

Pyry-Pekka Härkönen

# DATAFUUSION MENETELMÄT HYDRAULIJÄRJESTELMIEN VIKADIAGNOOSEISSA

Kandidaatintyö  
Tekniikan ja luonnontieteiden tiedekunta  
Ohjaaja: Henri Vainio  
Huhtikuu 2022

# TIIVISTELMÄ

Pyry-Pekka Härkönen: Datafuusion menetelmät hydraulijärjestelmien vikadiagnoseissa  
Kandidaatintyö  
Tampereen yliopisto  
Konetekniikan tutkinto-ohjelma  
Huhtikuu 2022

---

Datafuusiolla tarkoitetaan eri lähteistä peräisin olevan datan ja aiemman tiedon yhdistämistä, jonka tarkoituksena on tuottaa jollakin tapaa informatiivisempi kuvaus kohdejärjestelmästä. Datafuusion menetelmiä voidaan hyödyntää hydraulijärjestelmien analysoinnissa, jossa datafuusio on useiden lähteiden datafuusiota, kuten monianturidatafuusiota. Tässä kirjallisuuskatsauksessa tarkastellaan datafuusion menetelmiä hydraulijärjestelmien vikadiagnoseissa. Työn tavoitteena on selvittää, mitä on datafuusio, miten datafuusion menetelmiä voidaan hyödyntää hydraulijärjestelmien vikadiagnoseissa, ja mihin suuntaan hydraulijärjestelmien vikadiagnostiikka on kehitymässä.

Kirjallisuuskatsauksen aineistona on vertaisarvioituja julkaisuja ja alan kirjoja. Työn alussa käsitellään hydraulijärjestelmien ja datafuusion perusteita. Tämän jälkeen tarkastellaan hydraulijärjestelmien vikaantumista ja kunnonvalvonnan periaatteita. Lopuksi tarkastellaan datafuusion menetelmiä hydraulijärjestelmien vikadiagnoseissa. Soveltuvuuskohteena pidetään liikkuvien raskaiden työkoneiden hydraulijärjestelmiä.

Työn perusteella havaitaan, että hydraulijärjestelmien vikadiagnostiikka perustuu johonkin toimintafilosofiaan, joista suosituin on kuntoperusteinen huolto. Hydraulijärjestelmien vikadiagnosointi on haasteellista, koska hydraulijärjestelmät ovat monimutkaisia epälineaarisia järjestelmiä, jossa satunnaisilla tekijöillä on suuri vaikutus. Näistä syistä johtuen data voi olla vaikeasti tulkittavissa ja ominaisuuksia voi jäädä piiloon. Prosessina vikadiagnosoin tekeminen on korkean tason datafuusiota, jossa keskeinen käsite on hahmontunnistus. Hahmontunnistuksella tarkoitetaan mittausten ja ominaisuuksien informaation perusteella tehtävää kartoitusprosessia. Datafuusion mallit soveltuvat hyvin vikadiagnosoin tekemiseen. Suosituin malli vikadiagnoseissa on hierarkkinen datafuusiomalli. Vikadiagnosijärjestelmien suurimmat haasteet liittyvät ominaisuuksien erotteluun ja datan käsittelyssä käytettyihin algoritmeihin. Dempsterin-Shaferin teoria ja neuroverkot ovat paljon käytettyjä algoritmeja, mutta näiden algoritmeihin heikkouksia ovat muun muassa objektiivisuuden puute, konfliktit ja tarve toiminnallisille algoritmeille. Tähän ratkaisuna tutkimusta on suunnattu syviin neuroverkkoihin, jotka vaikuttavat korjaavan muiden menetelmien rajoitteita. Vaaditaan kuitenkin lisää kehitystyötä syvien neuroverkkojen potentiaalin hyödyntämiseksi. Parhaan lopputuloksen kannalta suositellaan, että kehitettäisiin vikadiagnosijärjestelmiä, joissa yhdistellään erilaisia algoritmeja.

Vikadiagnosijärjestelmien tulevaisuuden suuntauksena vaikuttaisi olevan useiden lähteiden datafuusioon perustuvat järjestelmät, jotka ovat pilvipohjaisia esineiden internetin järjestelmiä. Järjestelmien kehitystä tukevat tietokoneiden kehittynyt laskentateho ja tiedonsiirron nopeuttava 5G-teknologia. Teknologian tulee olla kuitenkin tarkoin testattua ennen kuin sitä voidaan käyttää korkean vaatimustason järjestelmissä, kuten liikkuvien raskaiden työkoneiden hydraulijärjestelmissä.

Avainsanat: datafuusio, hydraulijärjestelmä, vikadiagnosi, anturi, monianturidatafuusio.

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

# SISÄLLYSLUETTELO

1. JOHDANTO .....	1
2. RASKAIDEN TYÖKONEIDEN HYDRAULIIKKA.....	3
2.1 Hydrauliiikan perusteet .....	3
2.2 Hydraulijärjestelmä.....	5
3. DATAFUUSION MENETELMÄT .....	8
3.1 Datafuusio.....	8
3.2 Monianturidatafuusio.....	11
4. HYDRAULIJÄRJESTELMIEN KUNNONVALVONTA .....	15
4.1 Hydraulijärjestelmien vikaantuminen .....	15
4.2 Hydraulijärjestelmien kunnonvalvontateknologia .....	15
4.3 Hydraulijärjestelmien vikadiagnoosit.....	17
5. DATAFUUSIOON PERUSTUVA HYDRAULIJÄRJESTELMIEN VIKADIAGNOSOINTI.....	19
5.1 Datafuusioon perustuva vikadiagnoosijärjestelmä .....	19
5.2 Syväoppiminen datafuusiossa.....	21
5.3 Menetelmien soveltuvuus hydraulijärjestelmien vikadiagnosointiin .....	24
6. YHTEENVETO.....	28
LÄHTEET .....	30

# KUVALUETTELO

<i>Kuva 1. Yksinkertaistettu tyypillinen hydraulijärjestelmä (mukailtuna lähteestä Glass et al. 2017).....</i>	<i>6</i>
<i>Kuva 2. Yksinkertainen hydraulijärjestelmä (mukailtuna lähteestä Zhang 2018, s. 13).....</i>	<i>7</i>
<i>Kuva 3. JDL-datafuusiomallin rakenne (mukailtuna lähteestä Castanedo 2013) .....</i>	<i>10</i>
<i>Kuva 4. Datafuusiomallit: a) Dasarathyn funktionaalinen datafuusiomalli, b) Muokattu MSDF-malli (mukailtuna lähteestä Raol 2015, s. 7).....</i>	<i>11</i>
<i>Kuva 5. SDF:n prosessointiarkkitehtuurit: a) keskitetty, b) hajautettu ja c) hierarkkinen (mukailtuna lähteestä Raol 2015, s. 10).....</i>	<i>13</i>
<i>Kuva 6. Monianturi-informaatiofuusion kerrosmalli (mukailtuna lähteestä Yang et al. 2012).....</i>	<i>20</i>
<i>Kuva 7. Diagnostiikkaohjelman kaavioesitys (mukailtuna lähteestä Yang et al. 2012) .....</i>	<i>21</i>
<i>Kuva 8. DNN:n kerrokset (mukailtuna lähteestä Baek &amp; Choi 2020) .....</i>	<i>23</i>
<i>Kuva 9. Hydraulipumpun vikadiagnoosi (mukailtuna lähteestä Han et al. 2010).....</i>	<i>25</i>

# LYHENTEET JA MERKINNÄT

DFP	engl. data fusion processes, datafuusioprosessit
SDF	engl. sensor data fusion, anturidatafuusio
MSDF	engl. multisensor data fusion, monianturidatafuusio
JDL	engl. Joint Directors of Laboratories, laboratorioiden yhteisjohtajat
DOD	engl. Department of Defense, Yhdysvaltain puolustusministeriö
SNW	engl. sensor network, anturiverkko
HCI	engl. human-computer interaction, ihminen-tietokone vuorovaikutus
FL	engl. fuzzy logic, sumea logiikka
D-S	engl. Dempster–Shafer theory, Dempsterin–Shaferin teoria
CP	engl. central processor, keskusprosessori
IoT	engl. Internet of Things, esineiden internet
CBM	engl. condition-based maintenance, kuntoperusteinen huolto
AI	engl. artificial intelligence, tekoäly
DNN	engl. deep neural network, syvä neuroverkko
A/D	engl. analog-to-digital, analogia-digitaali
DBN	engl. deep belief network, syvän uskon verkko
CNN	engl. convolutional neural network, konvoluutioneuroverkko
AE	engl. autoencoder, autoenkooderi
RNN	engl. recurrent neural network, toistuva neuroverkko
SAE	engl. stacked autoencoder, pinottu autoenkooderi
SVM	engl. support-vector machine, tukivektorikone
$F$	voima
$p$	paine
$A$	pinta-ala
$Q_t$	teoreettinen virtausnopeus
$D_v$	kierrotilavuus
$n$	pyörimisnopeus
$P_m$	pumpun teho
$T$	vääntömomentti
$\omega$	kulmanopeus
$P_h$	hydraulinen teho
$Q$	virtausnopeus

# 1. JOHDANTO

Liikkuvia raskaita työkoneita, kuten kuorma-autoa ja kaivinkonetta, käytetään monialaisesti teollisuudenaloilla. Näiden työkoneiden toimintaympäristöt, vaihtelevat työkuormat ja monimutkaiset järjestelmät asettavat haasteita käytetylle tekniikalle. Haasteita pyritään selvittämään kunnonvalvontateknologialla, jolla on tärkeä merkitys vikatilojen ja vaaratilanteiden välttämiseksi. Kunnonvalvontateknologian tavoitteisiin pääsemiseksi tarvitaan anturitekniologiaa ja menetelmiä datan käsittelyyn. (He & Jiang 2020)

Hydrauliikalla saadaan siirrettyä tehoa nesteen paineen ja virtauksen avulla. Hydrauliikkaa hyödynnetään liikkuvissa raskaissa työkoneissa, joissa hydraulijärjestelmillä voidaan toteuttaa toiminnallisuutta. Esimerkiksi kuorma-auton kippaaminen voidaan toteuttaa hydraulijärjestelmällä. Hydraulijärjestelmän etuja ovat muun muassa nopea vaste, kuormajäykkyys, vakaus ja tehoteho. Hydraulijärjestelmien parametreja täytyy monitoroida anturitekniologialla, jotta säilytetään riittävä turvallisuus ja tarkkuus kunnossapidon kriteereillä mitattuna. (Zhang 2018, s. 1–20; Dai et al. 2019)

Datafuusio on rakenteellinen malli eri lähteiden datan ja tiedon yhdistämisellä. Datafuusion menetelmillä saadaan kohdejärjestelmästä jollakin tapaa informatiivisempi kuvaus. Datafuusion onnistumiseksi tiedeyhteisössä on kehitetty erilaisia datafuusiomalleja ohjaamaan datafuusioprosesseja. Mallien ja menetelmien valitseminen tulee tehdä järjestelmäkohtaisesti. (Castanedo 2013; Raol 2015, s. 1–11)

Hydraulijärjestelmistä saatava data voidaan yhdistää datafuusion menetelmin, mitä voidaan hyödyntää esimerkiksi vikadiagnostiikassa. Datafuusiota vaikeuttaa hydraulijärjestelmien ominaisuudet, joiden takia antureilla kerätty data voi muodostua vaikeasti tulkittavaksi. Jotkin uudet menetelmät, kuten syvät neuroverkot, pyrkivät ratkaisemaan aiempien menetelmien rajoitteita. Uusien menetelmien kehittäminen on tärkeää, jotta saataisiin kehitettyä järjestelmästä riippumattomia toimintatapoja. (Yang et al. 2012; Dai et al. 2019)

Tämä kandidaatintyö on kirjallisuuskatsaus, jonka tavoitteena on selvittää, mitä on datafuusio, miten datafuusion menetelmiä voidaan hyödyntää hydraulijärjestelmien vikadiagnostiikassa, ja miten hydraulijärjestelmien vikadiagnostiikka on kehittymässä. Soveltuvuutta mietitään liikkuvien raskaiden työkoneiden hydraulijärjestelmien kannalta. Työssä

ei tehdä selvitystä yksittäiselle sovelluskohteelle, mikä edellyttäisi järjestelmän tuntemusta ja oikeaa dataa. Työssä ei myöskään selitetä datafuusion matemaattisia menetelmiä. Työn alussa käsitellään hydraulijärjestelmien ja datafuusion perusteita. Neljännessä luvussa käydään läpi hydraulijärjestelmien vikaantumista ja kunnonvalvontaa. Viidennessä luvussa selvitetään, miten datafuusiota voidaan hyödyntää hydraulijärjestelmien vikadiagnooseissa.

## 2. RASKAIDEN TYÖKONEIDEN HYDRAULIIKKA

### 2.1 Hydrauliiikan perusteet

Hydrauliiikalla tarkoitetaan voiman ja liikkeen välittämistä nesteen välityksellä (Glass et al. 2017). Tehonsiirto tapahtuu nesteen paineen ja virtauksen avulla. Nesteet sopivat hyvin tehonsiirtoon niiden ominaisuuksien takia. Paine leviää nesteessä tasaisesti eri suuntiin, minkä takia tehonsiirtoa eivät rajoita geometriset muodot. Neste on liki kokoonpuristumatonta, mikä mahdollistaa korkean paineen vähäisellä nesteen tilavuuden muutoksella ja suurten voimien välittämisen pienellä nesteen määrällä. Hydrauliiikalla saavutetaan hyvä tehonsiirto järjestelmän kokoon nähden. Edellä mainittujen ominaisuuksien takia hydrauliiikka soveltuu tehonsiirtoon raskaissa työkoneissa, kuten kaivinkoneessa tai kuorma-autossa, joissa tarvitaan riittävästi tehoa raskaiden kuormien siirtämiseen. Hydraulijärjestelmällä tarkoitetaan hydraulikomponenteista koostuvaa järjestelmää, joka kuljettaa hydraulinestettä ja pystyy suorittamaan jonkin toiminnallisuuden. (Zhang 2018, s. 1–20)

Hydraulineste suorittaa monia funktionaalisuuksia ja se on hydraulijärjestelmien tärkein osa. Hydraulinesteen tärkein tehtävä on tehon välittäminen ja myös hydraulijärjestelmän voiteluaineena toimiminen. Hydraulinestettä sanotaan usein hydrauliiikkaöljyksi, koska se on usein öljypohjaista. Hydraulinesteen kyky välittää voimaa perustuu Pascalin lakiin

$$F = pA, \tag{1}$$

joka kuvaa voiman ( $F$ ), paineen ( $p$ ) ja pinta-alan ( $A$ ) välistä yhteyttä. Pascalin lain mukaan, kun tilassa olevaan nesteeseen kohdistetaan voima, paine leviää tasaisesti kaikkialle, ja se on verrannollinen käytettävään voimaan. Pascalin laki antaa perustan nesteen staattisen paineen ja nesteiden tehonsiirron ymmärtämiselle. (Zhang 2018, s. 6–7)

Hydraulipumput ovat hydraulijärjestelmien hydraulista tehoa tuottavia komponentteja. Hydraulipumput muuttavat kineettistä mekaanista energiaa hydrauliseksi potentiaalienergiaksi. Hydraulipumpuille välitetään mekaanista tehoa ulkoisesta lähteestä, joka on liikkuvien raskaiden työkoneiden järjestelmissä yleensä polttomoottori. Hydraulipumput tuottavat hydraulinesteen virtauksen. Pumppujen poistovirtauksen paine tai järjestelmän käyttöpainne määräytyy järjestelmän kuormituksen mukaan. Järjestelmän kuormitus koostuu virtaavan nesteen vastuksesta putkistossa ja ulkoisen kuorman määrästä vastuksesta. Paine on kuitenkin tärkeä pumpun toimintaa kuvaavaa parametri. Pumppuvalmistajat kuvaavat pumpun paineominaisuuksia usein neljällä parametrillä: nimellis-



purkauspaine, maksimipurkauspaine, minimipurkauspaine ja suurin tulopaine. Muut tärkeät parametrit pumpun toiminnan kannalta ovat pyörimisnopeus ja kierrostilavuus. Pumppujen kapasiteetti määritellään kierrostilavuuden ja pyörimisnopeuden perusteella. Teoreettinen tilavuus kuvaa, miten suuren nestemäärän pumppu pystyy tuottamaan yhden kokonaisen kierroksen aikana. Teoreettista tilavuutta kuvaa yhtälö

$$Q_t = D_v n, \quad (2)$$

jossa  $Q_t$  on teoreettinen virtausnopeus,  $D_v$  on kierrostilavuus ja  $n$  on pumpun pyörimisnopeus. Pumpputyyppejä voidaan ryhmitellä niiden nesteen syrjäyttämistavan mukaan kiinteätilavuus- ja muuttuvatilavuuspumppuihin. Ryhmittely voidaan tehdä myös rakenteen mukaan, ja tyypillisimpiä pumppuja ovat mäntäpumppu, siipipumppu ja hammaspyöräpumppu. Pumpputyypin valinta riippuu käyttötarkoituksesta. Esimerkiksi liikkuvissa työkonneissa suositaan mäntäpumppuja niiden hyvän tehopainosuhteen takia, ja maatalouskoneissa hammaspyöräpumppuja niiden edullisuuden ja kestävyys takia. (Zhang 2018, s. 25–26)

Hydraulisten toimilaitteiden tehtävänä on muuttaa hydraulinesteen potentiaalienergia mekaaniseksi tehoksi, eli hydraulinesteen paine ja virtaus muutetaan toimilaitteen voimaksi tai nopeudeksi kuorman liikuttamiseksi. Hydraulisylinteri ovat lineaarista liikettä välittäviä hydraulisia toimilaitteita. Tyypillisin hydraulisylinteri on yksisauvainen kaksitoiminen hydraulisylinteri. Hydraulimoottori on pyörivää liikettä välittävä hydraulinen toimilaitte. Erilaiset hydraulimoottorit toimivat samanlaisen periaatteen mukaisesti: paineistettu neste suunnataan painealalle jatkuvan pyörimisen aikaan saamiseksi, ja tämä yhteys välitetään akselille mekaaniseksi tehoksi. Hydraulimoottoreiden rakenne, koko ja toiminta vaihtelevat käyttötarkoituksen mukaan. Hydraulimoottorityyppejä ovat muun muassa mäntäkoneet ja siipimoottorit. (Zhang 2018, s. 109–126)

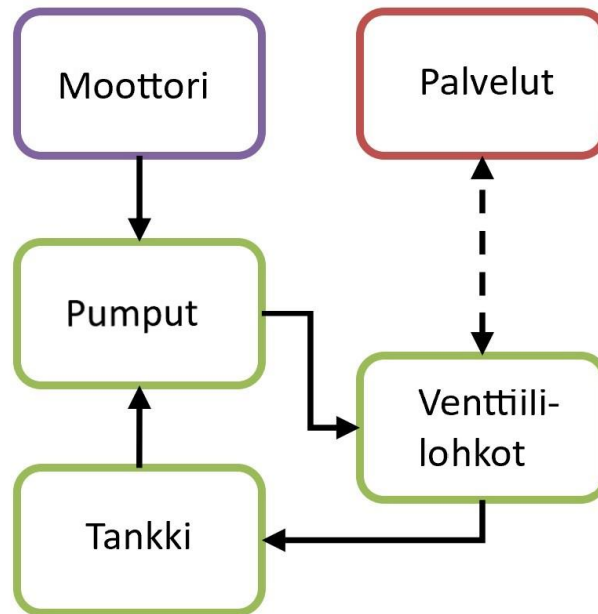
Hydrauliset ohjausventtiilit ovat hydraulisia komponentteja, joiden tehtävänä on ohjata hydraulisen tehon välitystä. Ohjausventtiilejä käytetään hydraulinesteen paineen, virtauksen ja suunnan ohjaamiseen. Ohjausventtiilejä voidaan luokitella käyttötarkoituksen mukaan: suuntaventtiilit, paineventtiilit ja virtausventtiilit. Erilaiset venttiilit eivät eroa paljon toisistaan rakenteellisesti. Rakenteellisesti ohjausventtiilit voidaan kategorisoida patruunaventtiileihin ja luistiventtiileihin. Patruunaventtiileistä käytetään myös nimeä iskuventtiili sen rakenteen takia. Patruunaventtiilin toiminta perustuu jousivoimaan, ja se tarvitsee toimiakseen venttiililohkon, joka toimii eräänlaisena kotelona venttiilille. Luistiventtiilit toimivat luisteina, joiden asemaa voidaan muuttaa eri kontrollimekanismeilla. (Zhang 2018, s. 55–57)

Hydraulijärjestelmän linjat koostuvat johtimista ja liittimistä, jotka tarjoavat reitin hydraulisen tehon välittämiseen. Sovelluskohteen johtimet ovat letkuja tai putkia. Putket ovat jäykkiä metallisia johtimia, ja letkut ovat joustavia synteettisestä kumista tai termoplastista materiaalista valmistettuja. Taipuvuuden takia letkut soveltuvat hyvin erilaisiin liikkuviin työkoneluihin. Letkut voidaan asentaa optimaalisesti, ja ne kestävät värähtelyä, liikkettä sekä painevaihteluja. Liittimien tehtävänä on liittää letkut hydraulisiin laitteisiin. (Zhang 2018, s. 93–95)

## 2.2 Hydraulijärjestelmä

Hydraulijärjestelmän voidaan ajatella koostuvan hydraulipumpusta, voimalähteestä, josta pumppu saa mekaanisen energiansa, hydraulitankista, suodattimista, hydraulioiljystä, hydraulisesta toimilaitteesta, hydraulisista suuntaventtiileistä, letkuista ja liittimistä. Hydraulijärjestelmien tavoitteena on toimittaa hydraulista tehoa jonkin toiminnallisuuden suorittamiseksi, mitä hyödynnetään liikkuvissa raskaissa työkonelissa. Esimerkiksi kuorma-auton kippausjärjestelmä ja kaivinkoneen kaivuulaitteen liike voidaan toteuttaa hydraulijärjestelmillä. (Glass et al. 2017; Zhang 2018, s. 2–4) Lohkokaavio esityksenä yksinkertaisen hydraulijärjestelmän voidaan ajatella koostuvan kuvan 1 kaltaisesta kaivinkoneen hydraulijärjestelmästä: Moottori edustaa polttomoottoria eli voimalähdettä. Pumput tarkoittavat hydraulipumppuja. Tankki eli hydraulitankki on hydraulijärjestelmissä hydraulioiljyn varastointiin käytetty komponentti. Venttiililohkot eli venttiilit ohjaavat hydraulisen tehon välitystä. Palvelut tarkoittavat toimilaitteita, ja kuvan järjestelmässä toimilaitteena on hydraulisylinteri. (Glass et al. 2017)

Hydraulijärjestelmästä käytetään nimitystä hydraulinen voimansiirtojärjestelmä, kun se on suunniteltu siirtämään tehoa hydrauliiikan välityksellä. Energiansiirto tapahtuu 3:ssa eri vaiheessa: ensin mekaaninen kineettinen energia muutetaan paineena hydraulines-teen potentiaalienergiaksi, sitten potentiaalienergia kuljetetaan hydraulijärjestelmän välityksellä kohteeseen, ja lopuksi potentiaalienergia muutetaan työksi ja takaisin kineettiseksi energiaksi. Energiansiirtoprosessi voidaan soveltaa kuvaan 1 seuraavasti: moottori- ja pumppulohko vastaavat kineettisen energian muunnoksesta potentiaalienergiaksi, ja palveluissa (toimilaitteet) muutetaan potentiaalienergia työksi ja kineettiseksi energiaksi. (Glass et al. 2017; Zhang 2018, s. 2–4)

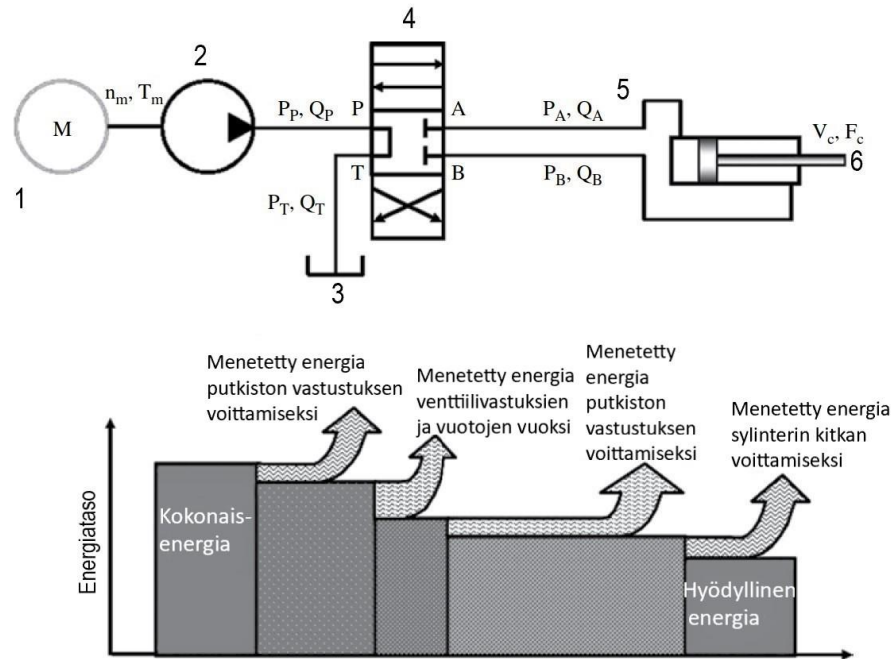


**Kuva 1.** Yksinkertaistettu tyypillinen hydraulijärjestelmä (mukailtuna lähteestä Glass et al. 2017)

Hydraulijärjestelmiä käytetään monialaisesti erilaisissa työkoneissa. Hydraulijärjestelmissä saavutetaan nopea vaste, suuri tehotiheys, merkittävä kuormajäykkyys ja stabiilius (Dai et al. 2019). Teknologian kehittyminen monipuolistaa hydraulijärjestelmiä, kun elektroniikka saadaan yhdistettyä osaksi hydraulijärjestelmiä (Zhang 2018, s. 238). On hyvä huomata, että todellisuudessa hydraulijärjestelmien energiansiirto ei ole häviötöntä. Hydraulisissa voimansiirtojärjestelmissä on erilaisia vastusvoimia ja häviöitä, mihin energiaa kuluu ennen kuin se saadaan välitettyä toimilaitteelle. Häviöitä syntyy muun muassa putkiston vastuksesta, venttiilien vastuksesta, nesteen vuodoista ja toimilaitteen kitkavoimista. Kulunutta energiaa ei voida käyttää mekaanisena energiana, vaan se muuttuu lämpöenergiaksi, joka voidaan nähdä hydraulinesteen lämpötilan nousuna. Häviöiden ja hallitsemattoman paineen nousun takia hydraulijärjestelmä tulee suunnitella, niin että paineistettu neste saadaan purettua järjestelmästä, jos järjestelmä ei tee työtä. (Zhang 2018, s. 12–13)

Kuvassa 2 on esitettyä yksinkertainen hydraulijärjestelmä ja energiansiirtoprosessi häviöineen: Ensin moottori (1) välittää mekaanisen energian pumpulle (2). Pumppu pystyy välittämään energian tietyllä hyötysuhteella järjestelmään. Putkisto (5) kuljettaa paineistettua nestettä, ja putkistossa syntyy häviöitä vastusvoimien takia. Hydrauliventtiilit (4) ohjaavat hydraulinesteen suuntaa, ja energiahäviöitä syntyy venttiilivastuksista ja vuodoista. Toimilaitteella, hydraulisylinterillä, (6) on alhaisin energiataso hydraulijärjestelmässä kuljetuksen aikana muodostuneiden häviöiden takia, ja energiahäviöitä syntyy

sylinterin kitkavoimista. Jos järjestelmä ei tee työtä kuormaan, voidaan paineistettu hydraulineeste ohjata takaisin tankille (3). (Kuva 2)



**Kuva 2.** Yksinkertainen hydraulijärjestelmä (mukailtuna lähteestä Zhang 2018, s. 13)

Hydraulijärjestelmän mekaanista tehoa voidaan kuvata pumpun kykynä välittää moottorilta saatua tehoa tai toimilaitteen kykynä ohjata ulkopuolista kuormaa. Pumpun antama teho saadaan määritetty vääntömomentit ja kulmanopeuden avulla

$$P_m = T\omega, \quad (3)$$

jossa  $P_m$  on pumpun antama teho,  $T$  on ulkoinen vääntömomentti akselille ja  $\omega$  on akselin kulmanopeus. Hydraulijärjestelmän hydraulinen teho määritellään järjestelmän paineen ja nesteen virtauksen perusteella

$$P_h = pQ, \quad (4)$$

jossa  $P_h$  on hydraulijärjestelmän hydraulinen teho,  $p$  hydraulijärjestelmän paine ja  $Q$  hydraulineesteen virtausnopeus. Todellisuudessa tehoissa on huomioitava komponenttien hyötysuhteet, eli missä suhteessa komponentti pystyy välittämään saamansa tehon. (Zhang 2018, s. 13–14)

## 3. DATAFUUSION MENETELMÄT

### 3.1 Datafuusio

Datafuusiolla tarkoitetaan datan ja tiedon yhdistämistä useasta eri lähteestä. Datafuusion tavoitteena on antaa kehittyneempää informaatiota. Kehittyneemmällä informaatiolla tarkoitetaan parempi laatusempaa ja relevantimpaa informaatiota tarkastelun kohteesta. (Castanedo 2013) Datafuusion vaikutuksesta puhutaan eri datalähteiden synergiana eli kumuloituvana yhteisvaikutuksena. Datafuusion tuloksena saadaan parannettua tarkkuutta, laatua ja virhevarmuutta verrattuna tilanteisiin, joissa käytettäisiin vain yhtä lähdettä tarkastelun kohteen analysoimiseen. (Raol 2015) Datafuusio on taustaltaan monitieteinen alue, johon liittyy useita eri aloja. Menetelmää on vaikea luokitella tai rajata selkeästi. Datafuusio on enemmänkin rakenteellinen malli. Datafuusioprosessit (DFP) voidaan luokitella karkeasti abstraktiotasolla kolmeen eri kategoriaan: datan yhdistäminen eli matalan tason fuusio, tilan arviointi eli keskitason fuusio ja päätösfuusio eli korkean tason fuusio. (Castanedo 2013; Raol 2015, s. 2) Usein termejä datafuusio ja informaatiofuusio käytetään synonyymeinä, mutta jossakin yhteydessä datafuusiolla viitataan raakadatan yhdistämiseen, kun taas informaatiofuusio viittaa jo käsitellyn datan yhdistämiseen (Castanedo 2013). Raolin (2015) mukaan muita datafuusion kanssa rinnastettavia termejä ovat anturidatafuusio (SDF) ja monianturidatafuusio (MSDF).

Matalan tason fuusiossa dataa yhdistetään useista eri lähteistä, esimerkiksi antureista. Tavoitteena on tuottaa uutta ja käytännöllisempää dataa, kun mitä saataisiin käyttämällä vain yhtä lähdettä. (Raol 2015, s. 2) Prosessin ideana on vähentää yhden lähteen rajoitteita, kuten mittausten rajallista aikaväliä ja mittausvirhettä. Käyttämällä useampaa lähdettä saavutetaan kohdejärjestelmästä joukko havaintoja, joilla on sama kohde. (Castanedo 2013)

Keskitason fuusiossa yhdistetään ominaisuuksia, kuten reunoja tai viivoja kuvien yhdistelyssä. Ominaisuuksien perusteella luodaan ominaisuuskartta, jota voidaan hyödyntää tiedon pilkkomiseen pienempiin osiin tai uusien asioiden havaitsemiseen. (Raol 2015, s. 2) Ominaisuuksia yhdistämällä pyritään arvioimaan kohteen liikettä ja muutosta havaintojen sekä mittausten perusteella. Keskitason fuusion tekniikat tunnetaan joskus jäljitystekniikkana niiden luonteen takia. Monesti ennen keskitason fuusiota dataa on käsitelty matalan tason fuusiossa. Tämän jälkeen dataa voidaan käsitellä sopivilla mate-

maattisilla menetelmillä, jotta löydetään parhaiten tietoa kuvaava parametrijoukko. Matemaattiset menetelmät hyödyntävät muun muassa vektoritiloja ja todennäköisyysteoriaa. Tunnetuin käytetty arviointitekniikka on Kalmanin suodatin. (Castanedo 2013)

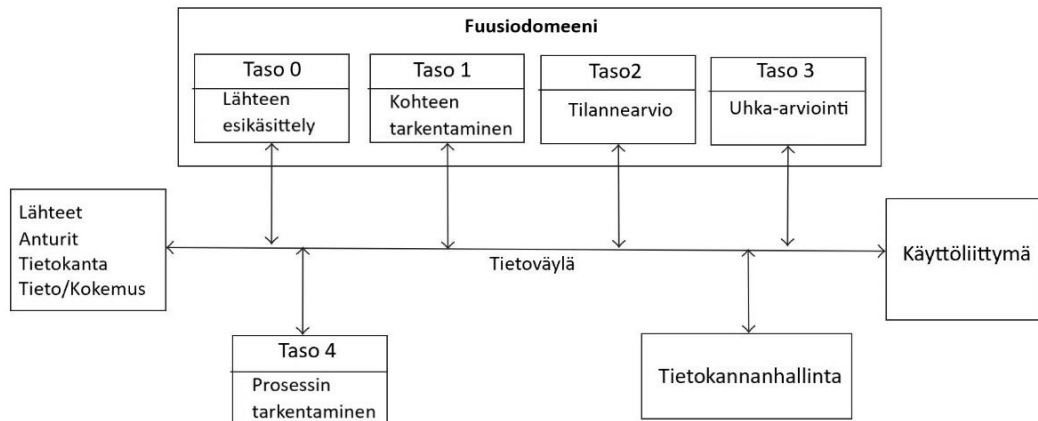
Korkean tason fuusiossa tehdään päätöksiä tietämykseen perustuen. Tietämystä saadaan monelta datafuusioalueelta. Tekniikat perustuvat tapahtumiin ja toimintoihin, mitä on saatu havaituista kohteista. Tekniikat käyttävät usein symbolista informaatiota, ja fuusioprosessi vaatii epävarmuustekijöiden ja rajoitteiden huomioimisen. Päätökset ovat korkeatasoisia päätelmiä tapahtumista ja toiminnoista. Korkean tason fuusioprosessit sijaitsevat malleissa viimeisimmällä tasoilla. (Castanedo 2013)

Castanedon (2013) mukaan datafuusiossa käytetyt tekniikat ja menetelmät voidaan luokitella malleihin esimerkiksi seuraavien kriteerien mukaan:

- 1) ottamalla huomioon syötetietolähteiden väliset suhteet
- 2) syöte- ja lähtötietolähteiden tietotyypin ja tiedon luonteen mukaan
- 3) käytetyn tiedon abstraktiotasojen perusteella
- 4) Joint Directors of Laboratories (JDL) datafuusiomallin mukaan
- 5) arkkitehtuurityyppien perusteella.

Tämä luokittelu pyrkii ottamaan huomioon vain yleisempiä tekniikoita. (Castanedo 2013) Eri mallit sisältävät datafuusion vaiheita eli tasoja. Tiedon luonteesta riippuen, yksittäinen taso kuuluu johonkin aiemmin määritellyistä abstraktiotason kategorioista (matala, keskitaso ja korkea). (Castanedo 2013; Raol 2015, s. 2–8)

JDL-datafuusiomalli on tunnetuin malli datafuusioyhteisössä. Malli on JDL:n ja Yhdysvaltain puolustusministeriön (DOD) kehittämä. Mallissa on 5 eri tasoa, siihen liittyvä tietokanta sekä tietoväylä tasojen yhdistämiseen (Castanedo 2013). JDL-datafuusiomallissa on 3 päätasoa, tasot 1–3. Malliin liittyy useita alatasoja ja aputehtäviä liittyen tiedonkäsittelyyn, informaation yhdistelyyn ja datafuusiosysteemin suorituskyvyn arviointiin. JDL-malli on toiminnallisesti suunniteltu ja siitä voi olla hyötyjä erilaisilla sovellusalueilla, kuten anturiverkostossa (SNW) tai ihmisen ja tietokoneen välisessä vuorovaikutuksessa (HCI). (Raol 2015 s. 3) Kuvasta 3 nähdään JDL-datafuusiomallin rakenne: lähteen esikäsitteily (Taso 0), kohteen tarkentaminen (Taso 1), tilannearvio (Taso 2), uhka-arviointi (Taso 3), prosessin tarkentaminen (Taso 4), tietoväylä, tietokannan hallinta, käyttöliittymä, lähteet, anturit, tietokannat ja tieto/kokemus.



**Kuva 3.** JDL-datafuusiomallin rakenne (mukailluna lähteestä Castanedo 2013)

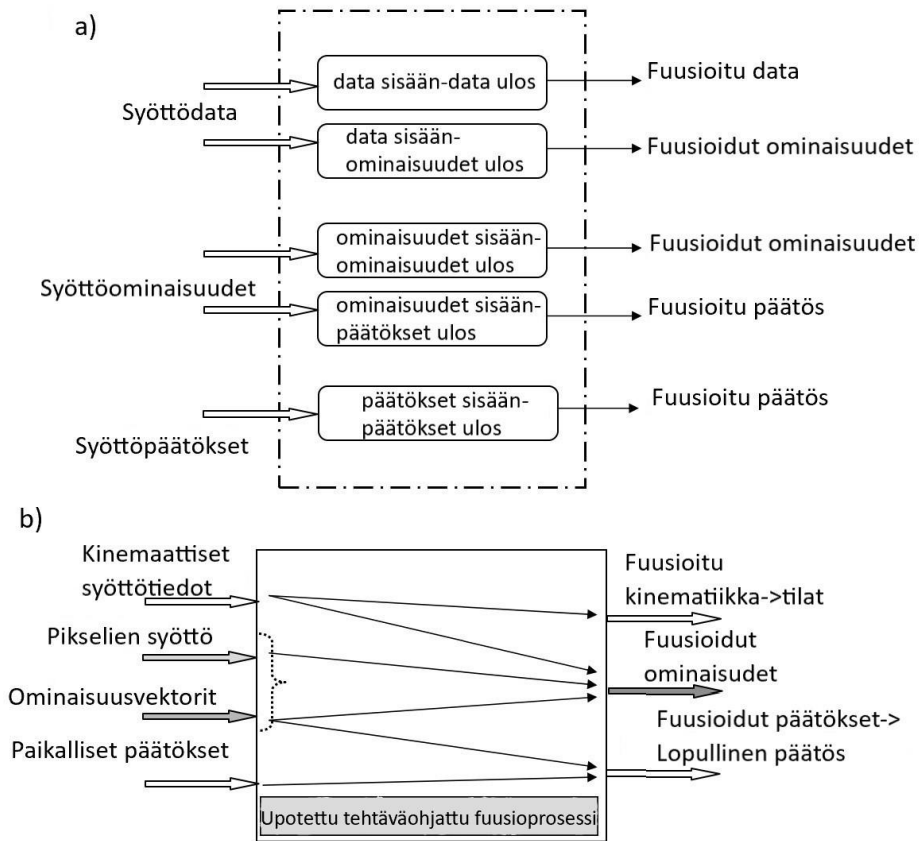
DFP voidaan hahmottaa visuaalisesti prosesseina, joissa syötetään dataa ja saadaan ulostulona yhdistettyä informaatiota. Syöteen ja ulostulon välissä käsitellään dataa sopivalla menetelmällä. Tämä prosessi voidaan nähdä kuvasta 4, jossa menetelmän käyttökohta on laatikoituna sisään- ja ulostulon välissä. Käytetty menetelmä voi olla lineaarinen, epälineaarinen, kertolaskullinen tai se voi perustua esimerkiksi tilastotieteeseen, todennäköisyysteoriaan tai sumeaan logiikkaan (FL). Dasarathyn funktionaalinen malli (kuva 4a) perustuu fuusiofunktion tehtävien sijasta. Mallissa yhdistäminen voi tapahtua abstraktiotason sisällä, mutta myös näiden välillä. Dasarathyn malli on suoraviivainen tulo- ja lähtötietolähteiden välinen malli. Muunneltu MSDF (kuva 4b) on taas upotettu tehtävöihjattu malli, joka auttaa hahmottamaan, kuinka erilaisia datalähteitä yhdistämällä saadaan informaatiolla arvoa. (Raol 2015, s. 7, 11)

Datafuusiossa käytetään algoritmeja datan käsittelyyn. Algoritmien tavoitteena on muokata dataa muotoon, joka on sopiva käyttötarkoitukseen. Lohkokaavioissa algoritmit jäävät piiloon lohkoihin, jossa käsitellään dataa. Esimerkkejä paljon käytetyistä algoritmeista ovat Bayesin kriteerit, pienimmän neliösumman menetelmä, Dempsterin–Shafeerin teoria (D-S), sumea integraaliteoria, neuroverkot, klusterointitekniikka ja tietokanta-teoria. (Bai et al. 2020)

Bayesin menetelmät perustuvat todennäköisyyksiin. Eri ongelmille on omat aiemmat ja jälkimmäiset todennäköisyydet, ja fuusio-ongelma käsitellään jälkimmäisen mukaisesti. Bayesin menetelmät vaativat korkean tason matematiikka ja kaikki todennäköisyydet ovat itsenäisiä. (Bai et al. 2020)

D-S on Bayesin menetelmien laajennus, joka pyrkii poistamaan luotettavuusfunktiolla Bayesin kykenemättömyyden erotella tuntemattoman ja epävarman välisen eron. Todennäköisyyteen käytetään intervalliarviointia. Luotettavuusfunktion subjektiivisuus rajoittaa menetelmän käyttöä. (Bai et al. 2020)

Neuroverkot on laajamittainen hajautettu neurotiedonkäsittelyjärjestelmä, joka voi käsitellä paljon dataa reaaliajassa. Menetelmässä datafuusio voidaan suorittaa lukuisissa neuroneissa samanaikaisesti, millä saadaan nopeutettua datan käsittelyä. (Bai et al. 2020)



**Kuva 4.** Datafuusiomallit: a) Dasarathyn funktionaalinen datafuusiomalli, b) Muokattu MSDF-malli (mukailtuna lähteestä Raol 2015, s. 7)

### 3.2 Monianturidatafuusio

Monianturidatafuusiolla (MSDF) tarkoitetaan teoriaa, tekniikoita ja menetelmiä, mitä käytetään yhdistämään antureista peräisin olevaa dataa. MSDF:n perusidea vastaa ihmisten ja eläinten kykyä muodostaa kokonaiskuva tilanteesta aistihavaintojen, tiedon ja kokemuksen perusteella. Kokonaiskuvan informaation perusteella kyetään tekemään tarvittavat päätökset selviytymisen kannalta. (Mitchell 2012, s. 1) Karray et al. (2013) määrittelevät MSDF:n on koko ajan kasvavana ja kehittyvänä tieteenalana, jonka pyrkimyksenä on parantaa teknologian kykyä yhdistellä eri lähteistä peräisin olevaa informaatiota kokonaiskuvan parantamiseksi.

Mitchellin (2012, s. 3–4) mukaan Boudjemaan ja Forbesin mallissa MSDF-järjestelmät voidaan luokitella sen mukaan, mitkä järjestelmän osat ovat fuusioitu. Anturien välisessä



fuusiossa yhdistetään samaa ominaisuutta mittaavat anturit. Ominaisuuksien välisessä fuusiossa yhdistetään eri ominaisuutta mittaavat anturit, jota saadaan selvitetty jokin näiden anturien yhdessä määräämä ominaisuus. Toimialueiden välisessä fuusiossa useat anturit mittaavat samaa ominaisuutta useilla eri asteikoilla ja toimialueilla. Aikojen välisessä fuusiossa sen hetkiset mittaukset yhdistetään aiemman historiassa olevan tiedon kanssa. Useasti sen hetkiset tiedot eivät riitä määrittämään järjestelmää tarkasti, ja historialliset tiedot ovat sisällytettävä, jotta järjestelmä saadaan määritettyä tarkasti. (Mitchell 2012, s. 3–4)

Durrant-Whyte malli määrittelee MSDF-järjestelmät antureiden asetelman perusteella. Mallissa on 3 peruskategoriaa: komplementaarinen (engl. complementary), kilpailuhenkinen (engl. competitive) ja yhteistoiminnallinen (engl. cooperative). (Mitchell 2012, s. 4)

Komplementaarisessa asetelmassa anturit eivät ole toisistaan riippuvia. Anturit havainnoivat järjestelmää eri alueilla ja pyrkivät muodostamaan kokonaiskuvan järjestelmästä. Komplementaarinen asetelma pyrkii ratkaisemaan epätäydellisyyden ongelman. (Mitchell 2012, s. 4; Raol 2015, s. 8–9)

Kilpailuhenkisessä tai redundantissa asetelmassa jokainen anturi mittaa samaa ominaisuutta itsenäisesti. Asetelma on vankka ja vikavarma. Tämänkaltaisella asetelmalla saadaan vähennettyä epävarman ja virheellisen mittauksen vaikutusta eliminointiprosesseilla. Kilpailuhenkistä asetelmaa käytetään järjestelmissä, jossa turvallisuus on todella tärkeää, kuten lentoteollisuudessa. (Mitchell 2012, s. 4; Raol 2015, s. 8–9)

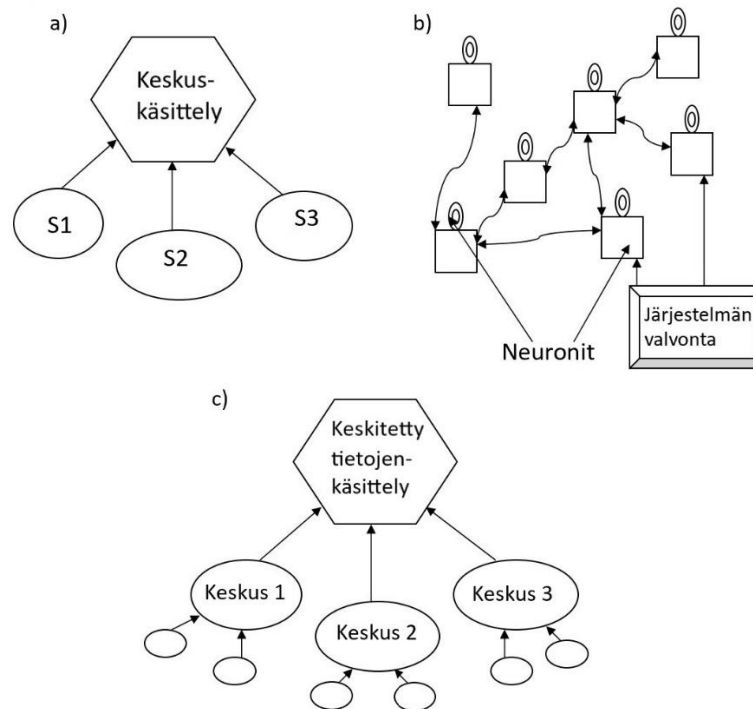
Yhteistoiminnallisessa asetelmassa informaatiota saadaan kahdesta tai useammasta anturista. Asetelma pyrkii johtamaan informaatiota, jota ei olisi mahdollista saada yhdellä anturilla. (Mitchell 2012, s. 4) Esimerkiksi 3D-kuvan johtaminen kahdesta 2D-kuvasta onnistuu, kun tarkasteltavasta alueesta saadaan 2D-kuvat hieman erilaisissa tulokulmissa, ja syvyystiedot yhdistetään oikeantyyppisellä fuusioinnilla. Esimerkissä täytyy huomioida, että ennen 3D-kuvan johtamista on yksittäisten antureiden data käsiteltävä. (Raol 2015, s. 8–9)

MSDF:n arkkitehtuurimallilla tarkoitetaan antureiden asetelmaa järjestelmässä. Arkkitehtuurimallin idea voidaan esittää anturidatafuusion (SDF) arkkitehtuurimallien avulla (kuva 5). Malleja ovat keskitetty, hajautettu ja hierarkkinen fuusio. (Raol 2015, s. 9–10) Arkkitehtuurimalli auttaa hahmottamaan järjestelmän yksittäiset moduulit ja datan virtaamisen moduulien välillä (Mitchell 2012, s. 7).

Keskitetyssä mallissa (kuva 5a) anturien raakadata viedään keskusprosessorille (CP), jossa data yhdistetään kokonaiskuvan muodostamiseksi. Tämänkaltaisen menettely on datatason fuusiota. (Raol 2015, s. 10, 209)

Hajautetussa mallissa (kuva 5b) antureilla on omat prosessointijärjestelyt. Malli koostuu antureista ja sen omasta prosessointiyksiköstä, neuroneista (engl. sensor nodes), jotka vastaanottavat dataa sekä välittäjistä (engl. medium), jotka kytkevät kaikki komponentit toisiinsa. Mallissa datafuusio tapahtuu paikallisissa neuroneissa ja informaatio liikkuu viereisten neuronien välillä. CP:lle ei ole tarvetta. (Raol 2015, s. 212)

Hierarkkisessa mallissa (kuva 5c) informaatio virtaa progressiivisesti kohti korkeampaa tasoa. Informaatio virtaa rinnakkaisissa seurantajärjestelmissä, jonka jälkeen informaatio yhdistetään paikallisesti ja tila arvioidaan, jonka jälkeen informaatio johdetaan eteenpäin. Korkeimmalla tasolla CP:llä voidaan muodostaa globaalikuva mitattavasta järjestelmästä. Hierarkkinen malli vähentää CP:n kuormitusta, mutta silti pystytään säilyttämään hyvä kontrolli aliprosessoinneissa. (Raol 2015, s. 210–211)



**Kuva 5.** SDF:n prosessointiarkkitehtuurit: a) keskitetty, b) hajautettu ja c) hierarkkinen (mukailluna lähteestä Raol 2015, s. 10)

MSDF:ssä käytetyt algoritmit ovat piilossa rakenteellisissa malleissa kohdissa, jossa yhdistetään eri datalähteitä. Algoritmien pitää pystyä fuusioimaan dataa arkkitehtuurista tai järjestelmän koosta riippumatta. Algoritmien tehtävänä on ratkaista dataan liittyviä ongelmia, kuten epätäydellisyys, korreloitavuus, epäjohdonmukaisuus ja erilaisuus. Ongelmat ovat tapauskohtaisia ja sen takia järjestelmien tunteminen on tärkeää. Datafuusion ja MSDF:n laajentuessa uusiin sovelluksiin, on tarvetta uusille algoritmeille. Monialaisuuden takia olisi hyvä löytää sovellusalueesta riippumattomia toimintatapoja. (Karray et al. 2013)

MSDF:ää käytetään esineiden internetin (IoT) järjestelmissä. Esimerkiksi raskaan teollisuuden ja tehdasturvallisuuden tehtävissä anturien määrä ja kerättävä informaatio kasvavat suureksi, mikä aiheuttaa haasteita anturien informaation tulkitsemiseen. (Bai et al. 2020) Tähän ratkaisuna tietokoneiden laskentatehon kasvaminen ja 5G-teknologia tulevat vaikuttamaan myönteisesti anturipohjaisten järjestelmien suorituskyvyn kehitykseen (Huang et al. 2020).

## 4. HYDRAULIJÄRJESTELMIEN KUNNONVALVONTA

### 4.1 Hydraulijärjestelmien vikaantuminen

Hydraulijärjestelmien vikaantumiset voivat olla monisyisiä ja vaikeasti jäljitettävissä. Monimutkaiset hydraulijärjestelmät voivat jakaantua erilaisiin alijärjestelmiin, ja yksittäisen komponentin vika voi vikaannuttaa komponentin lisäksi alijärjestelmän tai koko järjestelmän. Näin järjestelmän koon kasvaessa vikaantumiseen johtavien tekijöiden määrä kasvaa tyypillisesti eksponentiaalisesti. Vian jäljittämisen kannalta tämä on vaikea tilanne, koska hydraulijärjestelmän signaalit ovat muutenkin vaikeasti tulkittavasti. Kasvava vikasyiden määrä lisää vian syiden mahdollista limittymistä. (Dai et al. 2019)

Yleisiä vikoja hydraulijärjestelmissä ovat esimerkiksi: öljyn vuotaminen, hankaus, korrosio, väsymys, kavitaatiot, hydraulisen paineen häiriöt, erilaiset murtumat osissa ja osien jumittuminen (Yang et al. 2012; Dai et al. 2019). Jotkin viat voivat olla paikallistettavasti tietyn hydraulijärjestelmän komponentin toimintaan ja siksi on tärkeää tiedostaa, miten viat ovat helppoiten jäljitettävissä.

Yleisesti hydraulioöljyn kontaminaatio eli saastuminen on suurin syy hydraulijärjestelmien vikoihin. Kontaminaatiolla tarkoitetaan hydraulineesteelle vierasta materiaalia, jolla on haitallinen vaikutus hydraulioöljyn suorituskykyyn. Basun et al. (2012) mukaan 70 % hydraulijärjestelmien vioista johtuu hydraulioöljyn kontaminaatiosta, mutta Glassin et al. (2017) mukaan jopa 90 % vioista voidaan paikallistaa öljyn kontaminaatioon. Tämän takia hydraulioöljyn täytyy olla korkealaatuista, jotta hydraulijärjestelmää voidaan operoida luotettavasti. (Basu et al. 2012) Myös monet muut viat, kuten komponenttien kuluminen, voidaan havaita epäsuorasti öljyn kontaminaatiosta, kun komponenteista irtoavat metallipartikkelit kulkeutuvat hydraulioöljyyn. (He & Jiang 2020) Lisäksi kontaminoitunut öljy voi aiheuttaa toisen komponentin vikaantumisen joko kuljettamalla partikkelin toiseen komponenttiin jumittaen sen tai se voi aiheuttaa korkean vastusvoiman, joka estää esimerkiksi suuntaventtiilin toiminnan.

### 4.2 Hydraulijärjestelmien kunnonvalvontateknologia

Hydraulijärjestelmien kunnonvalvontateknologia on anturiteknologian sovellusalue. Liikuvien raskaiden työkoneiden hydraulijärjestelmien kunnonvalvontateknologialla pyritään tarkkailemaan muun muassa hydraulioöljyn saastumista, hydraulioöljyn vuotoja, hydraulista painetta, virtausnopeutta, lämpötilaa, värähtelyjä hydraulikkakomponenteista ja

koko järjestelmän toimintaa. (Yang et al. 2012; He & Jiang 2020) Antureiden tavoitteena on kerätä hydraulijärjestelmästä monipuolista informaatiota, jota käsittelemällä saadaan arvioitua järjestelmän toimivuutta eri osatekijöiden kannalta (He & Jiang 2020). Tarkastellaan seuraavaksi kunnonvalvontateknologiaa muutamien esimerkkien avulla.

Kontaminaation valvontajärjestelmät ovat erilaisten hydraulioöljyyn liittyvien parametrien, kuten lämpötilan, viskositeetin ja kontaminaatiotasojen tarkkailua. Basun et al. (2012) mukaan öljyn kontaminaation estämiseen on 2 mahdollista toimintatapaa: järjestelmän sisäinen (engl. online) ja järjestelmän ulkoinen (engl. offline) suodattaminen. Järjestelmän ulkoisen suodatuksen etuna on suodatusjärjestelmän riippumattomuus pääjärjestelmästä, mikä mahdollistaa suodatusjärjestelmän huollon ja asennuksen erillisesti. Sisäinen suodatusjärjestelmä on parempi, jos halutaan suojata tiettyjä komponentteja kontaminaatiolta. (Basu et al. 2012)

Liikkuvien raskaiden työkoneiden hydraulioöljynäyte otetaan tyyppillisesti huollon yhteydessä. Näyte analysoidaan kannettavilla hiukkaslaskureilla tai tarvittaessa laboratoriossa. Metallipartikkeleja pidetään hydraulijärjestelmän haitallisimpina partikkeleina, joiden muotoa, kokoa ja väriä analysoimalla voidaan paikantaa komponentti, josta se on peräisin. Ennakoivat huoltotavat edellyttävät teknologiaa, jolla voitaisiin seurata hydraulioöljyn laatua reaaliaikaisesti. Tämän takia pyritään kehittämään anturiteknnologiaa, jolla voitaisiin valvoa hydraulioöljyn kontaminaatiota suoraan järjestelmässä. (Glass et al. 2017)

Kontaminaation monitoroinnin helpottamiseksi Glass et al. (2017) kehittivät mobiiliupotettuun partikkelikontaminaatioanturiin perustuvan dynaamisen datankeräämistekniikan kaivinkoneen hydrauliselle voimansiirtojärjestelmälle. Tutkimuksen perusteella öljyn kontaminaation monitorointijärjestelmä tulisi olla osa työkoneiden suunnittelua, antureiden asetelmalla on suuri merkitys reaaliaikaisen datan laatuun, ja hydraulioöljyn kontaminaation seurannassa pitäisi keskittyä tärkeiden komponenttien rakenteissa olevien metallipartikkelien havaitsemiseen, kuten kuparin ja raudan. (Glass et al. 2017) Gorritxategi et al. (2017) puolestaan kehittivät sirulla olevan impedanssianturin, jolla voidaan valvoa kulumiseen liittyvien sirpaleiden esiintymistä hydraulioöljyssä teollisissa hydraulisissa voimansiirtojärjestelmissä. Impedanssianturi huomioi näytteen sameuden, virtausnopeuden ja paineen yhdistämällä linssittömän mikroskoopin ja stroboskooppisen valaistuksen. Anturia voidaan käyttää paitsi induktiivisena anturina ferromagneettisten ja ei-ferromagneettisia hiukkasten havaitsemiseen, mutta myös kapasitiivisena anturi, joka havaitsee vesipisarat ja kuplat hydraulioöljyssä. Tulosten perusteella anturi kykenee havaitsemaan 4 erilaista saastumista hydraulioöljyssä ja soveltuu hydraulijärjestelmän monitorointiin ja vikadiagnosointiin. (Gorritxategi et al. 2017)

Hydrauliöljyn vuodot ovat yleinen ongelma hydraulijärjestelmissä. Pienet vuodot ovat vaikeita havaita ja paikallistaa. Sisäiset vuodot ovat ongelmallisia niiden sijainnin takia, ja sisäisten antureiden asentaminen on vaikeaa. (He & Jiang 2020) Esimerkiksi Arkwright et al. (2018) kehittivät uuden putken sisäisen valokuitupaineanturiryhmän, jonka avulla voidaan havaita hydraulisia muutoksia ja näiden aiheuttamia vuotoja.

Värähtelyjen eli vibraatioiden monitoroinnilla tutkitaan vibraatioita järjestelmästä. Tekniikassa vibraatiosignaali muutetaan sähköiseksi signaaliksi. Vibraatioiden monitorointia hyödynnetään muun muassa hydraulipumppujen kunnonvalvonnassa. (He & Jiang 2020) Esimerkiksi Li et al. (2019) testasivat uutta kokovektorispektrimenetelmää pyöriville hydraulikomponenteille. Menetelmä perustuu useiden anturien MSDF:ään. Kokovektorispektrissä 3 anturia asetellaan toisiinsa nähden kohtisuoraan xyz-koordinaatiston mukaisesti tallentamaan vikatietoja. Tekniikalla saatiin parannettu informaation saamista koko hydraulipumpun kuorelta. (Li et al. 2019; He & Jiang 2020)

Hydraulisten suuntaventtiilien viat ovat monesti vaikeita havaita ja ne käyvät kalliiksi (Glass et al. 2017). Esimerkiksi Chen et al. (2021) testasivat kaksivaiheista MSDF-menetelmää hydraulisten suuntaventtiilien sisäisten vikojen vianmäärittämiseen. Menetelmässä analysoitiin vibraatiosignaaleja MSDF:ää hyödyntäen. Tutkimuksen tärkeimpiä havaintoja olivat, että useiden anturien yhdistelmä parantaa suuntaventtiilien vikadiagnosia, ja useiden ominaisuuksien yhdistely parantaa ominaisuusjoukon vian ilmaisukykyä. (Chen et al. 2021)

Koko järjestelmän analysoinnin haasteet liittyvät hydraulijärjestelmän rakenteeseen. Hydraulijärjestelmät ovat monimutkaisia epälineaarisia järjestelmiä, jossa on useita muuttujia. (He & Jiang 2020) Koneiden kunnonvalvonnassa yleisin huoltomalli on kuntoperusteinen huolto (CBM). CBM:n perusideana on tehdä huoltopäätökset kerätyn informaation perusteella. CBM koostuu datan keräyksestä, datan käsittelystä ja huoltopäätöksistä. Vikadiagnostiikka ja vikojen ennustettavuus eli prognostiikka ovat CBM:n tärkeimmät kohteet. (Banjevic et al. 2006) Glass et al. (2017) määrittelevät CBM:n filosofiana, jossa säilytetään tekniset ominaisuudet kuntoon ja kunnossapitologiikkaan perustuvilla häiriöttömillä mittauksilla.

### **4.3 Hydraulijärjestelmien vikadiagnosot**

Hydraulijärjestelmän vikadiagnostiikan tavoitteena on vaaratilanteiden ja lisäkustannuksien välttäminen sekä tietysti vian syyn oikeaoppinen määrittely. Vikadiagnostiikan tavoitteisiin pääsemiseksi voidaan seurata jotain hyväksi havaittua toimintafilosofiaa, kuten CBM:ää.

CBM:n mukaan koneiden vikadiagnoosissa keskitytään vian huomaamiseen, rajaamiseen ja tunnistamiseen. Prognostiikan peittäessä diagnostiikka voi olla täydentävä työkalu ylläpitopäätösten tukemisessa. Diagnostiikan avulla saadaan myös parannettu prognostiikan ja tutkittavan järjestelmän malleja, kun tunnetaan vikoja. Koneiden vikadiagnoosi on menetelmä, jossa kartoitetaan mittausten tai ominaisuuksien informaatiota vikojen määrittämiseksi. Kartoitusprosessia kutsutaan myös hahmontunnistukseksi. Hahmontunnistus tehdään perinteisesti manuaalisesti, mikä vaatii tarkkaa asiantuntijuutta. Hahmontunnistuksen automatisoimiseksi pitää osata tulkita signaalin informaatiota. Tätä ongelmaa koitetaan ratkaista muun muassa tekoälyn ja tilastollisten menetelmien avulla. (Banjevic et al. 2006; Dai et al. 2019)

Dain et al. (2019) mukaan hydraulijärjestelmän vikadiagnoosit ovat jaettavissa kolmeen kategoriaan: malli-, tieto- ja signaaliperusteiset menetelmät. Menetelmillä on omat käyttötilanteensa, joista kerrotaan seuraavaksi lyhyesti.

Malliperusteisessa menetelmässä järjestelmästä täytyy luoda malli ennen diagnoosia. Tämä rajoittaa diagnoosin tekemistä lähinnä tilojen ja parametrien arvioimiseen. Monimutkaisille hydraulijärjestelmille on vaikea löytää toimivaa malliperusteista menetelmää, koska parametrien yhdistely on vaikeaa. (Banjevic et al. 2006; Dai et al. 2019)

Tietoperusteisessa menetelmässä tarvitaan asiantuntijoiden tietoa mallin simulointiksi. Malli soveltuu tilanteisiin, jossa vian perustelut ovat selkeitä ja päätöslogiikka on vahva. Menetelmä ei toimi tilanteissa, jossa mallia tarvitsee opettaa, eli malliin pitää lisätä tietoa. Hydraulijärjestelmät ovat dynaamisia järjestelmiä, ja viat ovat vaikeasti ennustettavissa pelkän tiedon perusteella. (Dai et al. 2019)

Signaaliperusteisen menetelmän ideana on tehdä vikadiagnoosi mitattavien signaalien perusteella, eli vian pitäisi näkyä anturien signaalissa. Vian olennainen piirre voidaan saada selville teoreettisesti, kun signaalin ominaisuudet on louhittu asianmukaisesti ja hahmontunnistaminen on suoritettu oikein. Signaaliperusteista menetelmää on tutkittu laajasti älykkäiden vianmääritysmenetelmien yhteydessä. Menetelmä hyötyy anturitekniikan ja tietokantojen kehityksestä, kun dataa voidaan tallentaa enemmän ja helpommin. Lisäksi menetelmässä saadaan hyödynnettyä koneoppimisen algoritmeja. Esimerkiksi tekoälyn (AI) menetelmistä syvien neuroverkkojen (DNN) hyödyntäminen hydraulijärjestelmien vikadiagnooseissa herättää lupauksia. DNN:ien käyttäminen poistaa objektiivisuutta ja rajoitteisuutta, kun sitä käytetään signaaliperusteisessa vianmäärittämisessä. DNN:ien kyky oppia epälineaaristen hydraulijärjestelmien signaaleja voi auttaa jatkossa moniulotteisen korkean tason ominaisuuksien määrittämisessä. (Dai et al. 2019)

## 5. DATAFUUSIOON PERUSTUVA HYDRAULI-JÄRJESTELMIEN VIKADIAGNOSOINTI

### 5.1 Datafuusioon perustuva vikadiagnoosijärjestelmä

Datafuusiota voidaan hyödyntää hydraulijärjestelmien vikadiagnooseissa. Vikadiagnoosit etenevät tyypillisesti kaavamaisesti noudattaen tiettyjä periaatteita: datan keräys, datan käsittely ja päätösten tekeminen informaation perusteella. (Yang et al. 2012; Bai et al. 2020) Tässä luvussa havainnollistetaan vikadiagnosointia esimerkin avulla.

Monianturi-informaatiofuusio on monipuolinen datan käsittelymenettely, jonka avulla saadaan analysoitua järjestelmää. Vikadiagnoosissa monianturi-informaatiofuusio koostuu mittauksen kohteen datan ja tiedon yhdistämisestä. Yangin et al. (2012) mukaan vikadiagnoosiin soveltuva monianturi-informaatiofuusio koostuu datafuusiosta, tiedon fuusiosta ja tiedonlouhinnasta. Kuvassa 6 on monianturi-informaatiofuusion kerrosmalli, josta nähdään informaatiofuusion jakautuminen 3 kerrokseen. (Yang et al. 2012)

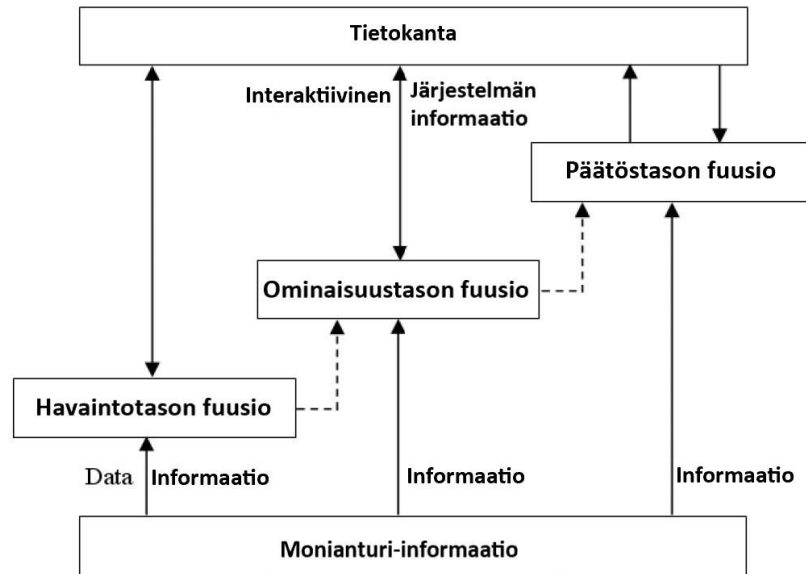
Havaintotason fuusiossa samanlaisten anturien alkuperäinen data yhdistetään ennen esikäsittelyä (kuva 6). Menetelmällä saadaan tulkittua hydraulijärjestelmän toimintaa intuitiivisesti ja havainnollisesti, kun informaatiota syötetään ensimmäistä kertaa. Informaatiota syötetään myös tietokantaa tiedonlouhimiseksi. (Yang et al. 2012)

Ominaisuustason fuusiossa erilaisten antureiden alkuperäinen data yhdistetään asiaan liittyvän teoreettisen tiedon kanssa (kuva 6). Menetelmällä hydraulijärjestelmän vika saadaan paikallisesti ja tunnistettua. Tarkkoja vikadiagnoosiin tähtääviä menetelmiä tai teknologiaa ei pystytä määrittämään ominaisuuskerroksen fuusiossa. (Yang et al. 2012)

Päätöstason fuusio on korkeimman tason fuusiota monianturi-informaatiofuusiossa (kuva 6). Kaikki erilaisten anturien informaatio ja teoreettinen tietämys hydraulijärjestelmästä yhdistetään, jotta pystytään tekemään tarvittavat vastatoimet vikadiagnoosin muodostamiseksi. Vastatoimia voivat olla muun muassa vian rajaaminen tai järjestelmän informaation hallinta. (Yang et al. 2012; Bai et al. 2020)

Rakenteellisesti monianturi-informaatiofuusion malli on lähellä perinteistä datafuusiomallia. Vikadiagnoosin yhteydessä korostuu mitattavan informaation lisäksi aiempi tietämys järjestelmästä, joka voi olla aiemman datan perusteella louhittua tai teoreettista tietoa, joka on saatu vastaavasta järjestelmästä. Informaatio voi olla peräisin asiantuntijoilta tai järjestelmän rakenteellisesta mallista. Tietokannat ja tietokannan hallinta ovat olennainen osa hyödyllisen informaation tallentamisessa. (Castanedo 2013).

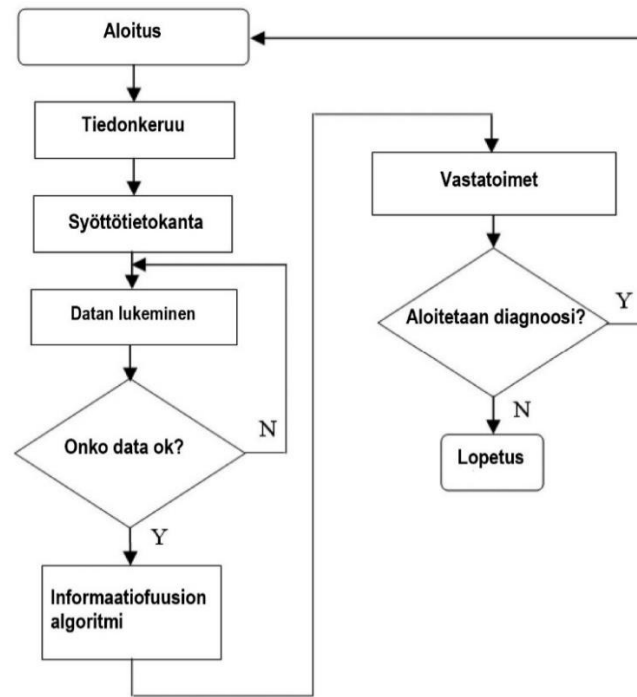




**Kuva 6.** Monianturi-informaatiofuusion kerrosmalli (mukailtuna lähteestä Yang et al. 2012)

Hydraulijärjestelmän monianturi-informaatiofuusioon perustuva vikadiagnosijärjestelmä voisi koostua kahdesta toiminnallisesta moduulista: datankeräysmoduuli ja keskusprosessimoduuli. Datankeräysmoduuli asennetaan järjestelmän jokaiseen pääkomponenttiin. Datankeräysmoduuli sisältää komponentteja, kuten antureita, signaalinkäsittelypiirin, A/D-muuntimen ja väyläliitännän. Datankeräysmoduulin tavoitteena on signaalien kerääminen ja kuljettaminen. Keskusprosessimoduuli sisältää CPU:n ja ohjelmiston. CPU:lla saadaan käsiteltyä ja analysoitua dataa sekä tehtyä tarvittavat vastatoimet vikadiagnosin muodostamiseksi. Onnistumisen kannalta on tärkeä tuntea järjestelmä, jotta osataan valita oikeanlaisia komponentteja. (Yang et al. 2012) Kuvassa 7 on tässä luvussa esiteltyyn monianturi-informaatiofuusiomalliin sopiva diagnostiikkaohjelma. Ohjelman toimintalogiikka on seuraava:

- Dataa kerätään ja syötetään tietokantaan.
- Dataa luetaan, ja varmistetaan datan laatu.
- Informaatio yhdistetään, jos luettava data on kunnossa.
- Datan yhdistämiseen ja käsittelyyn käytetään sopivia algoritmeja.
- Tehdään tarvittavat vastatoimet vikadiagnosin muodostamiseksi.
- Lopetetaan ohjelman suorittaminen tai aloitetaan uusi diagnoosi.



**Kuva 7.** Diagnostiikkaohjelman kaavioesitys (mukailtuna lähteestä Yang et al. 2012)

Edellä esitelty vikadiagnoosimalli auttaa ymmärtämään vikadiagnoosia prosessina, mutta tarkan vikadiagnoosijärjestelmän tekeminen on täysin riippuvainen sovelluskohdeesta. Teknologiakehityksen myötä keskittymistä suunnataan uusiin toimintatapoihin, jotka mahdollistavat suuremman ja reaaliaikaisemman informaation käsittelyn. Useiden lähteiden dataan perustuvat IoT-järjestelmät, AI ja massadatan (engl. big data) käsittely ovat teknologioita, joiden avulla pystytään parantamaan kunnossapitoa ja säästämään vikadiagnoosiin tarvittavissa resursseissa. (Huang et al. 2020)

Käytössä olevia vikadiagnoosimenetelmiä pyritään kehittämään, jotta saataisiin poistettua menetelmiin liittyviä rajoitteita. Esimerkiksi antureiden dataa hyödyntävissä datafuusio-menetelmissä informaatioon liittyy epävarmuustekijöitä. (Jiang et al. 2016) Epävarmuutta on koitettu ratkaista uusilla menetelmillä, kuten Jiangin et al. (2016) Z-lukujen ja D-S:n yhdistämisellä, sekä Xiaonin (2017) MSDF-menetelmällä, jossa yhdisteltiin teorioita todisteiden etäisyydestä, uskomuksen entropiasta ja sumeasta preferenssisuhdeanalyysistä. Monesti menetelmissä anturien luotettavuuden arviointi on välttämätöntä, ja uudet menetelmät keskittyvät korjaamaan aiempien menetelmien rajoitteita antureiden informaation tulkinnassa (Jiang et al. 2016).

## 5.2 Syväoppiminen datafuusiossa

Syväoppiminen (engl. deep learning) on eräänlaista koneoppimista (engl. machine learning). Monikerroksisten epälineaaristen verkkojen koulutuksen kautta syväoppimisella

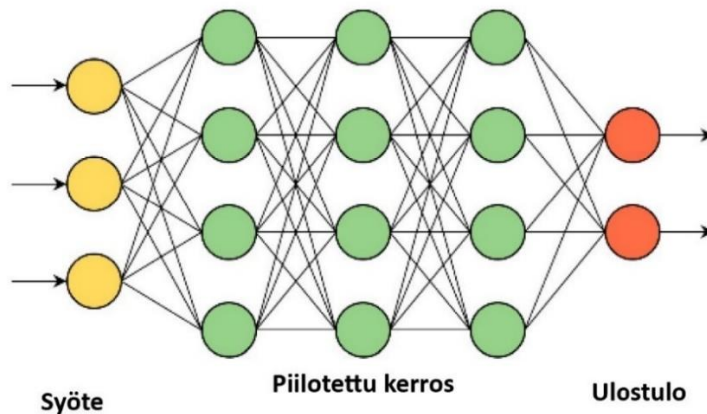
voidaan toteuttaa monimutkaisten funktioiden arvioimista, edustaa syötteen hajautettua ilmaisua ja oppia näytteen olennaisia ominaisuuksia. Syväoppimisen perusideana on oppia ominaisuuksia, jotka ovat hyödyllisempiä koulutetussa mallissa, jossa on useita piilotettuja kerroksia ja suuri määrä harjoitusnäytteitä parantamassa mallin ennustavuus- tai havainnointikykyä. Yleisesti ottaen missä tahansa karttarakenteessa on potentiaalia syvän mallin rakentamiseen, ja epälineaaraisia malleja, joissa on yli 3 kerrosta, voidaan pitää syvämalleina. Tästä määrittelystä seuraa, että syvämalleja on paljon. (Dai et al. 2019)

Syväoppimiseen perustuvat algoritmit pystyvät automaattisesti yhdistämään yksinkertaisia ominaisuuksia uusiksi monimutkaisemmiksi ominaisuuksiksi, joita yhdistelemällä voidaan ratkaista käytännön ongelmia. (Huang et al. 2020) Dai et al. (2019) mukaan syväoppimisen ominaisuudet, kuten tehokas erottelukyky, ominaisuuksien muuntaminen sekä fuusiointi- ja kuviontunnistamisominaisuudet ovat lisänneet huomiota syväoppimiseen käyttämiseen vikadiagnostiikan alalla. Syväoppimisen ominaisuudet voivat olla hyödyllisiä vikadiagnoosissa hydraulijärjestelmän kaltaisessa järjestelmässä, jossa ominaisuudet tahtovat jäädä piiloon, satunnaisilla tekijöillä on suuri vaikutus, ja kartoitus signaalien ominaisuuksien ja todellisen järjestelmän välillä on monimutkaista. (Dai et al. 2019) Mekaanisten konejärjestelmien vikadiagnooseissa käytettyjä algoritmeja ovat esimerkiksi syvä neuroverkko (DNN) ja syvän uskon verkko (DBN). Muita tunnettuja DNN:iä ovat muun muassa konvoluutioneuroverkko (CNN), autoenkooderi (AE), toistuva neuroverkko (RNN) ja pinottu autoenkooderi (SAE). (Dai et al. 2019; Huang et al. 2020) Dai et al. (2019) korostavat DNN:ien merkitystä nopeimmin kehittyvänä sekä laajimmin käytettynä syvämallina.

Erilaiset DNN:t noudattavat yhteisiä periaatteita. DNN:iä käytetään monesti hahmontunnistuksessa. DNN:n onnistunut soveltaminen monimutkaiseen hahmontunnistukseen johtuu pääasiallisesti sen mallin rakenteesta ja koulutusmenetelmästä. (Dai et al. 2019) Vaikka perinteinen syvä neuroverkko voi tuottaa enemmän abstrakteja ominaisuuksia lisäämällä useita piilotettuja kerroksia, voi menetelmästä koitua helposti ylisovittamisiongelmiä. Esimerkiksi tätä ongelmaa yritetään ratkaista muilla variaatioilla. (Huang et al. 2020) DNN:ille on yhteistä monikerroksisuus, joka mahdollistaa kehittyneen epälineaarisen muunnoksen kerros kerrokselta periaatteella. Tämän ominaisuuden takia DNN:illä on hyvä ominaisuuksien erottamiskyky. DNN:issä ominaisuusmuunnin ja tilan luokitin ovat integroitu yhdeksi malliksi. Ominaisuuden oppiminen on suuntautunut hahmontunnistukseen, ja siksi ominaisuusmuunnos ja luokittelu optimoidaan yhdessä. Lisäksi ker-

ros kerrokselta ahne ohjaamaton oppiminen on itsesopeutuva oppimisprosessi, joka vähentää ihmisen subjektiivisuuden vaikutusta parametrien alustukseen ja koulutusprosessin tuloksiin. (Dai et al. 2019)

Rakenteellisesti DNN koostuu 3 kerroksesta: syöte, piilotettu ja ulostulo (kuva 8). Jokainen kerros koostuu useista neuroneista, jotka on liitetty hierarkkisesti seuraavaan kerroksen neuroneihin. Syöte ja ulostulo koostuvat yleensä yhdestä kerroksesta, kun taas piilotettu kerros koostuu kahdesta tai useammasta kerroksesta. Syötteen dataominaisuudet prosessoidaan piilotetussa kerroksessa, minkä jälkeen ulostulosta saadaan johdettua ennustearvot. DNN:n ennusteperiaatteena on, että piilotettujen kerrosten neuronit saavat syötteenä muiden neuronien painotettuja summia, mistä ne laskevat pätevät arvot aktivaatiofunktioiden perusteella. Esimerkiksi regressioanalyysissä käytetyin aktivaatiofunktio on oikaistu lineaarinen yksikkö (engl. rectified linear unit). (Baek & Choi 2020)



**Kuva 8.** DNN:n kerrokset (mukailtuna lähteestä Baek & Choi 2020)

Termit syväoppiminen ja neuroverkot (engl. neural networks) sekoittuvat helposti toisiinsa. Sekaantumista aiheuttaa termit syvä neuroverkko ja pelkkä neuroverkko. Luokitelutasolla vain syvä neuroverkko on syväoppimista (Dai et al. 2019). Molempia malleja käytetään datafuusion sovelluksissa, kuten vikadiagnoseissa (Huang et al. 2020). Itse termien välillä vaikuttaa olevan muutamia eroavaisuuksia. Syväoppiminen on monikerroksinen neuroverkko, joka vaatii raskasta prosessointia tietokoneen komponenteilta, ja mallin rakentaminen on vie aikaa. Syväoppimisen etuna on valmiin mallin tehokkuus. (Schmidhuber 2015) Neuroverkot ovat puolestaan keinotekoisia hermoverkkoja, jotka jäljittelevät biologisia neuroverkkoja (Raol 2015. s. 437–439). Neuroverkot ovat rakenteellisesti yksinkertaisempia kerroksettomia malleja, jotka perustuvat neuronien aktivoitumiseen ja niiden välisiin signaaleihin. Vertaillen syväoppimiseen neuroverkko on helpompi rakentaa ja opettaa, mutta se ei kykene samanlaiseen prosessointiin, kuin syvät neuroverkot. Neuroverkko ei vaadi tietokoneen komponenteilta raskasta prosessointia,

vaan malli rakentuu neuronien yhteyksistä ja funktioista. (Schmidhuber 2015) Syvän neuroverkon toimintaa voisi verrata aivoihin ja pelkkiä neuroverkkoja aivoissa käytettäviin funktioihin.

### **5.3 Menetelmien soveltuvuus hydraulijärjestelmien vikadiagnosointiin**

Kuten aiemmissa luvuissa on mainittu, hydraulijärjestelmän vikadiagnoosin tekeminen on haasteellista. Pääsyitä ovat muun muassa hydraulijärjestelmien monimutkainen epälineaarinen rakenne, minkä takia todellisia ominaisuuksia on vaikea kartoittaa mittaus-signaalien perusteella sekä satunnaisilla tekijöillä on suuri rooli. Toimivia datafuusion avulla toteutettuja vikadiagnoosijärjestelmiä on kehitetty paljon erilaisiin käyttötarkoituksiin, mutta ajatus sovelluskohteesta riippumattomista menetelmistä ei ole toistaiseksi toteutunut. Käytössä oleviin menetelmiin liittyy rajoituksia, jotka täytyy tiedostaa vikadiagnoosijärjestelmää suunniteltaessa. Tässä luvussa tutustutaan lisää datafuusion hyödyntämiseen hydraulijärjestelmien vikadiagnoseissa, esitellään lupaavia toimintatapoja ja pohditaan eri menetelmien rajoitteita.

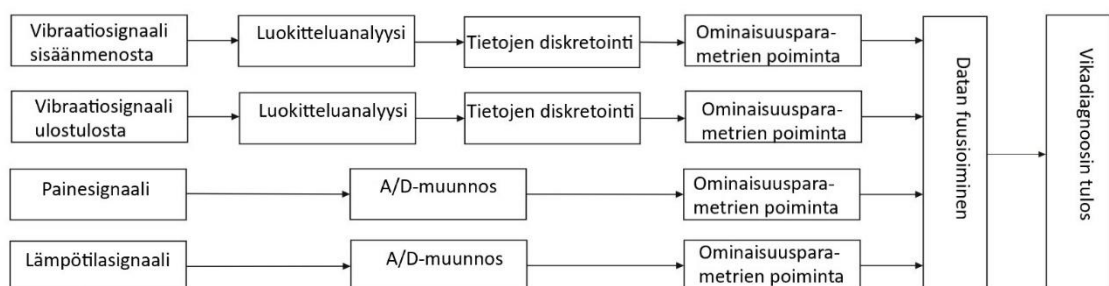
Vikadiagnoosin tekemistä voidaan lähestyä valitsemalla jokin hyväksi todettu datafuusiomalli, joka auttaa hahmottamaan prosessia. Esimerkiksi Huang et al. (2020) esittävät hierarkkista datafuusiomallia parempana valinta vikadiagnoosiin, kuin JDL-datafuusiomallia. JDL-datafuusiomallin on ongelmina ovat prosessien hitaus, ja ihmisen toiminta vaikuttaa liikaa diagnoosin lopputulokseen. Hierarkkisella datafuusiomallilla on puolestaan tiettyjä etuja. Mallissa on 4 vaihetta: datan esikäsittely, datatason fuusio, ominaisuustason fuusio ja päätösfuusio. Ideana on käyttää edellisen vaiheen tuloksia syötteenä seuraavaan vaiheeseen. Hierarkkinen malli kärsii liiallisesti tasojen määrästä ja hitaasta prosessoinnista. Informaatiota saadaan kuitenkin karsittua fuusioprosesseissa, joka vähentää kustannuksia esimerkiksi siirrettäessä IoT:n tietoja pilveen. Tämän takia hierarkkisella mallilla on viitearvoa IoT:hen perustuvan vikadiagnoosijärjestelmän rakentamisessa. Hierarkkista mallia pidetään suosituimpana valintana vikadiagnoosijärjestelmään. (Huang et al. 2020)

Tällä hetkellä useiden lähteiden datafuusio on erittäin potentiaalinen ja tehokas menetelmä vikadiagnostiikassa. Useiden lähteiden datafuusiolla tarkoitetaan antureita, IoT-järjestelmiä, datan käsittelyä pilvessä ja teknologiaa pilvipalvelujen ympärillä. Mekaanisten laitteiden tapauksessa tämä on käytännössä datan keräämistä antureilla, datan prosessointia ja datan siirtäminen pilveen, jossa dataa yhdistetään tietokantojen informaation kanssa. Useiden lähteiden datafuusiota tukevat kehitysaskeleet tietokoneiden laskeutuksessa sekä 5G-teknologia, joka nopeuttaa tiedonsiirtoa laitteiden, palvelujen ja

pilven välillä. (He & Jiang 2020; Huang et al. 2020) Uuden teknologiaan kehittäminen on jo meneillään liikkuvien raskaiden työkoneiden sovelluksissa (He & Jiang 2020). Tästä voidaan päätellä, että näiden koneiden hydraulijärjestelmien vikadiagnosointi on kehitty-mässä vahvasti älykkäiden ratkaisujen tarjoamaa toimintatapaa.

MSDF:n suosio perustuu sen tapaan kerätä dataa. Antureiden oikealla asetelmalla saa-daan parannettua mittausdatan tarkkuutta ja analysoitua monipuolisesti esimerkiksi hyd-raulijärjestelmän parametrejä. (Yang et al. 2012) Kun huomioidaan, että MSDF on käy-tännössä antureiden datan ja aiemman informaation yhdistämistä, voidaan todeta, että tämä on varsin luonnollinen tapa analysoida konejärjestelmiä. Hydraulijärjestelmien komponenteille löytyy monipuolisesti MSDF:n sovelluksia vikadiagnostiikan alalla. Jos-kus vikadiagnosien yhteydessä monien anturien datan yhdistämisestä puhutaan moni-anturi-informaatio fuusiona, joka esiteltiin luvussa 5.1.

Esimerkiksi Han et al. (2010) testasivat MSDF:ää hydraulipumpun vikadiagnosissa. Menetelmässä yhdistettiin virtuaaliympäristön työkaluja ja D-S:n kanssa, jotta pystyttiin tekemään päätöksen fuusiointi hydraulipumpun vian diagnosoimiseksi. Datan esikäsit-telyyn käytettiin erikseen kehitettyä järjestelmää, jossa hyödynnettiin virtuaalisen ympä-ristön teknologiaa, hydraulipumpun sisään- ja ulostuloista mitattuja signaaleja sekä hyd-rauliöljyn lämpötila- ja painesignaaleja. Signaalien muokkauksen jälkeen, signaalit vietiin tietokoneelle, jossa käytettiin signaalien käsittelyfunktioita. Erityisesti värähtelysignaalin käsittely on tärkeää, koska tähän signaalin liittyy häiriöitä muun muassa pumpun nopeu-den muutoksista. Erilaisten värähtelyjen erotteluun käytettiin luokitteluanalyysiä (engl. order analysis), jolla saadaan eroteltua eri taajuuksien ja kierrosnopeuksien väliset yh-teydet. Lopuksi jokaisen yksittäisen anturin signaalit yhdistettiin D-S:n avulla päätösta-son fuusiossa, jonka jälkeen anturitiedot yhdistettiin vian selvittämiseksi. Kuvassa 9 on Hanin et al. (2010) hydraulipumpun vikadiagnosijärjestelmä: ensin antureiden signaalit käsitellään, sitten ominaisuudet kerätään vektoreiksi ja hyödynnetään D-S:ää, ja lopuksi saadaan vikadiagnosointi fuusioinnista tiedosta. Menetelmällä saatiin kokeellisesti eroteltua vian syyksi mäntäpumpun kuulapään löysyys. (Han et al. 2010)



**Kuva 9.** Hydraulipumpun vikadiagnosointi (mukailtuna lähteestä Han et al. 2010)

Datafuusiossa käytetyillä algoritmeilla on erilaisia vahvuuksia ja heikkouksia. Eri algoritmeille tyypilliset piirteet vaikuttavat niiden soveltuvuuteen. Tarkastellaan seuraavaksi muutamien algoritmien vahvuuksia ja rajoitteita.

D-S on suosittu algoritmi erilaisissa datafuusion sovelluksissa ja sen yksi suurimmista eduista on laaja tutkimusnäyttö. D-S on päättelytyökalu, jossa epävarmuutta arvioidaan massafunktion, uskomuksen ja uskottavuusfunktion mittareilla (Jiang et al. 2016). D-S:n avulla epävarmuus saadaan ilmaistua suoraan kohdentamalla todennäköisyys osajoukkoihin, ja menetelmän avulla voidaan saada uusia todisteita yhdistämällä alkuperäisiä todisteita toisiinsa (Xiao 2017). Joissakin vanhemmissa lähteissä, kuten Han et al. (2010) D-S:ää pidetään harvinaisempaan algoritmina vikadiagnoseissa, mutta uudemmissa lähteissä (Jiang et al. 2016; Xiao 2017; Huang et al. 2020) D-S:ää pidetään suosittuna algoritmina vikadiagnoseissa. D-S:n suurimpana etuna on joustavuus ja kyvykyys karsia epävarmuutta (Jiang et al. 2016). Huang et al. (2020) toteavat D-S:n sopivan erityisen hyvin tilanteisiin, jossa todisteet ovat toisistaan riippumattomia. Menetelmän rajoitteet ilmenevät, kun todisteiden välillä on konflikteja. Konfliktien myötä tulokset ja todellisuus voivat ajautua ristiriitaan, sekä osa todisteista voi suoraan kumota lopullisen päätöksen. Myös laskemisen määrä kasvaa valtavaksi, kun todisteiden määrä on suuri. (Huang et al. 2020) Ratkaisuna rajoitteisiin D-S voidaan yhdistää jonkun toisen algoritmin kanssa, todisteita voidaan esikäsitellä ja se voidaan yhdistää muiden teorioiden kanssa, jotta saadaan painotettua esimerkiksi tietyn todisteen merkitystä (Jiang et al. 2016; Xiao 2017; Huang et al. 2020).

Neuroverkkojen etuna on älykäs tapa käsitellä dataa, yksinkertainen rakenne ja sen menetelmiä on kehitetty pitkään (Huang et al. 2020). Neuroverkoilla saadaan aiempien viikkojen syiden avulla kehitettyä mallia nopeasti, mikä lisää vian diagnosoinnin potentiaalia. Näiden algoritmien rajoitteena on, että suorituskyky on paljon riippuvainen neuroverkon rakenteesta ja harjoittamisen intensiteetistä. (Jiang et al. 2016) Monesti informaatiota täytyy esikäsitellä signaalinkäsittelyn menetelmin, ja algoritmi pitää yhdistää jonkin heuristisen eli päättelyyn perustuvan algoritmin kanssa, jotta saadaan optimoituja painotusparametrejä (Huang et al. 2020).

DNN:ien potentiaali vikadiagnostiikan alalla liittyy niiden ominaisuuksiin, kuten objektiivisuuteen sekä kykyyn erotella ominaisuuksia ja tehdä hahmontunnistus yhdessä optimoidulla mallilla. DNN:iä selitettiin laajemmin luvussa 5.2. Esimerkiksi hydraulijärjestelmien vikadiagnoseiden yhteydessä syötteenä voidaan käyttää 1D ominaisuuksia, kuten aikataason signaalia tai taajuusspektriä; 2D ominaisuuksia, kuten aika-taajuus diagrammia; tai 3D ominaisuuksia, kuten useiden anturien signaalin aika-taajuus diagrammia.

DNN:ien käyttöä hydraulijärjestelmien vikadiagnoseissa rajoittavat erilaiset tekijät: Verkon kouluttaminen vie aikaa. Hydraulijärjestelmän rakenteesta johtuen harjoitusnäytteitä on vaikea saada tarpeeksi. Vian ratkaisemiseen voi liittyä ylisovittamisongelmia. Laajat DNN:t kuormittavat laitteistoa tarpeettoman paljon. Oikeiden luokittimien valitseminen on vaikeaa päätöstason fuusiossa. Ihmisen tietämyksen yhdistäminen on vaikeaa rakentaessa vikadiagnosiin tähtäävää mallia. (Dai et al. 2019)

Eräs maininnan arvoinen menetelmä hydraulijärjestelmien vikadiagnosien yhteydessä on tukivektorikone (SVM) (engl. support-vector machine), joka on luokitinmalli. SVM on valvottu oppimisalgoritmi, joka perustuu tilastolliseen oppimisteoriaan. Sen vahvuudet liittyvät yleistämiskykyyn, jossa ennalta tuntemattomia näytteitä osataan luokitella oikein. SVM:ää on testattu suhteellisen paljon erilaisissa sovelluksissa, kuten esimerkiksi Das et al. (2021) testasivat sitä liikkuvan hydraulisen koneen puomin toimilaitteen sisäisen vuodon havaitsemiseen ja luokitteluun. (Dai et al. 2019; Das et al. 2021)

Vaikuttaa siltä, että parhaimpaan vikadiagnosijärjestelmään päästään yhdistelemällä erilaisia algoritmeja. Myös esimerkiksi Huang et al. (2020) ehdottavat vikadiagnosijärjestelmiä, jossa yhdisteltäisiin eri algoritmeja. Esimerkiksi D-S:n parantaminen yhdistämällä siihen muita teorioita, D-S:n ja neuroverkon yhdistäminen sekä DNN:ien yhdistäminen osaksi monimutkaisempi vikadiagnosijärjestelmiä voisivat olla toimivia ratkaisuja. (Huang et al. 2020)

Voidaan todeta, että hydraulijärjestelmien vikadiagnostiikka on kehittymässä kohti automatisoituja järjestelmiä, joissa vikadiagnositi saadaan tehtyä reaaliaikaisemmin. Datafuusio vaikuttaa olevan rakenteellisesti sopiva vikadiagnosien tekemiseen, ja erilaisia malleja on helppo muokata järjestelmään sopivaksi. Vahva tutkimusnäyttö ja menestyksäästi toteutetut vikadiagnositi hydraulijärjestelmien eri komponenteilla tukevat väitettä. Koko järjestelmän vikadiagnosointiin liittyy haasteensa, mutta uudet menetelmät herättävät lupauksia näiden ongelmien ratkaisemiseksi. Toisaalta uudempia menetelmiä on tutkittava ja testattava lisää, jotta uutta teknologiaa voidaan käyttää korkean vaatimustason järjestelmissä, kuten liikkuvien raskaiden työkoneiden hydraulijärjestelmissä.



## 6. YHTEENVETO

Datafuusion menetelmillä saadaan yhdistettyä eri lähteiden dataa aiemman tiedon kanssa, minkä tuloksena kohdejärjestelmästä saadaan informatiivisempi kuvaus. Datafuusion tyyppi on riippuvainen datatyypistä ja ominaisuuksista, joita halutaan saada esille kohdejärjestelmästä. Esimerkiksi hydraulijärjestelmissä, joissa dataa kerätään erilaisilla antureilla, datafuusio luokitellaan usein monianturidatafuusioksi (MSDF), monianturi-informaatiofuusioksi tai useiden lähteiden datafuusioksi.

Tässä työssä huomattiin, että raskaiden työkoneiden hydraulijärjestelmien kunnonvalvonta on tärkeää vika- ja vaaratilanteiden välttämiseksi. Yleisin tapa lähestyä konejärjestelmien prognostiikan ja vikadiagnostiikan tavoitteita on kuntoperusteinen huolto (CBM). Vikadiagnostiikan alalla hydraulijärjestelmien yleisimmäksi vikojen syyksi havaittiin hydraulioöljyn kontaminaatio, joka vastaa lähteestä riippuen 70–90% hydraulijärjestelmien vioista. Viat voivat olla kuitenkin monisyisiä, ja vikojen diagnosointia vaikeuttaa hydraulijärjestelmien ominaisuudet. Hydraulijärjestelmät ovat monimutkaisia epälineaarisia järjestelmiä, joihin liittyy satunnaisuutta. Antureilla kerättävä data voi muodostua vaikeasti tulkittavaksi, jonka takia jotkin ominaisuudet voivat jäädä huomaamatta.

Lisäksi tässä työssä haluttiin selvittää, miten datafuusion menetelmiä voidaan hyödyntää hydraulijärjestelmien vikadiagnoseissa, ja mihin suuntaan hydraulijärjestelmien vikadiagnostiikka on kehittymässä. Kyseessä on hyvin laaja aihe, minkä takia menetelmien tarkempi kuvaus edellyttäisi laajempaa tutkimusta. Tämän takia työssä keskityttiin rakenteelliseen tarkasteluun, jossa pyrittiin ymmärtää yleisiä vikadiagnosiin tähtääviä toimintatapoja.

Tämän työn perusteella hydraulijärjestelmästä riippumattomien vikadiagnosijärjestelmien tekeminen ei ole vielä mahdollista. Vaikuttaisi siltä, että datafuusion perustuvien vikadiagnosimallien rakentaminen on hyvällä tasolla, ja löydetään menetelmiä, joilla pystytään diagnosoimaan yksittäisiä järjestelmiä sekä komponentteja. Vikadiagnosimallien logiikkaa tarkasteltiin luvuissa 5.1 ja 5.3. Vikadiagnosijärjestelmistä signaali-perusteinen lähestymistapa vaikuttaisi parhaimmalta yleisratkaisulta, koska se ei edellytä järjestelmän tarkkaa tuntemista. Itse datafuusioprosesseissa suurimmat haasteet liittyvät ominaisuuksien erottamiseen ja datan yhdistelyvaiheissa käytettyihin algoritmeihin. D-S ja neuroverkot ovat vakiinnuttaneet paikkansa paljon testattuina algoritmeina. Näihin algoritmeihin liittyy kuitenkin rajoitteita, kuten erilaisia konflikteja, objektiivisuuden

puutetta, tarve signaalien esikäsitteilylle ja vaatimukset erilaisille toiminnallisille algoritmeille. Tähän ratkaisuna tutkimusta on suunnattu DNN:ien kehittämiseen, koska DNN:t poistavat aiempien menetelmien rajoitteita. Etenkin monimutkaisia järjestelmiä analysoidessa DNN:ien kyvykyys itsenäiseen oppimiseen herättää uusia mahdollisuuksia. Vaaditaan kuitenkin lisää kehitystyötä, jotta DNN:ien potentiaalia osattaisiin hyödyntää paremmin.

Vikadiagnostiikan tulevaisuuden kannalta tärkeä havainto on teknologian kehittyminen. Datafuusion kannalta merkittävimpiä teknologian kehitysaskelaiteita ovat tietokoneiden lisääntynyt laskentateho ja tiedonsiirron nopeuden mullistava 5G-teknologia. Vikadiagnostisijärjestelmien kehityssuuntana vaikuttaa olevan pilviteknologiaa ja useiden lähteiden datafuusiota hyödyntävät IoT-järjestelmät. Uutta teknologiaa hyödynnetään jo erilaisissa sovelluskohteissa, mutta korkean vaatimustason järjestelmissä, kuten liikkuvien raskaiden työkoneiden hydraulijärjestelmissä, teknologian täytyy olla tarkoin testattua ennen kuin sitä voidaan hyödyntää.

## LÄHTEET

He, X., & Jiang, Y. (2020). Overview of Applications of the Sensor Technologies for Construction Machinery. *IEEE Access*, 8, pp. 110324–110335. doi:10.1109/ACCESS.2020.3001968.

Dai, J., Huang, S., Tang, J., & Wang, Y. (2019). Signal-Based Intelligent Hydraulic Fault Diagnosis Methods: Review and Prospects. *Chinese Journal of Mechanical Engineering = Ji xie gong cheng xue bao*. English ed., 32(1), pp. 1–22. doi:10.1186/s10033-019-0388-9.

Glass, J., Harding, J.A., & Ng, F. (2017). Improving hydraulic excavator performance through in line hydraulic oil contamination monitoring. *Mechanical Systems and Signal Processing*, 83, pp. 176–193. doi:10.1016/j.ymssp.2016.06.006.

Zhang, Q. (2018). *Basics of Hydraulic Systems*. 2nd ed. CRC Press.

Castanedo, F. (2013). A Review of Data Fusion Techniques. *The Scientific World Journal*. Edited by D. Ursino and Y. Takama, p. 704504. doi:10.1155/2013/704504.

Raol, J.R. (2015). *Data Fusion Mathematics: Theory and Practice*. 1st ed. CRC Press.

Mitchell, H.B. (2012). *Data Fusion: Concepts and Ideas*. 2nd ed. Springer Berlin Heidelberg.

Karray, F., Khaleghi, B., Khamis, A.M., & Razavi, S.N. (2013). Multisensor data fusion: A review of the state-of-the-art. *Information Fusion*, 14(1), pp. 28–44. doi:10.1016/j.inffus.2011.08.001.

Huang, M., Liu, Z. & Tao, Y. (2020). Mechanical fault diagnosis and prediction in IoT based on multi-source sensing data fusion. Special Issue on IoT, Cloud, Big Data and AI in Interdisciplinary Domains, 102, p. 101981. doi:10.1016/j.simpat.2019.101981.

Yang, G.L., Zhang, L.G., Zhang, L.Q., & Zhang, S.Y. (2012). Application of multi-sensor information fusion technology on fault diagnosis of hydraulic system. IOP Conference Series. Earth and Environmental Science, 15(4). doi:10.1088/1755-1315/15/4/042008.

Basu, S.K., Lathkar, G.S., & Singh, M. (2012). Failure Prevention of Hydraulic System Based on Oil Contamination. Journal of The Institution of Engineers (India): Series C, 93(3), pp. 269–274. doi:10.1007/s40032-012-0032-2.

Bai, J., Chen, X., & Tong, Y. (2020). Research on Multi-sensor Data Fusion Technology. Journal of Physics: Conference Series, 1624(3). doi:10.1088/1742-6596/1624/3/032046.

Gorritxategi, E., Mabe, J., & Zubia, J. (2017). Photonic Low Cost Micro-Sensor for in-Line Wear Particle Detection in Flowing Lube Oils. Sensors, 17(3), p. 586. doi:10.3390/s17030586.

Arkwright, J.W., Cook, P.R., Gong, J., Lambert, M.F., Papageorgiou, A.W., & Png, G.M. et al. (2018). In-pipe fibre optic pressure sensor array for hydraulic transient measurement with application to leak detection. Measurement, 126, pp. 309–317. doi:10.1016/j.measurement.2018.05.072.

Li, H., Li, Y., Li, Y., & Yu, H. (2019). A novel improved full vector spectrum algorithm and its application in multi-sensor data fusion for hydraulic pumps. Measurement, 133, pp. 145–161. doi:10.1016/j.measurement.2018.10.011.

Chen, L., Li, Y., Ren, Y., Shi, J., Tang, H., & Yi, J. et al. (2021). Fault diagnosis in a hydraulic directional valve using a two-stage multi-sensor information fusion. Measurement, 179, p. 109460. doi:10.1016/j.measurement.2021.109460.

Banjevic, D., Jardine, A.K.S., & Lin, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), pp. 1483–1510. doi:10.1016/j.ymssp.2005.09.012.

Jiang, W., Shou, Y., Tang, Y., Xie, C., & Zhuang, M. (2016). Sensor Data Fusion with Z-Numbers and Its Application in Fault Diagnosis. *Sensors*, 16(9). doi:10.3390/s16091509.

Xiao, F. (2017). A Novel Evidence Theory and Fuzzy Preference Approach-Based Multi-Sensor Data Fusion Technique for Fault Diagnosis. *Sensors*, 17(11), p. 2504. doi:10.3390/s17112504.

Baek, J. & Choi, Y. (2020). Deep Neural Network for Predicting Ore Production by Truck-Haulage Systems in Open-Pit Mines. *Applied Sciences*, 10(5), p. 1657. doi:10.3390/app10051657.

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, pp. 85–117. doi:10.1016/j.neunet.2014.09.003.

Han, J., Liu, Y., Wang, Y.H., Yang, X.Q., & Zuo, D.W. (2010). Fault Diagnosis of Hydraulic Pump Based on Multi-Sensor Data Fusion. *Applied Mechanics and Materials*, 33, p. 539. doi:10.4028/www.scientific.net/AMM.33.539.

Das, J., Jose, J.T., Mishra, S. Kr., & Wrat, G. (2021). Early detection and classification of internal leakage in boom actuator of mobile hydraulic machines using SVM. *Engineering Applications of Artificial Intelligence*, 106, p. 104492. doi:10.1016/j.engappai.2021.104492.