. Valmiit soft sensor -ratkaisut tiettyihin yleisiin ongelmiin voivat olla helpompi vaihtoehto, mikäli kaivattuun ongelmaan on tarjolla soft sensori eikä saatavilla ole osaavia henkilöitä omien räätälöityjen mallien luomiseksi. Toisaalta valmiit ratkaisut toimivat vain siihen tarkoitetuissa kohteissa, eikä niitä voida soveltaa muualle ilman muutoksia. Valmiit soft sensor -ratkaisut ja muodostustyökalut voisivat palvella käyttäjää parhaiten tarjoamalla samassa alustassa sekä valmiita malleja että työkalun uusien mallien rakentamiseen ja valmiiden mallien muokkaamiseen. Tällainen sovellus voisi luoda käyttäjälle runsaasti mahdollisuuksia, mutta myös tarjota ongelmiin jo kehitettyjä ratkaisuja.

Soft sensoreissa on tutkimusten ja tulosten perusteella paljon hyödyllisiä ominaisuuksia ja potentiaalia prosessiteollisuuden käyttöön. Niiden jatkuva kehittäminen ja tutkiminen on varmasti kannattavaa, mikäli tavoitteena on tuotantolaitosten suorituskyvyn optimointi ja sitä kautta saatavat hyödyt niin taloudellisesti kuin ympäristön kannalta katsottuna.

6 YHTEENVETO

Työn tarkoituksena oli selvittää soft sensoreiden yleistä teoriaa sekä käyttökohteita prosessiteollisuudessa. Erityisesti tarkasteltiin käyttökohteita sellu- ja paperiteollisuuden puolelta. Apuna käytettiin erilaisia tutkimuksia, joissa oli hyödynnetty soft sensor -teknologiaa. Lisäksi tehtiin katsaus kaupalliseen soft sensor -tarjontaan. Kiinnitettiin huomiota tuotteisiin, joita markkinoitiin myös paperi- ja selluteollisuuden kohdistuvista ratkaisuksista.

Alkuun työssä esiteltiin kolmen erilaisen soft sensoreiden mallinnustavan peruseriaatteet, näitä mallinnustapoja olivat: datapohjainen ja ilmiöpohjainen mallinnus sekä grey-box-malli. Datapohjainen malli perustui tuotantolaitokselta kerättyyn dataan, ilmiöpohjainen malli perustui teoreettisiin fysikaalisiin, kemiallisiin ja biologisiin ilmiöihin ja grey-box-malli yhdisti kaksi erityyppistä mallia keskenään. Sekä ilmiöpohjaisissa että datapohjaisissa malleissa on omat haasteensa, joita käytiin työssä läpi. Ilmiöpohjaisten mallien suurimpana haasteena oli niiden monimutkaisuus ja dynaamisten prosessien hankala kuvaaminen niiden avulla. Datapohjaisissa malleissa puolestaan haasteena oli edustavan datan kerääminen sekä datan vaatima siistimistö. Tutkimusten perusteella datapohjaista mallinnusta käytettiin enemmän kuin muita mallinnustapoja. Käyttökohteista esiteltiin yleisimmät ja näitä oli prosessimuuttujan estimointi, prosessimuutosten havainnointi ja prosessin seuranta sekä mitta-arvon korjaaminen ja anturivikojen havainnointi. Todettiin myös, että soft sensoreiden ylläpito on tärkeää implementoinnin jälkeen, sillä prosessin muuttuessa malli ei anna enää luotettavaa ennustetta ilman sen päivittämistä.

Työssä käytiin lyhyesti läpi sellun -ja paperinvalmistusprosessit sekä esiteltiin niistä löytyviä potentiaalisia soft sensoreiden käyttökohteita. Esiteltiin tutkimuksia soft sensor -ratkaisuksista mm. kappaluvun ennustamisessa, pehmeiden estimoinnissa sekä puristus- ja puhkaisulujuuden estimoinnissa. Lisäksi tutkittiin kaupallista tarjontaa ja todettiin, että soft sensoreiden muodostustyökaluja löytyy markkinoilta enemmän kuin valmiita tuotteita. Soft sensoreiden käytölle sellu- ja paperiteollisuudessa löytyi paljon potentiaalisia sovelluskohteita ja suuria hyötyjä sekä ympäristön kannalta että taloudellisina säästöinä.

LÄHDELUETTELO

ABB, 2021. Verkkodokumentti. Saatavissa: <https://new.abb.com/pulp-paper/abb-in-pulp-and-paper/service/advanced-services/performance-services-for-paper-mills/strength-virtual-measurement> [viitattu 7.6.2021]

ABB, 2021. Verkkodokumentti. Saatavissa: <https://new.abb.com/pulp-paper/abb-in-pulp-and-paper/service/advanced-services/performance-services-for-paper-mills/weight-virtual-measurement> [viitattu 7.6.2021]

Abonyi, J., Farsang, B., Kulcsar, T., 2014. Data-driven development and maintenance of soft sensors. IEEE 12th International Symposium on Applied Machine Intelligence and Informatics (SAMI). 6 s.

Ahmad, I., Ayub, A., Kano, M., Cheema, I. I., 2020. Gray-box Soft Sensors in Process Industry: Current Practice, and Future Prospects in Era of Big Data. Processes, 8 (2), 243. <https://doi.org/10.3390/pr8020243>

Amazouz, M., Champagne, M., Platon, R., 2015. Soft sensor application in the pulp and paper industry_assessment study. 77 s. 10.13140/RG.2.1.2312.9442.

Andritz, 2021. Verkkodokumentti. Saatavissa: <https://www.andritz.com/automation-en/news-and-media/ahead-customer-magazine/enhance-operations-with-digital-twin-technology> [viitattu 7.6.2021]

Chen, K., Castillo, I., Chiang, L. H., Yu, J., 2015. Soft Sensor Model Maintenance: A Case Study in Industrial Processes. IFAC-PapersOnLine 48 (8), s. 427-432. <https://doi.org/10.1016/j.ifacol.2015.09.005>

Ge, Z., Song, Z., 2010. A comparative study of just-in-time-learning based methods for online soft sensor modeling. Chemometrics and Intelligent Laboratory Systems, 104 (2), s. 306-317. <https://doi.org/10.1016/j.chemolab.2010.09.008>

Honeywell, 2021. Verkkodokumentti. Saatavissa: <https://www.honeywellprocess.com/en-US/explore/products/advanced-applications/profit/profit-optimization-suite/Pages/profit-sensorpro.aspx> [viitattu 7.6.2021]

IntelliDynamics, 2021. Verkkodokumentti. Saatavissa: <https://intellidynamics.net/product-property-estimation/> [viitattu 7.6.2021]

Kadlec, P., Gabrys, B., Strandt, S., 2009. Data-driven Soft Sensors in the process industry. *Computers & Chemical Engineering*, 33 (4), s.795-814. <https://doi.org/10.1016/j.compchemeng.2008.12.012>

KnowPulp, 2021. Verkkodokumentti. Sulfaattisellun valmistus. Verkkodokumentti. Saatavissa: <http://www.knowpulp.com/www/suomi/kps/ui/process/general/ui.htm> [viitattu 11.6.2021]

KnowPap, 2021. Verkkodokumentti. Tuotantoprosessit, paperi. Saatavissa: http://www.knowpap.com/www/suomi/knowpap_system/user_interfaces/tuotantoprosessit/papvalm.htm [viitattu 11.6.2021]

Laiho, O., 2020. Valusenkan liukusulkimen säätöpiirin optimaalinen viritys. Diplomityö, Oulun Yliopisto. <http://jultika.oulu.fi/Record/nbnfioulu-201712123303>

Murtovaara, S., Juuso, E., Leiviskä, K., Sutinen, R., Lemmetti, A., 1999. Kappa Number Prediction Based on Cooking Liquor Measurements. *Proceedings of 6th International Conference on New Available Technologies, The World Pulp and Paper*. Tukholma, Ruotsi.

Raffaele, D., Ondruch, T., 2020. Data-driven soft sensor for continuous production monitoring: an application to paper strength. *Proceedings of 25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, 1335-1338, ISBN:978-1-7281-8957-4. Doi: 10.1109/ETFA46521.2020.9212113.

Runkler, T. A., Gerstorfer, E., Schlang, M., Jünnemann, E., Villforth, K., 2001. Fuzzy Clustering for Data Compression, Modeling and Optimization in Recovered Paper Industry. *European Journal of Control*, 7 (1), s. 67-74. [https://doi.org/10.1016/S0947-3580\(01\)70941-7](https://doi.org/10.1016/S0947-3580(01)70941-7)

Sarimveis, H., 2001. INFERENCE SENSORS FOR ON LINE MONITORING OF TISSUE MACHINE QUALITY PROPERTIES. Chemical Engineering Communications, 188 (1), s. 231-242. <https://doi.org/10.1080/00986440108912905>

Siemens. Saatavissa: <https://new.siemens.com/global/en/company/stories/research-technologies/digitaltwin/virtual-sensor-opens-a-world-of-efficiency-for-large-motors.html> [viitattu 7.6.2021]

Siemens, 2021. Verkkodokumentti. Saatavissa: <https://mall.industry.siemens.com/mall/en/nl/Catalog/Products/10017370> [viitattu 7.6.2021]

Valmet, 2021. Verkkodokumentti. Saatavissa <https://www.valmet.com/automation/industrial-internet/VII-application-catalogue/online-quality-predictor/> [viitattu 22.6.2021]

Viitamäki, M., 2017. Lainerikartongin puristus- ja puhkaisulujuuden on-line-estimointi soft sensoria käyttäen. Diplomityö, Tampereen teknillinen yliopisto.

Voith, 2021. Verkkodokumentti. Saatavissa: [https://voith.com/uk-en/products-services/papermaking-components/digital-papermaking-solutions.html?132346\[\]=0#132346](https://voith.com/uk-en/products-services/papermaking-components/digital-papermaking-solutions.html?132346[]=0#132346) [viitattu 7.6.2021]

Yang, J., Zhang, Y., Zhou, L., Zhang, F., Jing, Y., Huang, M., Liu, H., 2021. Quality-related monitoring of papermaking wastewater treatment process using dynamic multiblock partial least squares. Journal of Bioresources and Bioproducts, In Press, Corrected Proof. <https://doi.org/10.1016/j.jobab.2021.04.003>