

## TIIVISTELMÄRAPORTTI

### Online-oppiva ilmavalvontajärjestelmän suorituskykymalli

**Ari Visa, Juha Jylhä, Marja Ruotsalainen, Riitta Kerminen**  
**Tampereen teknillinen yliopisto, Signaalinkäsittelyn laitos**  
**Korkeakoulunkatu 1, 33720 Tampere**  
**ari.visa@tut.fi, p. 040 728 7969**

Tiivistelmä: Tarkalla ilmavalvontajärjestelmän tutkia ja seurantalaskinta kuvaavalla suorituskykymallilla on tärkeä rooli valvontajärjestelmän operatiiviseen käyttöön liittyvässä päätöksenteon tuessa ja järjestelmän kehittämisessä. Lisäksi suorituskykymallia voidaan hyödyntää ilmavalvontajärjestelmän optimisäädössä, joka on yksi modernin valvontajärjestelmän kehityssuunta. Valvontajärjestelmän optimisäätö tarkoittaa tyypillisesti reaaliajassa tietokoneella toteutettavaa tutkien parametrien ja moodien valintaa sekä seurantalaskimen parametrintia siten, että järjestelmän alueellinen valvontakyky maksimoituu. Toisaalta valvontajärjestelmälle voidaan määrittää optimisäätö monitavoitteisesti minimoimalla tutkiin kohdistuvaa ilmapuolustuksen lamauttamisen uhkaa ja samanaikaisesti maksimoimalla valvontakykyä – näiden ollessa keskenään ristiriitaisia optimointivaatimuksia. Kehitimme tässä tutkimushankkeessa vuonna 2016 optimointikonseptin fyysikaalisen tutkamallin parametrien optimointiin ja seurantalaskimen mallin automatisoituun muodostamiseen. Konsepti on suunniteltu ja toteutettu automaattiseksi siten, että sitä on mahdollista käyttää ilman manuaalista työtä uudestaan ja uudestaan (online), kun uutta dataa kerätään. Konseptissa hyödynnetään mittausdataa, joka sisältää ilma-alusten satelliittinavigointijärjestelmän tuottamia lentoratataltioita sekä niitä vastaavia ilmavalvontajärjestelmän tuottamia tutkahavaintoja ja seurantoja. Kehitetty optimointikonsepti koostuu oliopohjaisesta tietokannasta mitatun historiadatan tallentamiseen ja tehokkaaseen hakemiseen, optimointimenetelmästä tutkamallin parametrien automaattiseen oppimiseen mittausdatasta sekä seurantalaskimen mallin koneoppimismenetelmästä. Optimointikonseptilla pyritään tuottamaan malli, jonka tuottama valvontajärjestelmän suorituskykyennuste vastaa mahdollisimman hyvin todellisuutta, eli optimoinnissa minimoidaan mitatun ja mallinnetun suorituskyvyn välinen ero. Tällä tavoin muodostettu malli kykenee tuottamaan tarkan ennusteen, kun esimerkiksi sensoreiden ryhmitystä ja parametreja säädetään, huomioiden ympäristöolosuhteet ja operatiivinen tilanne. Laadittu suorituskykymalli on tärkeä osa optimisäädön kehittämistä. Lisäksi sitä voidaan käyttää välittömästi operaattorin päätöksenteon tukena, kun nykyisestä valvontajärjestelmästä otetaan maksimaalinen suorituskyky irti. Tutkimusprojektissa saamamme tulokset todentavat online-oppivan optimointikonseptin käyttökelpoisuuden.

#### 1. Johdanto

Nykyaikainen ilmavalvontajärjestelmä sisältää verkottuneita etäohjattavia monikäyttötutkia (multifunction radar) sekä kyvyn tehokkaaseen datan käsittelyyn ja informaatiofuusioon. Operaattorit kontrolloivat valvontajärjestelmää mahdollisimman hyvän ilmatilannekuvan ja tilannetietoisuuden tuottamiseksi. Yksittäisen, mahdollisesti adaptiivisen, tutkan suorituskyvyn ennustaminen tarkasti kaikissa ympäristöolosuhteissa ja tilanteissa on haastavaa. Vielä vaikeampaa on ennustaa koko verkottuneen valvontajärjestelmän suorituskyky hyvällä tarkkuudella, kun huomioon on otettava

kaikki siihen vaikuttavat tekijät kuten vallitseva sää, sensorikonfiguraatio ja tutkamoodit.

Valinnat, suositukset tai päätökset järjestelmän ohjaamisesta voi tehdä ihminen perustuen kokemukseensa tai päätöksenteon tukityökaluihin, tai tietokone perustuen sille tarjottuun syötteeseen erilaisten valintojen hyvydestä. Molemmissa tapauksissa tarvitaan ymmärrys järjestelmän suorituskyvystä. Yksi tapa muodostaa ymmärrys, jonka perusteella ennusteet laaditaan, on mallintaa suorituskyky. Päätöksenteon tukityökaluilla tyypillisesti visualisoidaan suorituskykymallin tuottamia suorituskykyä kuvaavia tunnuslukuja. Tietokoneella toteutetussa optimisäädössä tunnusluvut toimivat kohdefunktion perustana.

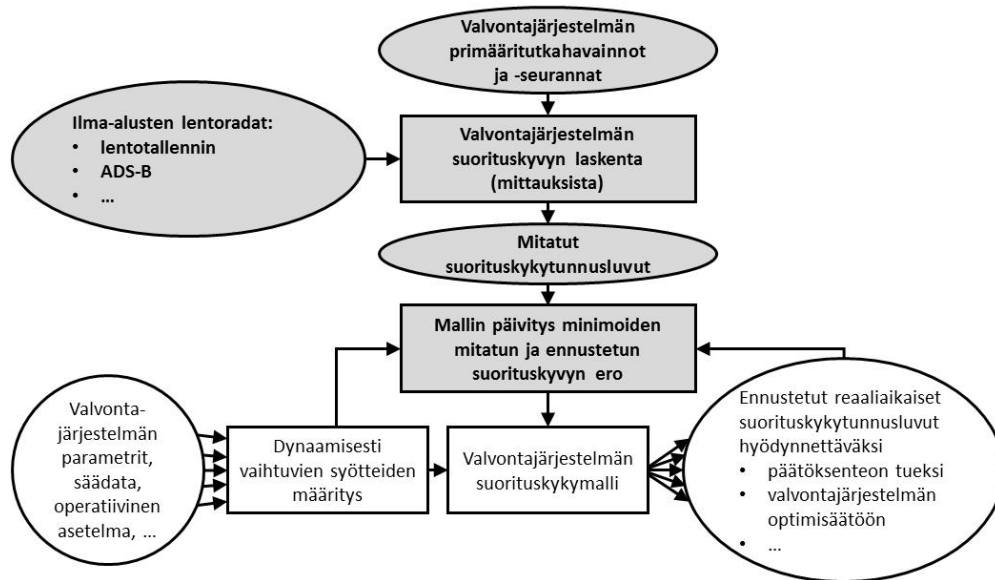
Ilmavalvontajärjestelmän hankintahinta, päivitys ja käyttökustannukset ovat merkittäviä. Välineet, joilla kehitetään järjestelmän taktista käyttöä, esimerkiksi optimaalisen sensoriryhmytyksen tai toimintaparametrien valinnan muodossa, voivat osoittautua hyvin kustannustehokkaiksi toteutuvan suorituskyvyn lisääjiksi. Laajassa kontekstissa tässä hankkeessa tehty työ tähtää TVM-suorituskyvyn (tiedustelu, valvonta, maalittaminen) kehittämiseen koskien erityisesti valvontaa ja maalittamista.

## 2. Tutkimuksen tavoite ja suunnitelma

Keskityimme tutkimuksessa tutkapohjaisen ilmavalvontajärjestelmän suorituskykymallien validointiin ja niiden tarkkuuden optimointiin jakaen tutkimusongelman karkeasti kolmeen tutkimuskysymykseen:

1. Miten tutkan suorituskykymallista saadaan mahdollisimman tarkka ja kattavasti eri syötetiedot hyödyntävä?
2. Miten seurantalaskimen suorituskykymalli kannattaa laatia ja miten siitä saadaan mahdollisimman tarkka ja kattavasti eri syötetiedot hyödyntävä?
3. Miten ilma-alusten lentoratataltiot ja ilmavalvontajärjestelmän havainnot ja seurannat saadaan tallennettua historiatiedoksi ja myöhemmin hyödynnettyä suorituskykymallin toistuvassa (online) uudelleenopettamisessa mahdollisimman laskentatehokkaasti ja kätevästi?

Tutkamalli noudattaa klassista tutkayhtälöä. Suurimpana haasteena on määrittää mallin parametrit siten, että malli ennustaa suorituskyvyn vaihtelevissa olosuhteissa huomioiden eri tutkamoodien käytön vaikutuksen. Päädyimme kehittämään menetelmän tutkamallin parametrien optimointiin. Seurantalaskimen mallin muodostamisen sen sijaan määrittelimme koneoppimisen ongelmana. Sekä tutkamallin että seurantalaskimen mallin optimoimiseen tai oppimiseen tarvitaan mitattua dataa. Mittausdatan avulla saadaan kuva oikean järjestelmän toiminnasta todellisessa toimintaympäristössä. Tutkimuksessa hyödyntämämme mittausdata sisältää lentokoneiden satelliittinavigointijärjestelmäpohjaisen sijaintitiedon sekä ilmavalvontajärjestelmän tuottamia tutkahavaintoja ja seurantoja. Suorituskykymallin tarkkuus määritellään mallin tuottaman suorituskykyarvion ja tosielämän mitatun suorituskyvyn välisenä erotuksena. Kehitimme tutkimusprojektissa optimointikonseptin, joka tähtää suorituskykymallin tarkkuuden maksimointiin tutkamallin parametrien ja seurantalaskimen mallin rakenteen automaattisella oppimisella. Kuva 1 havainnollistaa kehitettyä optimointikonseptia sekä sen kytkeytymistä reaaliaikaiseen suorituskykyennustimeen. Optimointikonseptin syötetietona käytettävän datan varastointiin päätimme kehittää oliotietokannan, jossa eri tyyppiset taltiot muodostetaan olioiksi, joita kyetään lataamaan ja tallentamaan tilaa ja aikaa koskien (spatiotemporaalisesti) kätevässä muodossa.



K Valkoiset lohkot esittävät suorituskyvyn ennustamisen, joka on  
u mahdollista tehdä reaaliajassa. Harmaat lohkot kuvaavat tässä  
v tutkimushankkeessa kehitetyn optimointikonseptin, jolla  
a valvontajärjestelmän suorituskykymalli opetetaan ennustamaan  
suorituskyky dynaamisesti muuttuvissa olosuhteissa mahdollisimman  
tarkasti. Satelliittinavigointijärjestelmän mukaiset lentoradat on  
mahdollista taltioida ilma-alusten lentotallentimista tai ilma-alusten  
tietoliikenneyhteydellä julkaisemista ADS-B -viesteistä (automatic  
dependent surveillance – broadcast).

Kun tehdään ilmavalvontajärjestelmän ohjaamista koskevia päätöksiä, päätöksentekoa tukevan suorituskykymallin on oltava validi, eli suorituskyvyn muutos on ennustettava oikein esimerkiksi muutettaessa tutkaryhmitystä tai järjestelmän parametreja. Online-oppivuus mahdollistaa mallin kehittymisen pitkän ajan kuluessa aina tarkemmaksi ja tarkemmaksi. Tämän jälkeen puolestaan mallia käyttävä järjestelmän ohjaus on mahdollista tehdä tarkemmin huomioiden dynaamiset ympäristö- ja operatiiviset olosuhteet.

### 3. Aineisto ja menetelmät

Toteutimme tutkimuksen mitattuun aineistoon pohjautuvana menetelmäkehityksenä. Aineistona oli suuri joukko ilma-alusten satelliittinavigointijärjestelmästä taltioituja lentoratoja ja valvontajärjestelmän tutkahavaintoja ja seurantoja. Optimointikonseptin vaatimat algoritmit ja menetelmät toteutettiin MATLAB:lla. Oliotietokanta toteutettiin Javalla.

Koska saimme käyttöön todellista dataa, riski dataan liittyville väärille oletuksille menetelmäkehityksessä oli hyvin pieni. Tunnistimme tutkimuksen tavoitteiden vaatiman työ määrän hyvin suureksi jo tutkimuksen suunnitteluvaiheessa. Halusimme kuitenkin toteuttaa optimointikonseptin kaikki keskeiset osat jo tutkimuksen ensimmäisenä

vuonna 2016. Tästä syystä kaikkien kolmen osan (tutkamallin oppiminen, seurantalaskimen mallin oppiminen, oliotietokanta) tavoitteelliseksi valmiusasteeksi asetimme alustavan, toteutuskelpoisuuden osoittavan kehityksen.


#### 4. Tulokset ja pohdinta

Tarkastellaan seuraavaksi optimointikonseptin kolmea osaa – tutkamallin optimointia, seurantalaskinmallin optimointia ja oliotietokantaa – kukin käydään läpi omassa alakohdassansa.

Muotoilimme suorituskykymallien optimoinnin kohdefunktion todellisen mittauksiin perustuvan suorituskyvyn ja mallin ennustaman suorituskyvyn erotukseksi. Erotusta minimoimalla mallit optimoidaan vastaamaan todellisuutta mahdollisimman hyvin ja näin ollen tuottamaan täsmällisiä ennusteita suorituskyvystä.

##### Tutkan suorituskykymallin optimointi

Tutkan havaintotodennäköisyys ja havaintojen tarkkuus tietyissä ympäristöolosuhteissa voidaan mallintaa teknis-fysikaalista mallia hyödyntäen. Mallin keskeisin komponentti on klassinen tutkayhtälö. Tutkan suorituskyky kuvataan useilla tunnusluvuilla kuten havaintotodennäköisyys ja mittaustarkkuus. Suorituskykyarvio koko valvontatilavuudelle saadaan jakamalla valvontatilavuus suhteellisen pieniin tilavuusalkioihin ja laskemalla suorituskykytunnusluvut näihin tilavuusalkioihin. Tilavuusalkioista muodostuu kolmiulotteinen solukko, jota havainnollistaa kuva 2. Laskennassa huomioidaan muun muassa tutkan toimintaparametrit ja geometria tutkan ja tilavuusalkion keskipisteen sijainnin välillä. Tutkan keskeisiä parametreja ovat esimerkiksi lähetysteho ja tutkan antennin vahvistus elevaatiokulman funktiona. Maaliympäristön keskeisiä ominaisuuksia ovat esimerkiksi kohteen tutkapoikkipinta-ala ja maaston aiheuttamat alakatveet.



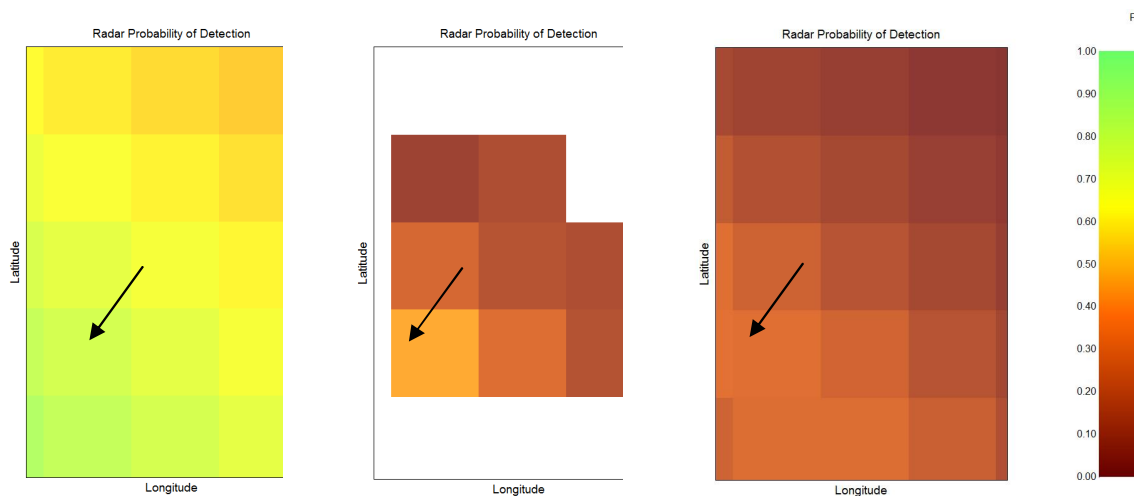
K Sekä suorituskyvyn mallintamisessa, että suorituskyvyn mittaamisessa  
u jaamme ilmatilan tilavuusalkioiden muodostamaksi solukoksi. Kuvassa  
v on sinisillä pisteillä piirretty solujen keskipisteitä. Kuhunkin soluun  
a kuvataan valvontajärjestelmän kyky valvoa solussa tapahtuvaa lentoliikennettä. Lentoratataltiot viedään solukkaan siten, että solun läpäisevä rata kuuluu kyseiseen soluun. Vasemmassa laidassa on esitetty solukosta yksi korkeusleikkaus mallinnettua

havaintotodennäköisyyttä, visualisoituna kartan päälle.

Mallinnusta vastaavasti tilavuusalkioiden suorituskykytunnusluvut voidaan laskea todelliseen mitattuun dataan perustuen. Tutkahavainnot assosioidaan oikeaan lentoratataltioon siihen kehitetyillä algoritmeilla. Algoritmi perustuu samankaltaisuutta kuvaavien metriikoiden laskentaan seurantojen ja lentoratataltioiden välillä – tutkahavainnot puolestaan on liitetty seurantoihin ja tällä yhteydellä saadaan myös havainnot liitettyä lentoratataltioon. Tämän jälkeen voidaan laskea se osuus lentoradasta, jossa kohde on havaittu ja se osuus, jossa sitä ei ole havaittu. Havaitun lentorataosuuden suhde koko rataan (tilavuusalkion sisällä) on havaintotodennäköisyys. Vastaavasti havainnon etäisyys lentoradasta kertoo havainnon tarkkuuden eri suunnissa (etäisyys, atsimuutti, Euclidinen, korkeus). Mitä enemmän lentoratoja on valaisu-alkion sisällä, sitä tarkempi estimaatti mitatusta suorituskyvystä muodostuu.

Tutkan suorituskykymallin optimoinnin muotoilimme hakuongelmaksi, jossa etsitään tutkamallille optimaaliset parametrit kuten antennivahvistukset elevaatiokulman funktiona, tutkan signaalinkäsittelyvahvistus ja ympäristöolosuhteiden vaikutusta mallintavat suureet. Vaikka ongelman analyttinenkin ratkaiseminen olisi ollut mahdollista, päädyimme hakualgoritmin kehittämiseen, koska se sellaisenaan käytännössä mahdollistaa minkä tahansa yksittäisen tutkamallin parametrin tai tutkamallin parametrijoukon optimoimisen joustavasti. Optimoinnin kannalta mielekäs parametrijoukko riippuu niin tutkan tyypistä kuin vallitsevista olosuhteistakin. Kuva 3 havainnollistaa tilannetta, jossa alkuperäinen mallin tuottama suorituskykyennuste poikkeaa selkeästi todellisesta mitatusta suorituskyvystä. Kuva esittää tilanteen ainoastaan yhden korkeuskerroksen osalta, vaikka kaikki korkeudet huomioidaan optimoinnissa. Optimoinnin jälkeen suorituskykyennuste seuraa tarkasti mitattua suorituskykyä.

Menetelmä osoittautui alustavien testien perusteella toimivaksi. Lisää kokeita kuitenkin täytyy tehdä, jotta nähdään, miten kattavasti eri tapauksiin menetelmää voidaan soveltaa. Esimerkiksi sääilmiöiden vaikutuksen oppimista ei ole vielä testattu. Ilma-aluksen lentosuuntaa tai sen tutkapoikkipinta-alan suuntariippuvuutta ei myöskään erikseen tarkasteltu oppimisessa. Tarvittavan opetusdatan määrään ja menetelmän yleistämiskykyyn täytyy myös kiinnittää huomiota.



- K Vasemmalla on alkuperäisellä tutkamallin parametrioinnilla muodostettu  
 u ennuste tutkan havaintotodennäköisyydestä (probability of detection,  
 v  $P_d$ ). Keskellä on mittauksista laskettu  $P_d$ . Oikealla on ennustettu  $P_d$   
 käyttäen optimaalisia tutkamallin parametreja. Nuolilla on esitetty tutkan

- a suunta. Kaikki kolme kuvaa edustavat yhtä korkeusleikkausta kuvan 2 kaltaisesta kolmiulotteisesta solukosta. Keskimmaisessä kuvassa valkoinen väri tarkoittaa, että kyseisessä solussa ei ole yhtään lentoratalttioiden näytettä.

### Seurantalaskimen suorituskykymallin optimointi

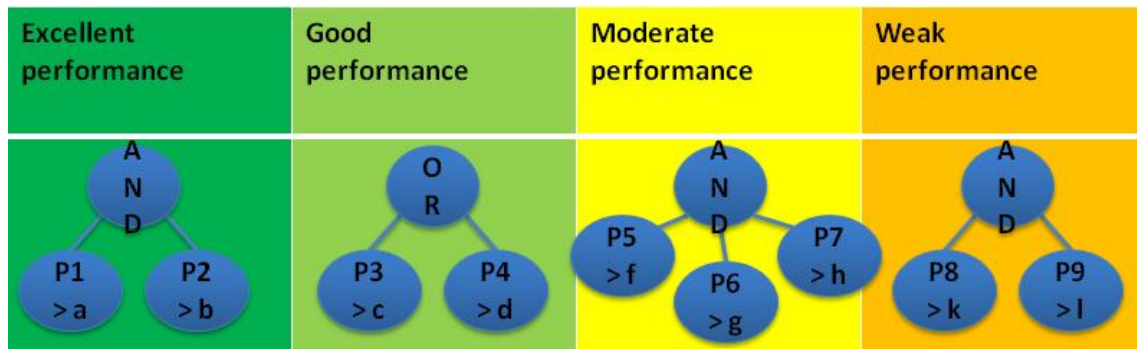
Koska seurantalaskin monimutkaisena ohjelmistopohjaisena järjestelmänä on vaikea mallintaa matemaattisesti tai fysikaalisesti ja Monte-Carlo -toistokokeeseen perustuva simulaatiopohjainen mallintaminen on laskennallisesti epämieliekäs ja vaatii todellisen seurantalaskinalgoritmin imitoimisen, päätimme luoda seurantalaskimen mallin koneoppimisen keinoin. Mitatut lentoradat assosioimme automaattisesti seurantojen kanssa siihen kehittämällämme algoritmilla. Tutkan ja seurantalaskimen suorituskykytunnusluvut laskemme tuotettujen assosiaatioiden avulla, kuten edellisessä alakohdassa kuvailtiin. Tutkien mittauksiin perustuva suorituskyky on seurantalaskinmallin sisäänmeno, kun taas mallin tavoiteulostulo on seurantalaskimen mittauksiin perustuva suorituskyky. Ongelman ratkaisemisessa pyritään koneoppimisen keinoin luomaan yksinkertainen, helposti tulkittava, malli, joka kuvaa tutkan suorituskyvyn ja seurantalaskimen suorituskyvyn välillä olevan syy-seuraussuhteen. Koneoppimiseen sovelsimme geneettiseen ohjelmointiin perustuvaa menetelmäämme<sup>1</sup>.

Kuvassa 4 on konseptitason esimerkki määrittelemästämme seurantalaskimen suorituskykymallista. Esimerkissä suorituskyky on jaettu neljään tasoon: erinomainen, hyvä, keskinkertainen ja heikko. Tasojen määrittely seurantalaskimen suorituskykytunnuslukujen perusteella jätetään järjestelmän operaattorin tehtäväksi. Määrittelytehtävä on hyvin suoraviivainen ja intuitiivinen – käytännössä suorituskykyä esimerkiksi pidetään hyvänä, jos seurannan onnistumisen todennäköisyys on riittävän suuri ja seuranta on riittävän tarkka. Operaattorin tehtäväksi jää kertoa, millä seurantalaskimen suorituskykytunnusluvuilla onnistuminen halutaan kuvata ja mikä (lukuarvo) on riittävän hyvä esimerkiksi kuvaamaan tarkkuutta. Geneettiseen ohjelmointiin perustuvaa menetelmää käytetään erikseen jokaiselle suorituskykytasolle tutkan suorituskyvyn ja seurantalaskimen suorituskyvyn välisen riippuvuussuhteen oppimiseksi. Tuloksena saadaan riippuvuussuhdetta kuvaava yksinkertainen sääntö jokaiselle suorituskykytasolle. Kuvan 4 mukaisesti malli ennustaa esimerkiksi erinomaista seurantalaskimen suorituskykyä, kun tutkan suorituskykytunnusluku  $P1$  on suurempi kuin kynnyisarvo  $a$  ja tutkan suorituskykytunnusluku  $P2$  on suurempi kuin kynnyisarvo  $b$ .

Opittuja seurantalaskimen suorituskykymalleja testattiin vertaamalla niiden tuottamia binäärisiä luokittelutuloksia todelliseen mitattuun seurannan suorituskykytasoon. Testien perusteella opitut mallit ennustavat seurannan suorituskykytason oikein yli 90 prosentin todennäköisyydellä. Saadut tulokset osoittavat, että luotettava seurantalaskimen suorituskykymalli voidaan oppia automaattisesti mittausdatasta.

---

<sup>1</sup> M. Ruotsalainen, J. Jylhä ja A. Visa, Reasoning Logical Rules from Multi-sensor Data for Lifecycle Management of Aircraft Structures, Proc. IEEE Congress on Evolutionary Computation, s. 3221–3227, kesäkuu 2013.



K Seurantalaskimen suorituskykymallin konseptitason esimerkki.  
 u Suorituskyvyn kuvaus on annettu esimerkissä neljällä erikseen  
 v määritellyllä tasolla. Kuvassa esitetyt ehdot (ehtorakenne ja  
 a kynnsarvot) ovat koneopittuja mittausdataan perustuen. Ehtoja voi käyttää seurantalaskimen suorituskyvyn ennustamiseen tutkamallin ulostulojen perusteella.  $P1...P9$  viittaavat tutkamallin ulostuloihin. Esimerkiksi, jos  $P1 > a$  ja  $P2 > b$ , malli ennustaa, että seurantalaskimen suorituskyky on erittäin hyvä.

Seurantalaskimen suorituskykymallin optimoinnista saadut alustavat tulokset kannustavat jatkokehittämään menetelmää. Oppimisessa hyödynnetyt tutkan suorituskykytunnusluvut olivat yksinkertaisia, joten monimutkaisempien mittojen määrittely ja laskeminen saattaisi tarjota nykyistä parempaa informaatiota koneoppimiselle. Huomiota pitäisi tunnuslukujen laskennassa kiinnittää nykyistä enemmän myös usean tutkan suorituskyvyn yhdistämiseen. Menetelmä tuottaa tällä hetkellä erillisen säännön jokaiselle suorituskykytasolle siten, että jokainen sääntö ennustaa tutkien suorituskyvyn perusteella, kuuluuko seurantalaskimen suorituskyky sille suorituskykytasolle, jota sääntö edustaa, vai ei. Jotta luokittelu voitaisiin suorittaa useaan luokkaan ilman mahdollisia ristiriitaisuuksia, tarvittaisiin algoritmi – eräänlainen metaluokittelija – yhdistämään erilliset binääriset luokittelutulokset yhdeksi päätökseksi. Lisäksi kuten tutkamallin oppimisen kanssa, opetusdatan määrään, mallin kattavaan yleistyskykyyn sekä myös mallin toimintaan eri käyttötapauksissa kannattaa perehtyä jatkossa tarkemmin.

Tietokanta oppimisessa hyödynnettävän datan tallentamiseen

Tässä hankkeessa kehitetty tutkamallin ja seurantalaskinmallin optimointikonsepti on suunniteltu ja toteutettu automaattiseksi siten, että sitä on mahdollista käyttää ilman manuaalista työtä uudestaan ja uudestaan, kun uutta dataa kerätään. Jotta online-oppiva järjestelmä kykenee ajan kuluessa oppimaan kaikki oleelliset toimintaolosuhteet ja parametrit, mittausdataa on kerättävä paljon. Datan varastointiin historiatiedoksi kehitimme oliopohjaisen tietokannan, joka mahdollistaa nopeat ajan ja paikan perusteella indeksoidut tietokantahaut suuresta datamäärästä. Tietokanta on laadittu Javalla. Oliona tietokannassa toimii esimerkiksi lentoratataltio. Tietokannan olio sisältää kaiken oliota koskevan hyötytiedon ja olioiden välille kytetään luomaan osoittimia. Tällöin esimerkiksi rata-assosiointialgoritmin toisiinsa assosioimat lentoratataltio ja vastaava seuranta ovat tietokannassa yhdistetty assosiaatiota kuvaavalla osoittimella, jolloin ne ikään kuin löytävät toisensa nopeasti tietokannasta ja ovat kytketty toisiinsa tietokannasta ladatussa tietorakenteessa.

Oliotietokantaa ja siitä muodostettua tietorakennetta kannattaa jatkossa testata erilaisissa käyttötapauksissa. Tietokannan käyttökelpoisuutta on syytä myös arvioida erittäin suurten datamäärien kannalta.

## 5. Loppupäätelmät

Tutkimuksessa kehitettiin konsepti ilmavalvontajärjestelmän suorituskykymallin optimointiin. Konseptia voidaan hyödyntää monissa sovelluksissa, joissa tarvitaan tarkkaa ennustetta järjestelmän suorituskyvystä. Esiin nousevat erityisesti olosuhteet, joissa suorituskykyennuste on hyvin epävarma perinteisin menetelmin laskettuna. Kehitetty konsepti on kuitenkin riippuvainen mittausdatasta, jota ei välttämättä ole vielä saatavilla kaikkien olosuhteiden osalta. Optimointikonseptin sisältämät automaattiset menetelmät kuitenkin takaavat, että uutta dataa kyetään hyödyntämään helposti. Seuraavaksi kannattaa jatkokehittää laadittuja alustavia menetelmiä ja testata konseptin soveltuvuutta eri käyttötapauksissa.

Kehitetyn konseptin ensimmäinen sovelluskohde on ilmavalvontajärjestelmän operaattorin päätöksenteon tukeminen. Tarkentuvaa suorituskykyennustetta kannattaa hyödyntää esimerkiksi tutkaryhmitysten ja toimintatilojen valinnassa eri tilanteisiin. Toinen mahdollinen käyttökohde on järjestelmän analyysin tai kalibroinnin tukeminen, jossa voidaan hyödyntää konseptin tarjoamaa mittauksiin perustuvaa tietoa esimerkiksi tutkien havaintokyvystä ja tarkkuudesta eri alueilla. Optimisäätö viittaa tutkamoodien tai järjestelmän parametroiden valintaan ja muuttamiseen optimaalisen suorituskyvyn saavuttamiseksi kaikissa olosuhteissa – esimerkiksi säteilyyn hakeutuvilta ohjuksilta suojautumisessa, tai välikkeen tai häirinnän väistössä. Optimisäätö edellyttää kyvyn tuottaa tarkat suorituskykyennusteet tarkasteltaville tilanteille. Adaptiivisen tai kognitiivisen tutkajärjestelmän kehityksessä on mahdollista hyödyntää edellä kuvattua optimisäädön periaatetta ja vastaavasti tässä hankkeessa kehitettyä tarkkaa suorituskykymallinnusta.

Tämä tutkimushanke on edennyt ensimmäisen vuoden osalta suunnitelmien mukaisesti. Tutkimuskysymyksiin saatiin alustavat vastaukset. Tärkeimpänä johtopäätöksenä voidaan pitää optimoinnin ja koneoppimisen periaatteen soveltuvuuden osoittamista ilmavalvontajärjestelmän suorituskyvyn mallinnuksessa.

## 6. Tutkimuksen tuottamat tieteelliset julkaisut ja muut mahdolliset raportit

Tutkimuksen tuloksista kirjoitettiin (J. Jylhä, M. Ruotsalainen, V. Väisänen, R. Kerminen, A. Visa, M. Harju, K. Virtanen) tieteellinen artikkeli otsikolla "An Optimization Framework for Performance Prediction and Control of Air Surveillance System" ja se toimitettiin "2017 IEEE Radar Conference" -konferenssin vertaisarviointiin. Artikkelin sisältö on tämän raportin mukainen.