

TIIVISTELMÄRAPORTTI

Signaalitiedustelun resurssiystävälliset luokittelumenetelmät

Juha Kainulainen, Harp Technologies Oy, Tekniikantie 12, 02150 ESPOO, puh: +358 50 594 7121, s-posti: juha.kainulainen@harptechnologies.com
Matti Mikkola, Harp Technologies Oy

Tiivistelmä

Elektronisessa tiedustelussa (ELINT) on tarve nykyisten, tyypillisesti huippusuorituskykyä tavoittelevien ja laskennallisesti raskaiden ja resursseja vaativien, järjestelmien lisäksi edullisille laitteille, joilla voitaisiin ajaa laskennallisesti kevyempiä signaalinhavainnointi ja -luokittelumenetelmiä. Tällaisilla laitteistoilla ja menetelmillä voitaisiin täydentää, tai toteuttaa nopeasti tai paikallisesti, laajempien järjestelmien tuottamaa tilannetietoa. Tässä tutkimuksessa selvitettiin, millaiset *signaaliluokittelumenetelmät* ja *sensorikomponentit* voisivat soveltua resurssiystävälliseen signaalitiedusteluun.

Tutkimus koostui selvitys-, tutkimus- ja sovellusvaiheesta. Selvitysvaiheessa tehtiin kirjallisuuskatsaus erilaisiin luokittelumenetelmiin ja sensorikomponentteihin, tutkimusvaiheessa valikoituihin menetelmiin ja komponentteihin perehdyttiin tarkemmin ja lopuksi sovellusvaiheessa toteutettiin ja testattiin sekä sensoreita että luokittelumenetelmiä.

Selvitysvaiheessa opittiin, että luokittelumenetelmistä neuroverkkojen suorituskyky vaikuttaa lupaavimmalta. Näiden lisäksi tukivektorit ja satunnaismetsäluokittelu valittiin jatkotarkasteluun. Sensorikomponenteista laskenta-alustaksi tutkittiin mikrokontrollereita, yhden piirilevyn tietokoneita ja ohjelmoitavia porttimatriiseja, joista jatko-tarkasteluun valittiin yhden piirilevyn tietokoneet. Vastaanottimeksi valittiin edulliset ohjelmistoradiot.

Tutkimusvaiheessa aiemmin valitut luokittelumenetelmät toteutettiin tietokoneympäristössä ja niiden suorituskykyä testattiin käyttämällä kahta signaalikirjastoa, jotka sisälsivät tietoliikenne- ja tutkasignaaleja. Kullekin luokittelijalle määritettiin oikean luokittelun todennäköisyys ja sekaannusmatriisi. Paras luokittelutulos saavutettiin neuroverkoilla. Sensoritutkimuksessa vertailtiin kahta ohjelmistoradiota ja neljää yhden piirilevyn tietokonekokonaisuutta. Sensorikomponenttien oleellisia eroja ovat esimerkiksi ohjelmistoradion A/D-muuntimen tarkkuus sekä kaistanleveys ja laskenta-alustan prosessorin suorituskyky.

Tutkimuksen sovellusvaiheessa rakennettiin sensoriprototyyppisiä käyttämällä ohjelmistoradioita ja laskenta-alustoja. Niillä toteutettiin valitut luokittelumenetelmät. Sensorien toimivuus todennettiin laboratorio-olosuhteissa. Lisäksi sensorien suorituskyky määritettiin mittaamalla keskimääräinen luokittelunopeus eri luokittelijoilla. Tehokkaimmalla sensorilla pystyttiin tekemään yli 40 luokittelua sekunnissa.

Tutkimuksen lopputuloksena voidaan todeta ensinnäkin, että neuroverkot näyttävät lupaavalta signaalien luokittelumenetelmältä. Niitä voidaan rakentaa joustavasti siten, että ne soveltuvat pieniinkin laskenta-alustoihin. Tutkimuksessa neuroverkot saavuttivat sekä parhaan luokittelu-tarkkuuden että nopeimman luokittelun. Lisäksi voidaan todeta, että resurssiystävällisen sensorin toimintaa rajoittaa ennen kaikkea edullisen laskentayksikön prosessoriteho sekä rajoitettu kyky vastaanottaa ja prosessoida nopeaa datavirtaa.

Postiosoite
Postadress
Postal Address
MATINE/Puolustus
PL 31
FI-00131 Helsinki
Finland

Käyntiosoite
Besöksadress
Office
Eteläinen
00130 Helsinki
Finland

Puhelin
Telefon
Telephone
Vaihe 295 160

s-posti, internet
e-post, internet
e-mail, internet
matine@defmin.fi
www.defmin.fi/ma



1. Johdanto

Elektroninen sodankäynti on kiinteä osa nykyaikaisessa sodankäyntiä ja sähköinen ulottuvuus määritellään usein yhdeksi taistelukentän oleellisista ulottuvuuksista. Signaalitiedustelussa (SIGINT) mitataan ja analysoidaan vastapuolen radiotaajuisia (RF, Radio Frequency) lähetteitä ja erityisesti, elektronisessa tiedustelussa (ELINT) mitataan signaalien radiotaajuisia ominaisuuksia (ei esimerkiksi viestisisältöä). Tyypillisiä ELINT-analyysiin liittyviä osa-alueita ovat esimerkiksi heikkojen signaalien havaitseminen, signaalien erottelu, signaalien luokittelu, karakterisointi tai paikantaminen. Tässä tutkimuksessa tutkittiin menetelmiä, joilla signaalien luokittelua voidaan tehdä laskennallisesti kevyin menetelmin.

Tyypilliset signaalitiedustelujärjestelmät perustuvat suureen laskentatehoon ja käyttävät esimerkiksi grafiikkakiihdyttämiä signaalianalyyseissa. Tällaiset järjestelmät vaativat paljon tehoa, tilaa, ja ovat kalliita – toki myös suorituskykyisiä. Kuitenkin, modernissa epäsymmetrisessä sodankäynnissä nähdään, että laskentaintensiivisten ja hyvin suorituskykyisten signaalitiedustelujärjestelmien lisäksi erilaisissa operaatioissa on tarve edullisille ja riittävän suorituskyvyn tarjoaville järjestelmille, joita voitaisiin esimerkiksi levittää valvottavalle alueelle ja uhrata tarvittaessa, siirtää suoraviivaisesti paikasta toiseen esimerkiksi dronien avulla, tai levittää lentokoneesta maastoon välitöntä tiedonkeruuta varten.

Tässä hankkeessa tutkitaan tällaisia *riittävän suorituskyvyn tarjoavia*, edullisia ELINT-sensorien kyvykkyyksiä. Tutkimuksen kohteena on erityisesti havaittujen signaalien luokittelumenetelmät sekä tähän soveltuvat laitteistot.

2. Tutkimuksen tavoite ja suunnitelma

Tutkimuksen tavoitteet muotoiltiin seuraaviin tutkimuskysymyksiin:

- Minkälaiset signaalinluokittelumenetelmät soveltuvat resurssiystävällisiin ELINT-sensoreihin?
- Kuinka ym. luokittelumenetelmät voidaan toteuttaa resurssiystävällisessä ELINT-sensorissa?
- Minkälaisista elementeistä resurssiystävällinen ELINT-sensori voidaan toteuttaa?
- Miten resurssiystävällisen ELINT-sensorin suorituskykyä mitataan, ja minkälaisista suorituskykyä niillä saavutetaan?
- Minkälaisia rajoituksia resurssiystävällisellä ELINT-sensorilla on?

Ylläolevat tutkimuskysymykset jaettiin kahteen kokonaisuuteen: Toisaalta, tutkitaan (matemaattisia) signaalinluokittelumenetelmiä. Toisaalta, tutkitaan laitteistoja, joilla näitä menetelmiä voidaan toteuttaa resurssiystävällisessä ELINT-sensorissa. Näin ollen tutkimus jaettiin kahteen tutkimuslinjaan: menetelmätutkimukseen sekä laitteistotutkimukseen. Sekä menetelmä- että laitteistotutkimus jaettiin kolmeen toisiaan ajallisesti seuraavaan vaiheeseen: selvitys-, tutkimus- ja sovellusvaiheeseen.

Selvitysvaiheessa tehtiin kirjallisuuskatsaus olemassa oleviin luokittelumenetelmiin ja sensorialustoihin. Menetelmiä arvioitiin suorituskyvyn ja resurssien käytön kannalta. Sensorialustojen kohdalla pohdittiin eri komponenttivalintoja vastaanottimeksi ja laskentalustaksi markkinoilla olevien ratkaisujen joukosta. Lopuksi menetelmistä ja alustoista valitaan lupaavimmat tutkimusvaiheen syventävää tutkimusta varten.

Tutkimusvaiheessa valittujen luokittelumenetelmien ja sensorikomponenttien suorituskykyä vertailtiin tarkemmin. Menetelmät toteutettiin tietokoneympäristössä käyttäen julkisesti



saatavilla olevia signaalikirjastoja, ja menetelmien suorituskky määritettiin signaaliparametrien funktiona. Laitteistotutkimuksessa hankittiin valikoidut sensorikomponentit sekä toteutettiin luokittelumenetelmät näillä alustoilla. Sensorikomponenteista tunnistettiin erityisesti laitteen toiminnallisuuteen vaikuttavia ominaisuuksia. Lisäksi suunniteltiin testiympäristö sensorien toiminnan mittaamiseen.

Sovellusvaiheessa menetelmien ja sensorien toimintaa demonstroitiin laboratorio-olosuhteissa. Toiminnallisuus todennettiin luomalla opetusaineistoja vastaavia testiläheteitä ja vastaanottamalla ja prosessoimalla näitä kokoonpanuilla sensoriprototyypeillä. Sensorien suorituskky mitattiin määrittämällä luokittelunopeus kullakin menetelmällä.

3. Aineisto ja menetelmät

3.1 Selvitysvaihe

3.1.1 Luokittelumenetelmät

Tutkimuksessa tarkasteltiin neljää erilaista luokittelumenetelmää: päätöksentekopuu ja satunnaismetsä, tukivektorikone, opetusvektorikvantisointi ja neuroverkot. Päätöksentekopuu on puumallia hyödyntävä luokittelumenetelmä, jota käytetään laajalti yksinkertaisuutensa ja luettavuutensa vuoksi. Se koostuu solmuista ja lehdistä. Kukin solmu sisältää yhtä muuttujaa koskevan ehdon, jonka perusteella siirrytään toiseen solmun lapsista. Lapset voivat olla joko solmuja tai lehtiä. Puussa edetään kunnes saavutaan yhteen lehdistä, jotka toimivat puun päätepisteinä ja määrittävät luokan. Päätöksentekopuilla on taipumus ylisovittua opetusaineistolle, jolloin puun yleistyskyky on heikompi. Tätä voidaan lievittää opettamalla useita puita saman opetusaineiston eri osajoukoilla. Tuloksena syntyy puujoukko, jota kutsutaan satunnaismetsäksi. Luokittelu satunnaismetsällä tapahtuu metsän puiden välisenä äänestyksenä, jossa eniten ääniä saanut luokka valitaan.

Tukivektorikone on luokittelumenetelmä, joka pyrkii määrittelemään luokkien välisen rajapinnan ominaisuusavaruudessa. Se etsii opetusvaiheessa tukivektoreita, eli näytteitä tämän rajapinnan lähistöltä, ja asettaa niille painokertoimet. Luokittelu tapahtuu tukivektoreita ja painokertoimia käyttäen. Perusmuotoinen tukivektorikone on rajoitettu kahteen luokkaan ja lineaariseen rajapintaan. Yhdistämällä useita luokittelijoita voidaan laajentaa toiminnallisuutta useille luokille ja kernelifunktioiden käyttö mahdollistaa epälineaariset rajapinnat.

Opetusvektorikvantisointi on luokittelumenetelmä, jossa määritellään joukko opetusvektoreita toimimaan esimerkkeinä luokkien edustajista. Vektorien lukumäärä voi olla yksi tai useampi luokkaa kohden. Opetusvaiheessa vektorit alustetaan satunnaisluvuilla ja niitä siirretään iteratiivisesti kohti edustettavan luokan jäseniä ja vastaavasti pois päin muiden luokkien jäsenistä. Uuden datan luokittelu tapahtuu etsimällä lähimmät vektorit ja valitsemalla yleisin luokka näiden keskuudessa. Opetusvektorikvantisointi on periaatteeltaan samankaltainen menetelmä kuin tukivektorikone, koska molemmat tekevät luokittelupäätöksen esimerkkijoukon avulla. Menetelmät eroavat siinä, että opetusvektorit asettuvat edustamansa luokan keskelle, kun taas tukivektorit sijaitsevat luokkien rajapintojen lähellä. Toinen eroavaisuus on se, että opetusvektorit ovat keinotekoisia, kun taas tukivektorit valitaan opetusjoukosta.

Neuroverkot ovat rakenteeltaan luonnollisia hermoverkkoja matkivia luokittelijoita, jotka koostuvat neuroneista. Verkon kullakin neuronilla on joukko kertoimia ja aktivaatiofunktio, joiden perusteella se käsittelee sille annetun syötteen ja antaa vasteen siihen kytketyille neuroneille. Neuroverkon sisällä neuronit ovat ryhmitelty kerroksiin: syötekerros ottaa vastaan luokiteltavan datan, yksi tai useampi piilotettu kerros käsittelee sitä ja vastekerros antaa lopputuloksen. Kerrokset voidaan jakaa myös niiden sisältämien neuronien tyyppin mukaan.



Katsaukseen perustuen jatkotutkittavaksi valittiin kolme luokittelumenetelmää: satunnaismetsä, tukivektorikone ja neuroverkot.

3.1.2 Laitteistotutkimus

ELINT-sensorin tulee olla kykenevä vastaanottamaan signaaleja kohtuullisen laajalla taajuusalueella. Luokittelua varten signaalit pitäisi saada ulos vastaanottimesta I/Q-muodossa riittävällä tarkkuudella ja näytteistystaajuudella. Lisäksi vastaanottimen tulisi olla suhteellisen edullinen, jotta sensorin kokonaishinta pysyisi kohtuullisena. Nämä ominaisuudet yhdistyvät ohjelmistoradiossa. Ohjelmistoradio on radio, jossa osa ominaisuuksista on toteutettu ohjelmallisesti ja ne ovat täten käyttäjän säädettävissä. Usein ohjelmistoradiolla tarkoitetaan ohjelmistolla määritettyä radiota, jossa etupää (RF-suodatin, taajuussekoitin, vahvistin ja A/D-muunnin) on toteutettu laitteistolla. Ohjelmistoradion etuja ovat muun muassa laaja taajuusalue ja modulaarisuus.

Sensorin laskentayksikön tulisi olla kykenevä lukemaan signaaleja vastaanottimelta riittävällä nopeudella. Lisäksi sillä pitäisi olla riittävä suorituskyky luokittelua varten, mukaanlukien datan esikäsittelyn, sekä ohjaamaan vastaanottimen toimintaa. Laskentayksiköksi harkittiin mikrokontrolleria, yhden piirilevyn tietokonetta ja FPGA-piiriä.

Arduino on tunnettu yhden piirilevyn mikrokontrollerialusta. Arduino-levyjä voidaan ohjelmoida käyttäen C- ja C++-kieliä. Arduinot tukevat sarjaporttiin kytkettäviä lisäosalevyjä, joiden avulla laitteeseen voidaan lisätä esimerkiksi sensoreita ja liitäntöjä.

Yhden piirilevyn tietokoneista Raspberry Pi on sarja alunperin opetuskäyttöön suunniteltuja laitteita, joita käytetään esimerkiksi robotiikassa. Laitteen suorituskykyä tietyissä sovelluksissa voidaan kasvattaa USB-väylään kiinnitettävällä ulkoisella kiihdyttimellä. Coral Dev Board on Googlen valmistama yhden piirilevyn tietokone, joka on ensisijaisesti suunniteltu kehitysalustaksi Edge TPU -laskentapiirille. Tinker Board on sarja ASUS:n valmistamia yhden piirilevyn tietokoneita, joista erityisesti tekoälysovelluksiin on suunniteltu Tinker Edge R.

FPGA (field-programmable gate array, suom. ohjelmoitava porttimatriisi) on uudelleenohjelmoitava mikropiiri, johon voi lisäksi kuulua prosessori. FPGA sisältää useita logiikkasoluja, joita yhdistelemällä voidaan ohjelmoida piiri eri tarkoituksiin soveltuvaksi. Ohjelmointi tapahtuu laitteistokuvauskielillä, jolla voidaan kuvata digitaalisen logiikkapiirin rakenne. Kehitysvaiheessa FPGA:n toimintaa voidaan tarkastella kehityskortin avulla. FPGA:t tarjoavat hyvän suorituskyvyn energiankulutukseen nähden ja niitä käytetään muun muassa mikropiirin suunnittelussa.

Katsausta syvennettiin edelleen tutkimusvaiheessa.

3.2 Tutkimusvaihe

3.2.1 Luokittelumenetelmät

Tutkimusvaiheessa valitut luokittelumenetelmät toteutettiin tietokoneympäristössä, ja niiden suorituskykyä käyttäen kahta signaaliaineistoa. Ensimmäisenä aineistona tietoliikennesignaali kirjastoa, ja toisena aineistona käytettiin tutkasignaali kirjastoa. Aineistot jaettiin satunnaisesti opetus-, validaatio ja testijoukkoihin jaolla 50%/25%/25%.

Satunnaismetsien toteutuksessa luokittelumuuttujina käytettiin aluksi aikatazon kumulantteja. Metsät rakennettiin siten, että uudet puut keskittyvät luokittelemaan niitä opetusjoukon näytteitä, joissa aiemmat puut epäonnistuivat. Metsän parametreina olivat yksittäisen puun maksimisyvyys, puiden lukumäärä ja oppimisvauhti.

Tukivektorikoneet toteutettiin käyttäen luokittelumuuttujana käytettiin tehospektriä. Testissä käytettiin lineaarista tukivektorikonetta. Jokaiselle luokkavarille opetettiin yksi tukivektorikone ja nämä yhdistettiin käyttäen yksi vastaan yksi -periaatetta. Tukivektorikoneen parametreina olivat kernelifunktion hajontaparametri, kerneliapproksimaation kantavektorien lukumäärä ja regularisointiparametri. Validaatiojoukkoa käyttäen näille parametreille etsittiin parhaiten toimivat arvot.

Neuroverkoista tutkittiin neljää erilaista avoimeen lähdekoodiin perustuvaa referoitua neuroverkkorakennetta. Opetuksen jälkeen verkot kvantisoitiin sensorialustoja varten.


Luokittelijoiden toimintaa mitattiin sekä tutkimalla niiden luokittelukykyä ja sekaantuvuutta luokkakohtaisesti sekä kohinatason funktiona. Tuloksia on esitelty kappaleessa 4.

3.2.2 Laitteistotutkimus

Tutkimuksessa päätettiin keskittyä halvimpaan (noin 50-250 €) laskenta-alustakategoriaan. Tutkimusvaiheen aikana syvennettiin markkinoilla oleviin laskenta-alustavaihtoehtoihin. Tutkituista laskentayksiköistä Arduino on huokein, mutta sen rajallinen suorituskyky ja erityisesti matala näytteistystaajuus tekevät siitä huonosti soveltuvan tämän projektin käyttötarkoitukseen. FPGA:t ovat hintaluokasta riippuen hyvinkin tehokkaita ja soveltuvia reaaliaikaiseen signaalinkäsittelyyn, mutta luokittelumenetelmien toteuttaminen niillä vaikuttaa huomattavan työläältä. Raspberry Pi ja muut yhden piirilevyn tietokoneet ovat yhteensopiva USB-ohjelmistoradioiden kanssa ja niille on saatavilla useita valmiiksi toteutettuja luokittelumenetelmiä erilaisten kirjastojen muodossa. Lisäksi niiden suorituskykyä voidaan kasvattaa tarvittaessa ulkoisella laskentapiirillä. Näin ollen päädyttiin valitsemaan neljä erilaista laskenta-alustakokonaisuutta, jotka perustuvat yhden piirilevyn tietokoneisiin.

Ohjelmistoradioiden joukosta valittiin SDRPlay RSP1A, joka on hyvä kompromissi suorituskyvyn ja hinnan välillä, sekä RTL-SDR v3, joka tarjoaa hieman vähemmän suorituskykyä pienemmässä paketissa ja huokeammalla hinnalla.

Sovellusosioon valikoidut laskenta-yksiköt on esitetty kuvassa 1 ja ohjelmistoradiot kuvassa 2.



Ominaisuus	Raspberry Pi 4B	RPi 4B + Coral USB	Coral	Asus Tinker Edge R
Proessori	1.5 GHz, neljä ydintä	1.5 GHz, neljä ydintä	1.5 GHz, neljä ydintä	1.4-1.8 GHz, kuusi ydintä
Muisti	8 GB	8 GB	4 GB	4 GB
Muuta		Google Edge TPU	Google Edge TPU	Rockchip NPU
Hinta	90 €	150 €	190 €	250 €

Kuva 1. Tutkimuksessa käytetyt laskenta-alustat. Vasemmalta oikealle: Raspberry 4 Pi 4B, Raspberry Pi 4B ja Coral kiihdytin, Coral Dev Board ja Asus Tinker Edge R.



Ominaisuus	RTL-SDR V3	SDRPlay RSP1A
Taajuusalue	500 kHz – 1766 MHz	1 kHz – 2 GHz
Kaistanleveys	Max 2.4 MHz	Max 10 MHz
A/D-muunnin	8 bittiä	14 bittiä
Hinta	40 €	140 €

Kuva 2. Tutkimuksessa käytetyt ohjelmistoradiot. Vasemmalta oikealle: Raspberry 4 Pi 4B, Raspberry Pi 4B ja Coral kiihdytin, Coral Dev Board ja Asus Tinker Edge R.

Lisäksi sovellusvaihetta varten kehitettiin ohjelmistoradioon perustuva signaalilähetin, jolla voitiin tuottaa opetusaineiston luokkia vastaavia signaaleja. Lähettimenä käytettiin Ettus USRP B205 mini -ohjelmistoradiota, jolla lähetettiin erilaisia signaalityyppejä käyttäen GNU Radio -ohjelmistoa.

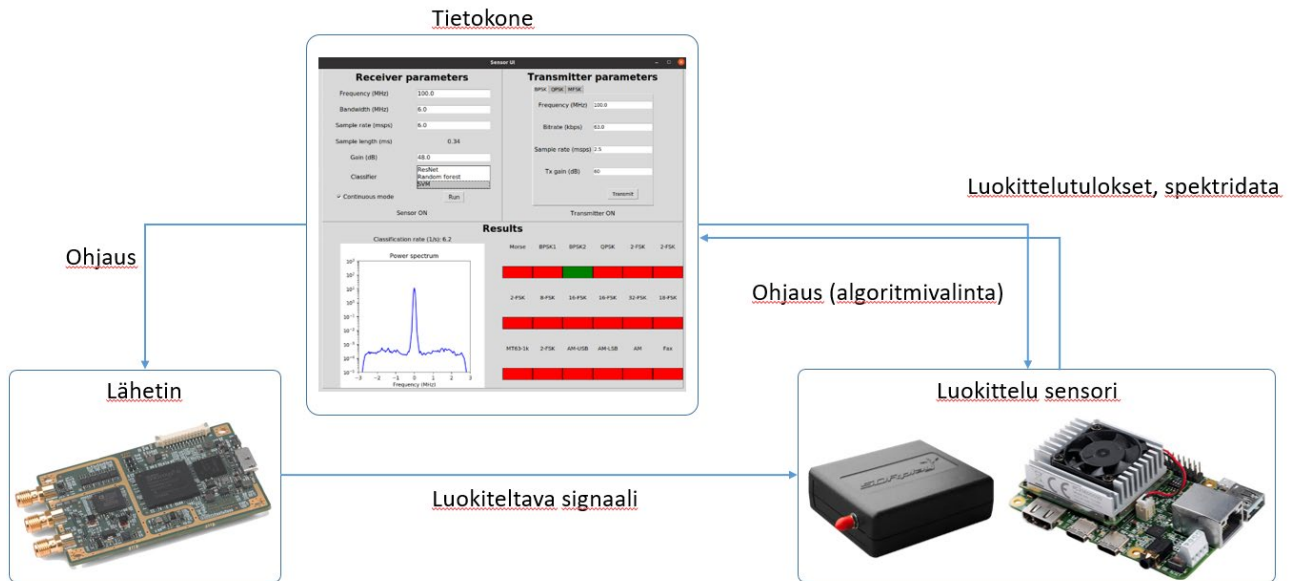
3.3 Sovellusvaihe

3.3.1 Luokittelumenetelmät

Sovellusvaiheessa kehitetyille sensoriprototyypeille asennettiin radioiden ajurit sekä luokittelumenetelmät sisältävät kirjastot. Sensorien toiminnallisuudet toteutettiin Pythonilla. Luokittelumenetelmien luokittelukykyä ei testattu sovellusvaiheessa, vaan tässä vaiheessa arvioitiin laskennan nopeutta ja rajoitteita. Näitä tuloksia on käsitelty luvussa 4.

3.3.2 Laitteistotutkimus

Sovellusvaiheessa kokoonpantujen sensoreiden toiminta todennettiin laboratorioympäristössä luomalla joitain opetusaineiston luokkia vastaavia signaaleja ohjelmistoradiolla ja prosessoimalla niitä sensoreilla. Lähetettävän signaalin tehotasoa ja keskitaajuutta vaihdeltiin. Sensorit yhdistettiin suoraan lähettimeen käyttäen koaksiaalikaapelia. Lisäksi sensoreiden suorituskykyä testattiin ajamalla eri luokittelijoita ja mittaamalla luokitteluun kuluvaa aikaa. Testeissä sensoreita käytettiin ajamalla tarkoitukseen tehty ohjelma joko suoraan alustalta tai etäyhteyden avulla. Sensorien etäkäyttöä varten tehtiin graafinen käyttöliittymä, jonka avulla voitiin myös ohjata lähetintä ja tarkastella tuloksia. Mittausjärjestely on esitetty kuvassa 3. Tuloksia on käsitelty luvussa 4.



Kuva 3. Sovellusvaiheen mittausjärjestely: Oikealla kehitetty sensoriprototyyppi, joka koostuu ohjelmistoradiosta ja laskenta-alustasta. Vasemmalla lähettimenä toiminut ohjelmistoradio. Ylhäällä kehitetty reaaliaikainen sensoriprototyyppin käyttöliittymä, jolla voitiin aktivoida luokittelijoita, seurata luokittelutulosta, sekä nähdä sensorin luokittelunopeus.

4. Tulokset ja pohdinta

Menetelmätyössä mitattiin eri luokittelijoiden kykyä luokitella kahdentyyppisiä signaaleja (HF-tietoliikenne ja UHF-tutkasignaalit). Sovellusvaiheeseen valittiin toteutettavaksi satunnaismetsä, tukivektorikone ja neljä eri arkkitehtuurista neuroverkkoa. Yhteenveto eri luokittelijoiden keskimääräisestä oikeasta luokittelutodennäköisyydestä on esitetty taulukossa 1.

Taulukko 1. Keskimääräinen oikean luokittelun todennäköisyys, joka saavutettiin eri signaalikirjastoille käyttämällä eri luokittelijoita.

Aineisto	Neuroverkko #1	Neuroverkko #2	Neuroverkko #3	Neuroverkko #4	Tukivektorikone	Satunnaismetsä
Tietoliikenne	0.88	0.84	0.80	0.61	0.63	0.35
Tutka	0.96	0.96	0.98	0.91	0.79	0.78

Tuloksesta nähdään, että testatut neuroverkot yltyvät jopa 98 % oikeaan luokittelutodennäköisyyteen. Yleisesti voidaan sanoa, että luokittelumenetelmistä neuroverkot ovat monipuolisimpia, vaikuttavat suorituskyvyltään parhaalta. Lisäksi, ne kykenevät käsittelemään aikataason signaaleja siinä missä tukivektori ja satunnaismetsä käyttävät signaalista laskettuja ominaisuuksia.

Tietoliikennesignaali joukko osoittautui kahdesta datapaketista kaikille luokittelijoille haastavammaksi johtuen keskimäärin matalammasta signaali-kohinasuhteesta ja suuremmasta luokkamäärästä. Tällä aineistolla useimmat neuroverkot antoivat oikean luokittelutuloksen yli 80% todennäköisyydellä, joka oli selkeästi paras tulos tutkittujen menetelmien joukossa. Joukon kevyin verkko suoriutui jonkin verran muita huonommin päästen samankaltaiseen tulokseen kuin tukivektorikone. Satunnaismetsä suoriutui huonoiten



tutkituista menetelmistä. Maksimisuorituskyky lähes kaikilla menetelmillä saavutettiin signaali-kohina -suhteiden 5 dB ja 15 dB välillä, jonka jälkeen luokittelutulos ei enää parantunut. Tästä poikkeuksena oli satunnaismetsä, jonka luokittelutulos kasvoi melko tasaisesti. Useimmin luokitteluvirheitä tapahtui saman tyypin signaalien kesken ja näiden poiketen vain yhden modulaatioparametrin suhteen. Lisäksi satunnaismetsällä oli taipumus luokitella useita eri signaalityyppejä kahteen luokkaan ja sillä oli vaikeuksia erottaa eri amplitudimodulaatiot. Myös tutkasignaaliaineistolla neuroverkot olivat parhaiten toimivat menetelmät ja keskimääräinen oikean luokittelun todennäköisyys oli kaikilla verkoilla yli 90%. Tukivektorikoneen ja satunnaismetsän luokittelutulokset olivat keskenään samaa luokkaa ollen vähän alle 80%. Neuroverkkojen luokittelukyky ei muuttunut kovin paljoa signaali-kohina -suhteen funktiona, toisin kuin tukivektorikoneen sekä satunnaismetsän. Vaikein signaalityyppi kaikille menetelmille oli yksi taajuusmodulaatioista, mikä voi johtua sen pienemmästä näytemäärästä opetusaineistossa. Tukivektorikoneella ja satunnaismetsällä oli lisäksi taipumus luokitella signaaleja väärin pulssimodulaatioksi.

Sensorikomponenttiverailussa suurimmat erot ohjelmistoradioiden välillä ovat kaistanleveydessä ja A/D-muuntimen tarkkuudessa, joista jälkimmäinen voi vaikuttaa tukivektorikoneen tai satunnaismetsän luokittelutulokseen. Laskenta-alustat ovat keskenään melko samanlaisia yhden piirilevyn tietokoneita. Suurimpana erona on neuroverkkolaskennan kiihdytysyksikkö, joka Raspberry Pi:ssa on erillinen lisävaruste ja kahdessa muussa integroitu alustaan. Eroavaisuuksia on lisäksi muistikapasiteetissa ja suorittimissa. Muistikapasiteetti vaikutti olevan riittävä kaikille luokittelumenetelmille, joten sen ei pitäisi vaikuttaa suoritussykyyn. Tehokkaampi suoritin voi antaa Tinker Edgelle muita alustoja paremman luokittelunopeuden.

Sovellusvaiheessa sensoreiden toiminta todennettiin laboratorioympäristössä ja riittävällä lähetysteholla luokittelu toimi odotetusti. Lisäksi sensoreiden suoritussykyä testattiin mittaamalla niiden luokittelunopeus eri menetelmillä. Tulokset on esitetty taulukossa 2.

Taulukko 2. Luokittelunopeus (luokittelua/sekunti) eri menetelmillä ja alustoilla.

<u>Alusta</u>	<u>Neuroverkko #1</u>	<u>Neuroverkko #2</u>	<u>Neuroverkko #3</u>	<u>Tukivektori-kone</u>	<u>Satunnais-metsä</u>
RPi	4.5	11.6	14.6	4.8	3.5
RPi + Coral	4.4	16.1	14.6	4.8	3.5
Coral	5.2	18.5	16.2	7.2	5.4
Tinker Edge	13.0	33.2	43.9	9.8	7.9

Tuloksista nähdään, että selkeästi suoritussykyisin alusta oli Tinker Edge R, mikä johtui luultavasti paremmasta prosessorista. Coral Dev Board oli hieman nopeampi kuin Raspberry Pi myös satunnaismetsää ja tukivektorikonetta ajaessa, mikä oli yllättävää sillä nämä menetelmät eivät hyödy kiihdytinpiiristä. Ulkoisen Coral-laskentayksikön vaikutus näkyi vain yhdellä neuroverkolla. Tiedonsiirto USB-väylän yli tai muut luokitteluun liittyvät operaatiot saattavat rajoittaa luokittelunopeutta enemmän kuin laitteen laskentateho. Lisäksi nopeustestissä luokittelijoille syötettiin yksittäisiä signaaleja ja luokiteltaessa suurempia signaalijoukkoja kerralla erillisellä laskentayksiköllä voi olla suurempi vaikutus.

5. Loppupäätelmät

Tässä tutkimuksessa tutkittiin luokittelumenetelmiä ja sensorikomponentteja, joita voitaisiin käyttää resurssiystävällisessä signaalitiedustelusensorissa, sekä tutkittiin näiden suoritussykyä. Kaikissa tutkituissa laskenta-alustoissa oli riittävästi laskentatehoa



suorittamaan kaikkia luokittelumenetelmiä useita kertoja sekunnissa, mitä pidettiin alarajana mahdollisten sovellusten kannalta. Tutkituista menetelmistä parhaaseen luokittelukykyyn päästiin neuroverkoilla, jotka toimivat hyvin etenkin tutkasignaaleilla. Lähes kaikissa tapauksissa ne päihittivät muut menetelmät myös luokittelunopeudessa. Vaikka tutkitut neuroverkot ovat teoreettisesti raskaampia ja vaativat enemmän laskutoimituksia kuin vaikkapa satunnaismetsä, tehokas toteutus antaa niille edun. Muut menetelmät voisivat olla kilpailukykyisempiä, mikäli niille olisi saatavilla vastaavanlaisia, erityisesti kevyitä laskenta-alustoja varten suunniteltuja, toteutuksia. Jatkotutkimus voisi keskittyä esimerkiksi yhden luokittelumenetelmän toteuttamiseen mahdollisimman tehokkaalla tavalla, mikä olisi askel kohti käytännöllistä sensoria.

Seuraavaksi vastaamme asetettuihin tutkimuskysymyksiin.

- Minkälaiset signaalinluokittelumenetelmät soveltuvat resurssiystävällisiin ELINT-sensoreihin?

Hankkeessa tutkittiin kirjallisuuskatsauksen pohjalta tarkemmin neljää luokittelijakonseptia: päätöksentekopuu ja satunnaismetsä, tukivektorikone, opetusvektorikvantisointi ja neuroverkot. Näistä potentiaalisimmaksi sekä nopeudeltaan että luokittelutulokseltaan osoittautui neuroverkot, jonka variantteja testaattiin hankkeessa lopulta neljä kappaletta. Neuroverkoja on tutkittu paljon ja niiden rakentamiseen löytyy paljon ohjelmointikirjastoja ja muita työkaluja, mikä helpottaa niiden integrointia myös resurssiystävällisiin sensoreihin. Myös laitteistoja, joilla on neuroverkkolaskentaan tarvittavaa kiihdytystä, on markkinoilla. Lisäksi, neuroverkojen soveltuvuus moniin sovelluksiin vauhdittaa niiden kehitystä tulevaisuudessa. Tutkimuksemme perustuen siis neuroverkot vaikuttavat lupaavimmalta luokittelija-arkkitehtuurilta myös resurssiystävällisissä ELINT-sensoreissa.

- Kuinka ym. luokittelumenetelmät voidaan toteuttaa resurssiystävällisessä ELINT-sensorissa?

Resurssiystävällisiin ELINT-sensoreihin soveltuvat prosessoripohjaiset laskentaympäristöt. Näin ollen niihin voidaan toteuttaa toiminnallisuuksia yleisimmillä ohjelmointikielillä (Python, ..). Erityisesti neuroverkojen ohjelmointiin on lisäksi useita vapaan lähdekoodin ohjelmistoja saatavilla, joita voidaan käyttää verkkojen rakentamiseen ja opettamiseen.

- Minkälaisista elementeistä resurssiystävällinen ELINT-sensori voidaan toteuttaa?

Resurssiystävällinen ELINT-sensori voi perustua yksinkertaisimmillaan antenniin, ohjelmistoradioon ja laskenta-alustaan. Tässä hankkeessa keskityttiin tutkimaan ohjelmistoradiolta ja laskenta-alustalta vaadittavia ominaisuuksia. Monipuolisimmaksi laskenta-alustoiksi erityisesti edullisimmassa kategoriassa koettiin yhden piirilevyn tietokoneet. Monipuolisuutensa ansiosta niitä tuotetaan miljoonia, ja näin ollen tuotantokustannukset ovat hyvin maltilliset. Jo <200 € hintaan saadaan hyvin suorituskykyisiä laskenta-alustoja. Tutkimukseen valikoidut ohjelmistoradiot ja laskenta-alustat esitettiin aiemmin kuvassa 1 ja 2.

- Miten resurssiystävällisen ELINT-sensorin suorituskykyä mitataan, ja minkälaista suorituskykyä niillä saavutetaan?

ELINT-sensorin merkittävimpiä suorituskykyä kuvaavia parametrejä ovat sen kaistanleveys, toimintataajuusalue, kanavien lukumäärä sekä laskenta-alustan prosessorin laskentakyky. Tutkitussa edullisessa hintaluokassa tyypillisiä esimerkkejä näille on esitetty aiemmin kuvissa 1 ja 2.

Yhden piirilevyn tietokoneet perustuvat prosessorilla tapahtuvaan laskentaan eikä niissä ole



ohjelmoitavaa reaaliaikaiseen prosessointiin kykenevää logiikkaa. Prosessori suorittaa yhden luokittelutoimenpiteen, jonka jälkeen se pyytää ohjelmistoradiolta uuden signaalinäytteen prosessoitavaksi. Prosessoinnin aikana sensoriin tuleva signaali menee "hukkaan".

Laskentakyvyiltään tällaiset resurssiystävälliset laskenta-alustat kykenivät 4-40 luokittelun sekuntivauhtiin, kun ne prosessoivat 0.2 ms mittaisia signaalinäytteitä kaistanleveydellä 10 MHz.

- Minkälaisia rajoituksia resurssiystävällisellä ELINT-sensorilla on?

Merkittävimmät rajoitukset resurssiystävällisellä ELINT-sensorilla syntyvät laskenta-alustan prosessorinopeudesta. Luokittelu on toimenpiteenä laskentaintensiivinen ja näin ollen sensorin pullonkaulat ovat luokittelun toteuttavassa prosessorissa. Käytännön ELINT-järjestelmän toteutuksessa onkin merkittävä trade-off siinä, tehdäänkö luokittelua kevyessä sensorissa, vai kannattaako se tehdä signaalinäytteen perusteella vasta keskitetyssä laskentapisteessä.

Loppupäätelmänä kerrataan, että tutkimustuloksiin nojaten voidaan sanoa että resurssiystävällisillä ELINT-sensoreilla voidaan saavuttaa riittävää suorituskykyä tiettyihin käyttötapauksiin. Luokittelumenetelmistä neuroverkot vaikuttavat kaikista lupaavimmilta menetelmiltä.

6. Tutkimuksen tuottamat tieteelliset julkaisut ja muut mahdolliset raportit

Ei tehtyjä julkaisuja raportin kirjoittamisen aikaan.