



Vaasan yliopisto
UNIVERSITY OF VAASA

Aino-Eveliina Eloranta

**Monisensorinen kuvafuusio miehittämättömissä
ilma-alusjärjestelmissä ihmisen havaitsemiseksi
maastoetsinnöissä**

Tekniikan ja innovaatiojohtamisen
akateeminen yksikkö
Kandidaatintutkielma
Automaatio ja tietotekniikka

Vaasa 2026

VAASAN YLIOPISTO
Tekniikan ja innovaatiojohtamisen akateeminen yksikkö

Tekijä:	Aino-Eveliina Eloranta		
Tutkielman nimi:	Monisensorinen kuvafuusio	miehittämättömissä ilma-	alujärjestelmissä ihmisen havaitsemiseksi maastoetsinnöissä
Tutkinto:	Tekniikan kandidaatti		
Koulutusohjelma:	Energia- ja informaatiotekniikan ohjelma		
Opintosuunta:	Automaatio ja tietotekniikka		
Työn ohjaaja:	Janne Koljonen		
Valmistumisvuosi:	2026	Sivumäärä:	48

TIIVISTELMÄ:

Miehittämättömien ilma-alusjärjestelmien hyödyntäminen maastoetsinnöissä on nykyään vakiintunut käytäntö. Niiden käyttöön liittyy kuitenkin usein haasteita, jotka rajoittavat järjestelmien suorituskykyä ja tehokkuutta. Maasto-olosuhteissa sääolosuhteet ja etsintäympäristö ovat dynaamisia. Vaikeuksia voivat aiheuttaa muun muassa epäsuotuisat sääolosuhteet, kasvillisuuden aiheuttama peitteisyys sekä muuttuvat valo-olosuhteet. Jotta miehittämättömät ilma-alusjärjestelmät toimisivat tehokkaammin monimutkaisessa ja dynaamisessa ympäristössä, tarkastellaan tutkielmassa ratkaisuna kuvafuusiota. Tutkielman tavoitteena on selvittää kuvafuusion hyödyntämisen nykytilanne etsintätarkoitukseen käytetyissä miehittämättömissä ilma-aluksissa, kartoittaa kuvafuusion hyödyntämiseen liittyviä haasteita sekä tarkastella eri anturiyhdistelmien ja fuusiometodien soveltuvuutta kyseiseen käyttötarkoitukseen. Tutkielma on toteutettu kirjallisuuskatsauksena.

Kuvafuusiota ei tällä hetkellä varsinaisesti hyödynnetä käytännössä etsintätoimessa, vaikka tutkimustulokset ovat osoittaneet, että sillä voidaan tehostaa miehittämättömien ilma-aluksien suorituskykyä. Kuvafuusion käyttöä etsinnöissä on tutkittu jonkun verran teoreettisesti, mutta käytännön sovelluksia on vain vähän. Tutkielmassa tarkastellaan kuvafuusiota yleisesti sekä eri kuvafuusiometodeja, jotka voidaan karkeasti jakaa perinteisiin metodeihin ja uudempiin syväoppimispohjaisiin fuusiomenetelmiin. Sopivan fuusiometodin valintaan vaikuttavat miehittämättömän ilma-aluksen ominaisuudet, kuten rajallinen laskentateho, hyötykuorman kantokyky ja virtalähteen kapasiteetti. Kuvafuusiota hankaloittavat myös kohina ja vääristymät, jotka johtuvat sääolosuhteista, vaihtelevista kuvakulmista sekä järjestelmän liikkeestä ja värinästä.

Tutkielman analyysin mukaan syväoppimispohjaiset fuusiometodit ovat suuremaksi osaksi korvanneet perinteiset metodit ja tarjoavat perinteisiin metodeihin verrattuna useita etuja, kuten paremman laskentatehokkuuden ja kyvyn tunnistaa pitkän matkan riippuvuuksia. Myös hyvin suunnitellulla perinteisellä fuusiometodilla voidaan kuitenkin saavuttaa hyviä tuloksia. Analyysin perusteella syväoppimispohjaisista fuusiometodeista erityisen hyvin suoriutui SeAFusion ja DenseFuse. Myös perinteinen fuusiomenetelmä MST-SR saavutti hyviä tuloksia. Fuusiometodien vertailussa ei kuitenkaan käytetty miehittämättömän ilma-aluksen ottamia ilmakuvia maasto-olosuhteissa, joten fuusiometodien todellista suorituskykyä käytännön sovelluksissa on vaikea arvioida.

AVAINSANAT: miehittämättömät ilma-alukset, ilmakuvaus, pelastuspalvelu, anturit, kuvafuusio

Sisällys

1	Johdanto	7
1.1	Tutkimuskysymykset ja tavoitteet	8
1.2	Tutkimusmenetelmät ja tutkimuksen rakenne	9
2	Etsintätehtävät maasto-olosuhteissa	10
2.1	Maasto-olosuhteiden erityispiirteet ja haasteet	10
2.2	UAS-järjestelmien nykytilanne	11
3	Optiset anturit	15
3.1	RGB-kamera	15
3.2	Lämpökamera	16
3.3	Multispektrikamera	18
3.4	LiDAR	19
3.5	Antureiden vertailu	21
4	Monisensorinen kuvafuusio	23
4.1	Monisensorisen kuvafuusion perusteet	23
4.2	Anturiyhdistelmät	26
4.3	Perinteiset fuusiometodit	28
4.3.1	Multi-scale transformation -pohjainen fuusio	29
4.3.2	Sparse representation -pohjainen fuusio	30
4.3.3	Esimerkki perinteisestä fuusiosta	31
4.4	Syväoppimispohjaiset fuusiometodit	32
4.4.1	Autoenkooderi	33
4.4.2	Konvoluutioneuroverkot	34
4.4.3	Generatiiviset kilpailevat verkostot	35
4.4.4	Transformer-mallit	36
4.4.5	Muut	36
4.4.6	Syväoppimispohjaisten fuusiometodien vertailu	36
4.5	Perinteisten ja syväoppimispohjaisten fuusiometodien vertailu	39
5	Johtopäätökset	43

Kuvat

Kuva 1. RGB-, lämpö- ja multispektrikameran aallonpituusalueet ja esimerkkikuvat (Cruz Ulloa ja muut 2024, s. 2).	16
Kuva 2. Lämpökameralla otettu kuva lämmitetyistä mallinukeista puisessa ympäristössä (Yamamoto ja muut, 2024, s. 5).	18
Kuva 3. LiDAR-anturin tuottama kuva tiheäkasvuisessa ympäristössä (A) ihmisen maata maassa ja (B) ilman ihmistä (Nègre ja muut, 2025, s. 5).	20
Kuva 4. Lämpökameran, RGB-kameran ja multispektrikameran spektrialueiden vertailu eri parametrien perusteella (Cruz Ulloa ja muut, 2024, s. 15).	22
Kuva 5. Multi-scale transform -pohjainen kuvafuusio (Ma ja muut, 2023, s. 3).	30
Kuva 6. Esimerkki kuvafuusiosta perinteisellä menetelmällä (Golcarenen ja muut, 2022, s. 11).	32
Kuva 7. Autoenkooderiin pohjautuvien fuusiometodien toimintaperiaate (Zhang & Demiris, 2023, s. 10541).	34
Kuva 8. Syväoppimispohjaisten fuusiometodien vertailu (Li ja muut, 2025, s. 20).	37
Kuva 9. Perinteisten ja syväoppimispohjaisten fuusiometodien vertailu (Ma ja muut, 2023, s. 16).	40
Kuva 10. Perinteisten ja syväoppimispohjaisten fuusiometodien suorituskyky eri mittareilla 361 kuvaparin perusteella (Ma ja muut, 2023, s. 18).	41

Taulukot

Taulukko 1. UAS-järjestelmätyyppien ominaisuudet (mukaillen Quero & Martinez-Carranza, 2025, s. 5).	13
Taulukko 2. Antureiden vertailu (mukaillen Mohsan ja muut, 2023, s. 115).	21
Taulukko 3. Syväoppimispohjaisten fuusiometodien suorituskyky eri mittareilla 221 kuvaparin perusteella (mukaillen Li ja muut, 2025, s. 21).	38

Lyhenteet

AE	Autoencoder, autoenkooderi
CNN	Convolutional Neural Network, konvoluutioneuroverkko
EN	Entropy
GAN	Generative Adversarial Network, generatiivinen kilpaileva verkosto
GPS	Global Positioning System, maailmanlaajuinen paikallistamisjärjestelmä
IMU	Inertial Measurement Unit, inertiamittausyksikkö
LiDAR	Light Detection and Ranging, valotutka
MI	Mutual Information, keskenäinen tieto
Qabf	Reunainformaatioon perustuva kuvafuusion laatuindeksi
RGB	Red, Green, Blue; punainen, vihreä, sininen
SCD	Sum of Correlation Differences
SD	Standard Deviation, keskihajonta
SF	Spatial frequency, spatiaalinen taajuus
SLR-kamera	Single-lens Reflex camera, yksisilmäinen peiliheijastuskamera
UAS	Unmanned Aircraft System, miehittämätön ilma-alusjärjestelmä
VIF	Visual Information Fidelity

1 Johdanto

UAS-järjestelmien (engl. unmanned aircraft system, miehittämätön ilma-alusjärjestelmä) teknologian kehityksen myötä järjestelmien käyttöalue on laajentunut yhä entisestään. Tänä päivänä UAS-järjestelmiä hyödynnetään muun muassa metsätaloudessa, maanviljelyssä, rakennusalla, kaukokartoituksessa ja pelastustoimissa. UAS-järjestelmät ovat löytäneet paikkansa myös etsintäoperaatioissa, joissa niitä käytetään menestyksekkäästi ympäri maailmaa. Syyt, joiden takia ihmisiä joudutaan etsimään maastosta, liittyvät usein eksymiseen, muistisairauden aiheuttamiin vaikeuksiin hahmoitta ympäristöä tai loukkaantumiseen. Maastoetsinnöissä tavoitteena on löytää ja paikantaa etsitty henkilö mahdollisimman nopeasti ja tarkasti maastosta.

Vuonna 2018 skotlantilainen vuorikiipeilijä joutui hengenvaaralliseen tilanteeseen pudottuaan jyrkän jäärinteen reunalle (McKenzie, 2018). Vuorikiipeilijän luultiin menehtyneen, kunnes kaksi puolalaista vuorikiipeilijää ja elokuvaajaa paikansivat pudonneen vuorikiipeilijän ja havaitsivat elonmerkkejä käyttämällä videokuvaukseen tarkoitettua UAS-järjestelmäänsä (McKenzie, 2018). UAS-järjestelmän ansiosta uhri onnistuttiin lopulta pelastamaan. Myös Suomen poliisi on onnistunut löytämään maastossa kadonneita henkilöitä UAS-järjestelmien avulla. Vuonna 2023 poliisi (2023a) uutisoi löytäneensä kadonneen miehen metsästä hyödyntäen UAS-järjestelmää. Uutisesta käy ilmi, että epäsuotuisista sääolosuhteista huolimatta ensimmäinen näköhavainto pahoin kylmettyneestä miehestä ja hänen lopullinen paikannuksensa onnistuttiin tekemään UAS-järjestelmällä. Suomen poliisi on käyttänyt toiminnassaan UAS-järjestelmiä vuodesta 2015 alkaen ja heidän mukaansa noin puolet UAS-järjestelmän avulla suoritetuista tehtävistä liittyi ihmisen etsimiseen (Poliisi, 2023b).

Lyun ja muiden (2023) mukaan UAS-järjestelmien käyttöönotto etsintätoiminnassa on osoittautunut tehokkaaksi ja edistänyt operaatioiden sujuvuutta ja tuloksellisuutta merkittävästi. Heidän mukaansa UAS-järjestelmien käytöllä on useita etuja, kuten helppo käyttöönotto, laitteiden ketteryys ja alhaiset ylläpitokustannukset. Näiden lisäksi he mainitsevat myös, että UAS-järjestelmät helpottavat alueiden etsintää, joihin ihmisten

on vaikea päästä tai jotka aiheuttavat vaaran ihmisille. UAS-järjestelmien käytöllä on myös taloudellisia etuja, esimerkiksi korvatesa helikopterilennot. Myös tekoälyteknologian kehitys ja sen soveltaminen UAS-järjestelmissä etsinnöissä on osoittanut lupaavia tuloksia (Bany Abdelnabi & Rabadi, 2024, s. 152031).

UAS-järjestelmät käyttävät ihmisten havaitsemiseen antureita. Useimmiten käytetään kuvaavia antureita, joihin kuuluvat muun muassa RGB-kamera (engl. red, green, blue; punainen, vihreä, sininen), lämpökamera, multispektrikamera ja LiDAR (engl. light detection and ranging, valotutka). Ihmisen havaitsemiseen UAS-järjestelmällä maasto-olosuhteissa liittyy kuitenkin useita haasteita. Etsintäoperaatioita suoritetaan vaihtelevassa maastossa ja etsinnän aikana olosuhteet voivat muuttua milloin vain. Tehokkaan UAS-järjestelmän tulisi kuitenkin pystyä ylläpitämään toimintakykynsä ja tuloksellisuutensa ympäristömuutoksista riippumatta. Myös ihmisen pieni koko, monimutkainen tausta ja ylhäältä kuvattu näkymä vaikeuttavat ihmisen havaitsemista kuvista (Dumenčić ja muut, 2025, s. 4). Eri antureiden suorituskyky vaihtelee ympäristö- ja sääolosuhteiden mukaan, jolloin toiset anturit voivat tuottaa tietyissä tilanteissa parempia tuloksia (Ozcan & Cetin, 2022, s. 66831). Integroimalla järjestelmään useampi erilainen anturi ja yhdistämällä näiden keräämä data, voidaan hahmoittaa ympäristöä tarkemmin ja kokonaisvaltaisemmin, ja siten saada luotettavampia tuloksia (Ozcan & Cetin, 2022, s. 66831). Antureiden keräämän datan yhdistäminen voidaan toteuttaa kuvafuusiolla.

1.1 Tutkimuskysymykset ja tavoitteet

Tutkielman tavoitteena on tutkia, miten UAS-järjestelmiä käytetään maastoetsinnöissä, ja analysoida eri antureiden soveltuvuutta tähän tehtävään. Lisäksi tavoitteena on tarkastella eri anturiyhdistelmiä ja kuvafuusiometodeja sekä analysoida niiden soveltuvuutta UAS-järjestelmillä toteutettuihin maastoetsintöihin. Tutkielma pyrkii myös tunnistamaan mahdollisia tutkimusaukkoja.

Tutkimuksessa pyritään vastaamaan seuraaviin tutkimuskysymyksiin:

1. Miten kuvafuusiota hyödynnetään UAS-järjestelmissä, joita käytetään maastoetsinnöissä?
2. Mitkä anturiyhdistelmät ja kuvafuusioteknologiat soveltuvat parhaiten parantamaan ihmisten havaitsemista maasto-olosuhteissa?
3. Mitä haasteita kuvafuusion käyttöön UAS-järjestelmissä liittyy?

1.2 Tutkimusmenetelmät ja tutkimuksen rakenne

Tutkimus toteutetaan kirjallisuuskatsauksena, jossa analysoidaan aihetta käsitteleviä tieteellisiä julkaisuja ja tehdään johtopäätöksiä niiden perusteella. Lähdemateriaali on peräisin useista tieteellisistä tietokannoista, kuten IEEE Xplore, ScienceDirect ja Springer Nature Link. Tutkielmassa pyritään hyödyntämään mahdollisimman uusia ja ajantasaisia lähteitä. Suurin osa käytetyistä lähteistä on julkaistu vuosina 2021–2025.

Tutkielman ensimmäinen luku johdattaa tutkimuksen aiheeseen ja käsittelee tutkimuksen tarkoitusta ja toteutusta. Toinen luku käsittelee etsintätoimintaa maasto-olosuhteissa, kuten maasto-olosuhteiden erityispiirteitä ja haasteita sekä miehittämättömien ilma-alusjärjestelmien roolia. Kolmannes luku käsittelee erilaisia antureita, joita voidaan käyttää ihmisten havaitsemiseen. Luvussa kuvataan antureiden toimintatapaa ja ominaisuuksia sekä analysoidaan niiden soveltuvuutta ihmisen havainnointiin maastossa. Neljännessä luvussa keskitytään monisensoriseen kuvafuusioon. Monisensorisen kuvafuusion periaatteiden lisäksi luvussa tarkastellaan mahdollisia anturiyhdistelmiä ja ihmisten havaitsemista edistäviä fuusiometodeja. Viimeinen luku käsittelee tutkielman tuloksia ja johtopäätöksiä.

2 Etsintätehtävät maasto-olosuhteissa

Maastoetsinnät keskittyvät eksyneiden, kadonneiden ja loukkaantuneiden ihmisten löytämiseen maastosta (Bany Abdelnabi & Rabadi, 2024, s. 152015). Maastoalueiksi luokitellaan muun muassa metsät, tunturit, vuoristot, aavikot ja muut syrjäiset alueet. Perinteisesti etsintöihin osallistuu henkilökuntaa, etsijäkoiria sekä erilaisia ajoneuvoja, kuten veneitä ja helikoptereita (Bany Abdelnabi & Rabadi, 2024, s. 152009). Nopea reagointi ja ajanhallinta ovat etsintäoperaatioissa erityisen tärkeitä, sillä ne vaikuttavat suoraan etsinnän onnistumistodennäköisyyteen ja etsityn henkilön selviytymismahdollisuuksiin.

2.1 Maasto-olosuhteiden erityispiirteet ja haasteet

Maastoetsintöihin liittyy useita erikoispiirteitä ja haasteita. Etsintöjä maastossa hankaloittavat muun muassa haastavat kulkuolosuhteet, laajat etsintäalueet sekä vaikea navigointi alueella (Bany Abdelnabi & Rabadi, 2024, s. 152015). Liikkuminen tiheässä metsikössä, suoalueella tai syvässä lumessa hidastaa etsijöiden etenemistä. Erityisen hankalassa tai vaarallisessa maastossa liikkuminen voi jopa olla mahdotonta. Vaikka etsintäalueita voidaan usein rajata taustatietojen tai matkapuhelinpaikannuksen perusteella, jäävät ne siitä huolimatta monesti laajoiksi. Edellä mainittuja ongelmia voidaan minimoida hyvin hyödyntämällä UAS-järjestelmiä.

Maasto-olosuhteisiin liittyy myös haasteita, jotka tuottavat vaikeuksia UAS-järjestelmille. Tilanteet, joissa ihmistä etsitään peitteisestä maastosta, ovat erityisen vaikeita. Metsäisillä alueilla haasteita aiheuttavat puiden peitteisyys, joka vähentää näkyvyyttä, ja puiden lämpösäteily, joka auringonvalossa voi vastata ihmisen kehonlämpötilaa ja siten väärentää lämpökameran tuloksia (Ramírez-Ayala ja muut, 2023, s. 1). Maaston ja puuston korkeusprofiilin vuoksi UAS-järjestelmä voi joutua lentämään normaalia korkeammalla, mikä vaikuttaa saatujen kuvien resoluutioon. Ihmisen havaitsemista vaikeuttaa myös ihmisen ja taustan välinen matala kontrasti ja lämpöjälkien visuaaliset

erot, jotka voivat johtua esimerkiksi sääolosuhteista, ympäristön lämpölähteistä, peitteestä tai valon aiheuttamasta kohinasta (Ramírez-Ayala ja muut, 2023, s. 3). Lisäksi UAS-järjestelmän täytyy pystyä erottamaan muiden eläimien lämpöjäljet ihmisen lämpöjäljestä, jotta vääriä tuloksia ei synny. Etsintäoperaatioissa täytyy myös huomioida mahdollisuus, että etsitty henkilö on menehtynyt.

Sääolosuhteet maastossa vaihtelevat. Kovat tuulet, rankka sade ja ääriämpötilat vaikuttavat UAS-järjestelmän suorituskykyyn ja lentovakauteen (Lyu ja muut, 2023, s. 2). Mohsanin ja muiden (2023, s. 128) mukaan sääolosuhteet vaikuttavat myös UAS-järjestelmän toiminta-aikaan, lentokorkeuteen, lentosuuntaan ja reittiin. He mainitsevat myös, että hankalat sääolosuhteet voivat estää UAS-järjestelmän leijumisen paikallaan. Nämä kaikki vaikuttavat negatiivisesti myös järjestelmän antureiden toimintaan ja siten saadun tiedon laatuun. Etsinnän ajankohdan ja sääolosuhteiden mukaan myös valolosuhteet voivat olla hyvinkin erilaisia eri etsintäkerroilla.

Jotta UAS-järjestelmä soveltuu maastoetsintäoperaatioihin, sen on täytettävä tiukat kriteerit. Queron ja Martinez-Carranzan (2025, s. 3) mukaan UAS-järjestelmän täytyy toimia luotettavasti vaativissa olosuhteissa ja kestää epäsuotuisia sääolosuhteita. Lisäksi he mainitsevat, että järjestelmän on kyettävä pitkäkestoisiin ja vakaisiin lentosuorituksiin sekä tarkkaan paikannukseen ja navigointiin. Olennaisin haaste on ihmisen luotettava ja tarkka tunnistaminen sekä selkeitä kohinattomista kuvista että epäselkeistä kohinallista kuvista riippumatta ympäristö- ja sääolosuhteista (Ramírez-Ayala ja muut, 2023, s. 3).

2.2 UAS-järjestelmien nykytilanne

UAS-järjestelmiä alettiin hyödyntämään etsintätoiminnassa 2000-luvun keskivälissä, ja vuosikymmenen loppupuolella niihin alettiin soveltaa konenäköalgoritmeja (Bany Abdelnabi & Rabadi, 2024, s. 152014). Kirjallisuudessa UAS-järjestelmien käyttöä maastoetsinnöissä on tutkittu jonkin verran, mutta suurimmassa osassa artikkeleista järjestelmiä on tarkasteltu vain teoreettisesti eikä niitä ole toteutettu käytännössä (Bany

Abdelnabi & Rabadi, 2024, s. 152015). UAS-järjestelmien hyödyntämisestä etsinnöissä ja pelastustoimessa on olemassa kokoavia artikkeleita, kuten Bany Abdelnabi ja Rabadi (2024) sekä Quero ja Martinez-Carranza (2025). Henkilöetsinnöissä UAS-järjestelmiä voidaan käyttää ensisijaisena menetelmänä, jolloin pyritään löytämään etsitty henkilö järjestelmän tuottaman datan avulla, tai avustavana menetelmänä perinteisten etsintätapojen ohella, jolloin järjestelmää käytetään esimerkiksi etsintäalueen kartoittamiseen tai etsijöille vaarallisten alueiden tutkimiseen.

Suomen poliisi (2023b) on käyttänyt toiminnassaan UAS-järjestelmiä vuodesta 2015 alkaen ja heidän mukaansa noin puolet UAS-järjestelmän avulla suoritetuista tehtävistä liittyy ihmisen etsimiseen. Poliisi (n.d.) on Suomen suurin miehittämättömän ilmailun toimijaorganisaatio ja heillä on käytössään yli 330 UAS-järjestelmää. Hyödyntämällä UAS-järjestelmiä toiminnassaan he ovat tukeneet ja korvanneet ihmisen tekemää työtä. Lisäksi he ovat säästäneet rahaa ja aikaa sekä parantaneet työturvallisuutta (Poliisi, 2023b). UAS-järjestelmät, joita Suomen poliisi käyttää henkilöetsinnöissä, ovat sekä kaupallisia että ei-kaupallisia (Poliisi, 2023b). He käyttävät järjestelmiä, joissa on hyvälaatuiset kamerat ja joihin on mahdollista kiinnittää lisäksi myös lämpökamera (Poliisi, n.d.). Ikosen ja Rytkösen (2023, s. 16) mukaan pelastustoimen ja muiden suomalaisten viranomaisten käyttämät UAS-järjestelmät ovat kaikki samankaltaisia, mutta mallit voivat vaihdella. He mainitsevat, että yleisin käytetty järjestelmien valmistaja on DJI ja toiseksi yleisin Autel.

UAS-järjestelmät voidaan jakaa kiinteäsiipisiin, moniroottoriin, yksiroottoriin ja hybridimalleihin (Quero ja Martinez-Carranza, 2025, s. 3). Etsintä- ja pelastustoimessa käytettyjen erityyppisten UAS-järjestelmien ominaisuudet on esitetty taulukossa 1. Suurin osa kaupallisista myynnissä olevista UAS-järjestelmistä, joita suositellaan etsintäoperaatioihin, on varusteltu laajakulmakameroilla, telekameroilla, laseretäisyysmittareilla ja infrapunakameroilla. Osaan myydään myös kiinnitettävä LiDAR-anturi. Järjestelmät on suunniteltu kestämään rankkoja sääolosuhteita ja lentämään pidempiä matkoja. UAS-järjestelmien tuottamaa tilannekuvaa pystytään

usein seuraamaan reaaliaikaisesti ja eri kameranäkymien välillä voidaan vaihdella. Nykyään monissa järjestelmissä sovelletaan tekoäly- ja syväoppimiskäytäntöjä, esimerkiksi esineiden tunnistamiseen tai lentoreitin suunnitteluun. Bany Abdelnabin ja Rabadin (2024) mukaan UAS-järjestelmän tuottaman tiedon läpikäyminen tapahtuu siitä huolimatta vielä usein manuaalisesti ihmisen toimesta.

Taulukko 1. UAS-järjestelmätyyppien ominaisuudet (mukaillen Quero & Martinez-Carranza, 2025, s. 5).

Ominaisuus	Yksiroottorinen	Kiinteäsiipinen	Moniroottorinen	Hybridi
Hyötykuorma	< 2 kg	0,1–1 kg	1–50 kg	> 5 kg
Massa	Pienet 1–5 kg, keskikokoiset 5–50 kg, isot sotilaalliset järjestelmät 50–500 kg	Pienet 0,5–5 kg, keskikokoiset 5–100 kg, isot sotilaalliset järjestelmät 100–2000 kg tai yli	Pienet 0,2–5 kg, keskikokoiset 5–50 kg, isot 50–500 kg tai yli	> 10 kg riippuen käyttötarkoituksesta
Nopeus	Korkein etenemisnopeus yleensä 57–173 mph (\approx 92–278 km/h)	Pienet 23–46 mph (\approx 37–74 km/h), edistyneemmät mallit jopa 173 mph (\approx 278 km/h)	Tyypillisesti etenemisnopeus 17–57 mph (\approx 27–92 km/h)	Riippuen mallista 46–115 mph (\approx 74–185 km/h)
Lentokorkeus	Sotilaalliset mallit jopa yli 10000 ft (\approx 3048 m) korkeudessa, siviili mallit alle 2000 ft (\approx 610 m) korkeudessa	Muutaman sadan jalan (\approx 60 m) ja yli 30000 ft (\approx 9144 m) välillä	Suurin osa kuluttajamalleista muutaman sadan jalan (\approx 60 m) ja noin 3000 jalan (\approx 914 m) korkeudella	Yhdistää kiinteäsiipisten mallien lentokorkeuden multiroottorien kyvyllä lähteä lentoon ja

Ominaisuus	Yksiroottorinen	Kiinteäsiipinen	Moniroottorinen	Hybridi
				laskeutua vertikaalisti
Toiminta- säde	2–100 km, riippuen mallista ja hyötykuormasta	Pienet 50–150 km, isommat jopa satoja tai tuhansia kilometrejä	Parista kilometristä noin 20–30 km asti, riippuen mallista ja akun kapasiteetista	Vaihtelee suuresti 50 km ja 150 km välillä
Lentoaika	1–6 h	Pienet 2–5 h, suuremmat yli 10 h	Yleensä 15–45 min	1–5 h tai enemmän

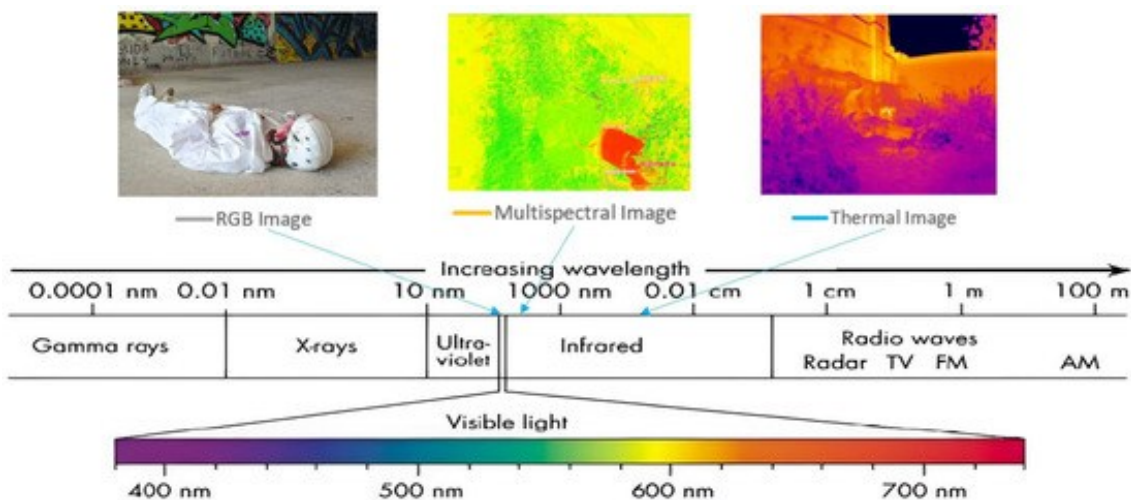
3 Optiset anturit

Tässä luvussa tarkastellaan erilaisia antureita, joita voidaan käyttää UAS-järjestelmissä ihmisten havaitsemiseen. Tarkasteltavaksi on valittu antureita, jotka tuottavat visuaalista dataa ja joiden dataa on mahdollista fuusoida kuvafuusiolla. Lisäksi antureiden valintaan vaikutti tutkimusaineiston saatavuus. Lopulta valinta päättyi RGB-kameraan, lämpökameraan, multispektrikameraan ja LiDAR-anturiin. Valituista antureista RGB- ja lämpökamera ovat yleisimmin käytettyjä antureita UAS-järjestelmissä (Golcarenarenji ja muut, 2022, s. 1).

3.1 RGB-kamera

RGB-kamera ottaa kuvia näkyvän valon aallonpituuksilla, jotka sijoittuvat välille 400–700 nm (Cruz Ulloa ja muut, 2024, s. 2). Kuvassa 1 näkyy miten RGB-kameran käyttämät aallonpituudet sijoittuvat spektrille ja miltä RGB-kameran ottama kuva näyttää. RGB-kameralla otettu kuvaa vastaa suurin piirtein ihmisen silmän tuottamaa kuvaa. Etsintä- ja pelastusrobotiikassa suurin osa järjestelmän käyttämästä datasta on RGB-kameran tuottamaa (Cruz Ulloa ja muut, 2024, s. 2).

Mohsanin ja muiden (2023, s. 109) mukaan RGB-kameroiden etuja ovat, että ne ovat hankinnassa edullisia, painoltaan kevyitä ja niissä on korkea spatiaalinen resoluutio. Joissain sääolosuhteissa RGB-kamera voi suoriutua heikosti, kuten esimerkiksi rankassa sateessa tai sumussa (Bany Abdelnabi & Rabadi, 2024, s. 152030). Cruz Ulloan ja muiden (2024, s. 15–18) mukaan RGB-kamera suoriutuu heikosti huonossa valaistuksessa, etsityn henkilön ollessa peitettynä sekä etsityn henkilön ja taustan välisen kontrastin ollessa matala. Heidän mukaansa RGB-kamerat kuitenkin toimivat hyvin kesäisissä olosuhteissa eivätkä häiriinny lämpölähteistä. Lisäksi RGB-kamerat käsittelevät dataa nopeasti (Cruz Ulloa ja muut, 2024, s. 17).



Kuva 1. RGB-, lämpö- ja multispektrikameran aallonpituusalueet ja esimerkkikuvat (Cruz Ulloa ja muut 2024, s. 2).

Zhangin ja Zhun (2023, s. 5) mukaan UAS-järjestelmissä yleisimmin käytetyt RGB-kamerat voidaan jakaa kahteen eri ryhmään. Ensimmäiseen ryhmään he luokittelevat integroidut RGB-kamerat ja toiseen erikseen kiinnitettävät yksisilmäiset peiliheijastuskamerat (engl. single-lens reflex camera, SLR-kamera). Heidän mukaansa integroidut RGB-kamerat pystyvät ottamaan korkearesoluutioisia kuvia korkealla kuvataajuudella, ovat kompakteja, ja soveltuvat pitkäkestoiseen käyttöön. Integroitujen RGB-kameroiden huono puoli on, että alkuperäistä objektiivia ei voida vaihtaa, toisin kuin SLR-kameroissa, joihin voidaan käyttötarkoituksen mukaan vaihtaa sopiva objektiivi (Zhang & Zhu, 2023, s. 5). SLR-kamerat ovat painavampia kuin integroidut kamerat ja niiden kiinnityksen takia ne eivät sovellu kaikkiin UAS-järjestelmiin (Zhang & Zhu, 2023, s. 5). Sopivimman RGB-kameran valitsemiseen vaikuttaa eri parametrit, kuten kameras objektiivi, resoluutio ja yhteensoveltuvuus UAS-järjestelmän kanssa (Yao ja muut, 2019, s. 4).


3.2 Lämpökamera

Lämpökameran käyttöä etsintäoperaatioissa on tutkittu laajasti. Lämpökameroiden hyödyntämisestä pelastus- ja etsintäoperaatioissa on julkaistu vuosina 2000–2022

huomattavasti enemmän tutkimuksia kuin RGB-kameran tai multispektrikameran hyödyntämisestä (Cruz Ulloa ja muut, 2024, s. 3). Lämpökamera käyttää pääasiassa infrapuna-aallonpituuksia, jotka sijoittuvat alueelle 8–14 μm (Cruz Ulloa ja muut, 2024, s. 2). Kuvassa 1 näkyy esimerkki lämpökameran ottamasta kuvasta ja spektrialue, jota lämpökamera hyödyntää. Lämpökamera havaitsee kohteiden lähettämän infrapunasäteilyn ja pystyy sen perusteella havainnollistamaan kohteiden välisiä lämpötilaeroja (Zhang & Zhu, 2023, s. 5). Ihminen voidaan erottaa ympäristöstä lämpökameran avulla, kun ihmisen ja ympäristön lämpötila eroaa toisistaan. Lämpökameran havaintoetäisyys on kuitenkin rajallinen (Quero & Martinez-Carranza, 2025, s. 12). Valitessa lämpökameraa UAS-järjestelmään täytyy huomioida järjestelmän lentokorkeus ja lämpökameralta vaadittu havaintoetäisyys.

Cruz Ulloan ja muiden (2024, s. 15–17) mukaan lämpökamera suoriutuu hyvin tilanteissa, joissa on huonot tai vaihtelevat valo-olosuhteet, kuten esimerkiksi yöllä. Lisäksi he mainitsevat, että lämpökamera toimii myös hyvin silloin, kun etsitty henkilö on osittain peitettynä tai kun etsitty henkilö erottuu vaikeasti maastosta silmin. Leen ja muiden (2016) mukaan etsityn henkilön vaatetuksella on vaikutus lämpökameran havaitsemaan lämpöjälkeen, sillä vaatteet alentavat mitattua pintalämpötilaa ja siten vaikeuttavat ihmisen erottamista ympäristöstä. Lämpökameralle vaikeuksia tuottavat myös ympäristön lämpölähteet ja kuuma sää (Cruz Ulloa ja muut, 2024, s. 15).

Lämpökamera voi auttaa löytämään ihmisen, joka on kasvillisuuden peittämänä (Dumenčić ja muut, 2025, s. 24). Puiden lähettämä lämpösäteily voi kuitenkin myös häiritä lämpökameran toimintaa ja vaikeuttaa ihmisen havaitsemista (Ramírez-Ayala ja muut, 2023, s. 1). Yamamoto ja muut (2024, s. 5) kuvasivat lämmitettyjä mallinukkeja UAS-järjestelmän lämpökameralla 30 metrin korkeudesta puisessa ympäristössä. Tutkimuksessaan he ottivat kuvan 2, josta näkyy miten puiden lämpösäteily vaikuttaa ihmisen havaittavuuteen puisella alueella.



Kuva 2. Lämpökameralla otettu kuva lämmitetyistä mallinukeista puisessa ympäristössä (Yamamoto ja muut, 2024, s. 5).

3.3 Multispektrikamera

Multispektrikameran hyödyntämistä uhrien tunnistamiseen henkilöetsinnöissä on Cruz Ulloan ja muiden (2024, s. 1–3) mukaan tutkittu vasta vähän ja esimerkiksi paljon vähemmän kuin RGB-kameran ja lämpökameran hyödyntämistä. Heidän mukaansa viimeaikaiset tutkimukset ovat kuitenkin osoittaneet, että multispektrikameroita voidaan hyödyntää myös etsintä- ja pelastusrobotiikassa. He huomauttavat, että multispektrikameran käyttöä maanviljelyyn liittyvässä robotiikassa on tutkittu laajasti ja että tätä tutkimusta voidaan hyödyntää kehittäessä menetelmiä uhrien havaitsemiseen multispektrikameralla.

Multispektrikamera käyttää yleensä näkyvän valon aallonpituuksia, lähialueen infrapunaa, joka aallonpituudet sijoittuvat välille 690–730 nm, ja lyhytaaltoinfrapunaa, jonka aallonpituudet ovat 750 nm – 2,5 μm (Cruz Ulloa ja muut, 2024, s. 2). Kuva 1 havainnollistaa mille spektrialueelle multispektrikameran käyttämät aallonpituudet sijoittuvat. Lisäksi kuvassa 1 on esimerkki multispektrikameran ottamasta kuvasta.


Multispektrikamera sopii monenlaisiin tehtäviin, sillä sen käyttämiä aallonpituuskaistoja voidaan vaihtaa tarpeen mukaan (Cruz Ulloa ja muut, 2024, s. 18). Käytetyt kaistat valitaan sen mukaan, miten ihminen erottuu parhaiten taustaympäristöstään (Qi ja muut, 2022, s. 4). Nexin ja muiden (2022, s. 219–222) mukaan multispektrikamerassa on yleensä 3–10 eri kaistaa. He huomauttavat, että jos kaistoja on enemmän myös dataa tuotetaan enemmän, jolloin tarvitaan enemmän laskentatehoa.

Cruz Ulloan ja muiden (2024, s. 15–18) mukaan multispektrikamera suoriutuu hyvin vaihtuvissa valo-olosuhteissa sekä kesäisellä säällä, mutta ei pimeässä. He toteavat myös, että multispektrikamera ei auta kokonaan peitetyjen ihmisten löytämisessä, mutta onnistuu löytämään osittain peitetyt tai vaatetuksen takia ympäristöön sulautuvat ihmiset paremmin kuin RGB-kamera. Nègren ja muiden (2025, s. 8) mukaan multispektrikameran uskotaan myös auttavan menehtyneiden ihmisten ruumiiden löytämisessä, sillä multispektrikamera pystyy havaitsemaan muutoksia kasvillisuudessa, jotka taas johtuvat ruumiin maatuessa vapautuvista mineraaleista ja muista kemiallisista yhdisteistä. He kuitenkin huomauttavat, että aihetta ei ole tutkittu vielä tarpeeksi, jotta sitä voitaisiin hyödyntää luotettavasti oikeissa tapauksissa.

3.4 LiDAR

LiDAR (engl. Light Detection and Ranging, valotutka) mittaa kohteiden etäisyyksiä lähettämällä laserpulsseja ja mittaamalla ajan, joka kuluu pulssin heijastumiseen takaisin (Zhang & Zhu, 2023, s. 8). Tämä mahdollistaa todella tarkan ja yksityiskohtaisen kolmiulotteisen kuvan luomisen (Zhang & Zhu, 2023, s. 8). Myös Queron ja Martinez-Carranzan (2025, s. 8) mukaan LiDAR-anturit pystyvät keräämään geometristä dataa erittäin tarkasti. He kuitenkin huomauttavat, että GPS:n (engl. global positioning system, maailmanlaajuinen paikallistamisjärjestelmä) ja IMU:n (engl. inertial measurement unit, inertiamittaussyksikkö) epätarkkuudet voivat vaikuttaa negatiivisesti LiDAR-anturin tuottaman datan laatuun. Verrattuna muihin aikaisemmin mainittuihin antureihin LiDAR on kallis ja painava (Mohsan ja muut, 2023, s. 115).

LiDAR-anturia voidaan käyttää silloin, kun maanpinta on kasvillisuuden peitossa (Zhang & Zhu, 2023, s. 8). Kasvillisuuden peittämässä ympäristössä LiDAR-anturin lähettämä laserpulssi voi heijastua takaisin useita kertoja osuessaan kasvillisuuden eri kerroksiin (Zhang & Zhu, 2023, s. 8). Näin saadaan tietoa myös siitä, mitä lehtipeitteen alla tapahtuu. Nègren ja muiden (2025) tutkimus osoitti, että UAS-järjestelmään liitetyllä LiDAR-anturilla on mahdollista havaita ihmisen kehon tunnusmerkkejä tiheäkasvuisilla alueilla. Tutkimuksessa verrattiin kahden eri LiDAR-anturin kykyä tunnistaa maassa makaava ihminen. Käytetyt anturit olivat Zenmuse L1 ja Zenmuse L2, jotka ovat molemmat merkiltä DJI. Anturien merkittävin ero on paluukaikujen lukumäärä. Zenmuse L1 tukee kolmea paluukaikua per pulssi ja Zenmuse L2 viittä. Tutkimuksesta käy ilmi, että hitaampi lentonopeus ja suurempi paluukaikujen lukumäärä vaikuttavat positiivisesti ihmisen havaitsemiseen. Tutkimuksessaan he tuottivat kuvan 2, joka perustuu Zenmuse L2 LiDAR-anturin tuottamaan dataan. Kuvan A ja B puolella näkyy sama alue, mutta vain A puolella kuvassa on ihminen. Tutkimuksen tekijät lisäävät, että LiDAR-anturin käyttöä ihmisten havaitsemiseen tulisi tutkia lisää, jotta tekniikkaa voidaan hyödyntää mahdollisimman tehokkaasti.



Kuva 3. LiDAR-anturin tuottama kuva tiheäkasvuisessa ympäristössä (A) ihmisen maassa maassa ja (B) ilman ihmistä (Nègre ja muut, 2025, s. 5).

3.5 Antureiden vertailu

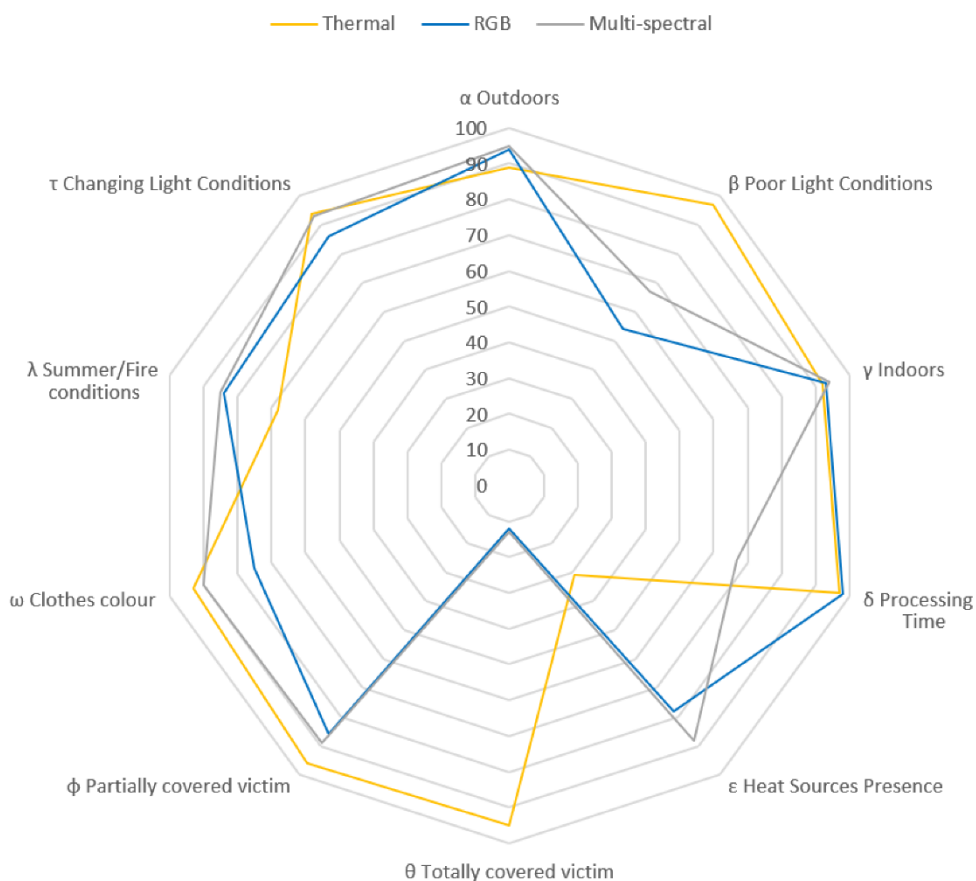
Luvuissa 3.1–3.4 tarkasteltiin valittujen antureiden vahvuuksia ja heikkouksia sekä niiden soveltuvuutta etsintäoperaatioihin. Mohsan ja muut (2023) vertaavat tutkimuksessaan antureita eri ominaisuuksien näkökulmasta. Heidän tekemänsä vertailu näkyy taulukossa 2, josta on poistettu rivit, jotka käsittelevät antureita, joita ei tässä tutkielmassa tarkastella. Taulukossa verrataan antureita hinnan, painon, spektrisen resoluution ja spatiaalisen resoluution mukaan. Heidän vertailustansa käy ilmi, että RGB-kameran hinta ja paino ovat matalimmat ja LiDAR-anturin hinta ja paino korkeimmat. Multispektrikameran spektrinen resoluutio on korkein. Spatiaalinen resoluutio on matalin lämpökamerassa ja korkein RGB-kamerassa ja LiDAR-anturissa. Jos halutaan esimerkiksi parantaa lämpökameran ottaman kuvan spatiaalista resoluutiota, voidaan fuusoida se korkearesoluutioisen kameran, kuten RGB-kameran, ottamalla kuvalla.

Taulukko 2. Antureiden vertailu (mukaillen Mohsan ja muut, 2023, s. 115).

Anturi	Hinta	Paino	Spektrinen resoluutio	Spatiaalinen resoluutio
RGB-kamera	Matala	Matala	Matala	Todella korkea
Lämpökamera	Keskiverto	Keskiverto	Matala	Keskiverto
Multispektrikamera	Keskiverto	Keskiverto	Keskiverto	Korkea
LiDAR	Korkea	Korkea	Matala	Todella korkea

Cruz Ulloa ja muut (2024) vertailevat tutkimuksessaan RGB-kameran, lämpökameran ja multispektrikameran käyttämiä spektrialueita ja näiden suorituskykyä eri tilanteissa. Parametrit, joiden vaikutusta spektrialueiden suorituskykyyn verrattiin, ovat: α ulkotiloissa, β huono valaistus, γ sisätiloissa, δ käsittelyaika, ϵ lämpölähteitä ympäristössä, θ kokonaan peitetty uhri, ϕ osittain peitetty uhri, ω vaateiden väri, λ kesäiset sääolosuhteet ja τ vaihtuva valaistus. Tulokset ovat näkyvissä kuvan 4 sädekaaviossa. Eri spektrialueet pisteytettiin parametrien mukaan 0–100 pisteellä ja saadut arvot summattiin lopussa kokonaispistemääräksi. Korkeampi pistemäärä vastaa parempaa suorituskykyä. Vertailussa lämpökameran spektrialue suoriutui parhaiten 966

pisteellä. Myös lämpökameran todennäköisyys havaita uhri ulkotiloissa oli korkein (91,1 %). Toiseksi eniten pisteitä sai multispektrikameran spektrialue (839) ja vähiten näkyvän valon alue (744). Multispektrikameran spektrialueen todennäköisyys havaita uhri ulkotiloissa oli korkeampi (81,2 %) kuin näkyvän valon alueen (79,4 %).



Kuva 4. Lämpökameran, RGB-kameran ja multispektrikameran spektrialueiden vertailu eri parametrien perusteella (Cruz Ulloa ja muut, 2024, s. 15).

4 Monisensorinen kuvafuusio

Etsintäoperaatioissa UAS-järjestelmien täytyy pystyä toimimaan vaihtelevissa olosuhteissa. Järjestelmän toimintaa häiritsevät usein epäsuotuisat ympäristöolosuhteet, jotka vaikuttavat negatiivisesti antureiden tuottamaan dataan. Järjestelmät, joissa on käytössä vain yksi anturi, ovat erityisen riippuvia ympäristöolosuhteista ja eivät siksi aina toimi halutusti joka tilanteessa (Li ja muut, 2021, s. 2331). Fuusioimalla komplementaariset eli toisensa täydentävät anturit voidaan parantaa ihmisten havaitsemisen tarkkuutta, mikä puolestaan helpottaa ja tehostaa etsintäoperaatioita (Li ja muut, 2021, s. 2335).

4.1 Monisensorisen kuvafuusion perusteet

Kaur ja muut (2021, s. 4425) määrittelevät monisensorisen kuvafuusion prosessiksi, jossa kahden tai useamman eri anturin tuottama kuva yhdistetään yhdeksi kuvaksi, joka esittää tiedon koneelle ja ihmiselle helpommin tulkittavalla tavalla. Monisensorisessa kuvafuusiossa yhdistettävät kuvat ovat erilaisten antureiden tuottamia. Yhdistämällä erilaisten antureiden tuottamat kuvat, pystytään muodostamaan kokonaiskuva, joka hyödyntää kunkin anturin vahvuuksia ja kompensoi niiden heikkouksia (Li ja muut, 2017, s. 100).

Fuusiotekniikan valintaan vaikuttavat UAS-järjestelmän ominaisuudet, kuten rajallinen laskentateho. UAS-järjestelmien rajallinen kyky kantaa hyötykuormaa ja virtalähteen rajallinen kapasiteetti vaikeuttavat reaaliaikaisen prosessoinnin toteuttamista (Li ja muut, 2021, s. 2331). UAS-järjestelmissä käytetyillä laskenta-alustoilla täytyy olla suuri laskentateho, mutta samaan aikaan myös pieni paino (Li ja muut, 2021, s. 2331). UAS-järjestelmän ottamien kuvien fuusiointia hankaloittavat myös muutokset valaistuksessa, kuvakulman vääristymät ja ilmakehän vaikutukset (Li ja muut, 2025, s. 13). Bany Abdelnabin ja Rabadin (2024, s. 152027) mukaan fuusiotekniikan valintaan vaikuttaa myös prosessoidaanko kerätty tieto reaaliaikaisesti itse UAS-järjestelmässä vai

lähetetäänkö tieto pilvipalveluun tai erilliselle laitteelle käsiteltäväksi, jolloin laskentatehoa on saatavilla enemmän. Kuvafuusion merkittävämpiä ongelmia tällä hetkellä ovat tehokkuus ja suuri laskentateho, jota tiedon prosessointi vaatii (Ma ja muut, 2023, s. 11).

Kuvafuusion ensimmäinen askel on kuvan rekisteröinti (engl. image registration) (Kaur ja muut, 2020, s. 4425). Kuvien rekisteröinti tehdään, jotta fuusioitavissa kuvissa näkyvä alue on tarkalleen sama ja sama pikseli eri kuvissa viittaa samaan fyysiseen kohtaan (Li ja muut, 2021, s. 2332). Rekisteröinti on tarpeellista, koska kuvien resoluutio, näkökenttä tai kuvauskulma voivat erota toisistaan (Li ja muut, 2021, s. 2332). Rekisteröinnillä estetään vääristymien syntyminen fuusoidussa kuvassa (Golcarenen ja muut, 2022, s. 3).

Fuusiometodit voidaan jakaa pikseli-, piirre- ja päätöstason fuusioon (Li ja muut, 2017, s. 100). Pikselitason fuusiossa lähdekuvien tiedot yhdistetään suoraan, ilman että kuvia käsitellään sitä ennen (Kaur ja muut, 2021, s. 4425). Samadzadeganin ja muiden mukaan (2025, s. 1362) pikselitason fuusio yhdistää pikselidataa eri kuvista ja luo niistä uutta dataa. Heidän mukaansa fuusio edellyttää, että kuvat on otettu samaan aikaan, kuvilla on sama resoluutio ja kuvat rekisteröidään ennen fuusiota. Piirretason fuusio yhdistää eri sensoreiden dataa yhdistämällä eri lähteistä poimittuja piirteitä, jotka voivat olla esimerkiksi spektrisiä, tekstuurisia, spatiaalisia tai struktuurisia (Samadzadegan ja muut, 2025, s. 1362). Piirretason fuusiossa kuvia käsitellään siis ennen kuin ne yhdistetään (Samadzadegan ja muut, 2025, s. 1362). Piirretason fuusio ei aina tuota uutta dataa vaan ennemmin tehostaa olemassa olevaa dataa (Samadzadegan ja muut, 2025, s. 1362). Päätöstason fuusiossa useiden prosessointijärjestelmien tai luokittelijoiden lopulliset päätökset yhdistetään käyttämällä päätöspohjaisia sääntöjä, kuten päätöspuita tai luokittelijoiden fuusiota (Samadzadegan ja muut, 2025, s. 1362). Päätöstason fuusiossa kuvat käsitellään erikseen (Kaur ja muut, 2021, s. 4426). Tämä tarkoittaa sitä, että objektintunnistus suoritetaan molemmille kuville erikseen, minkä jälkeen molemmista kuvista saadut tulokset yhdistetään (Li ja muut, 2025, s. 2).

Pikselitason ja piirretason fuusiossa fuusioinnin jälkeen saatu fuusiokuva syötetään objektintunnistusalgoritmiin. Objektintunnistusalgoritmit ovat konenäköalgoritmeja, joiden päätehtävänä on paikantaa ja tunnistaa tiettyjen objektien sijainti ja kategoria (Zhang ja muut, 2025). Maastoetsinnöissä algoritmien tehtävänä on havaita ihmiset ja niiden sijainti maastosta. Tällä hetkellä objektintunnistukseen käytetyt syväoppimisalgoritmit jaetaan yksivaiheisiin ja kaksivaiheisiin algoritmeihin (Zhang ja muut, 2025). Kaksivaiheiset tunnistusalgoritmit vaativat enemmän laskentatehoa ja niitä on siksi vaikea hyödyntää reaaliaikaisissa järjestelmissä (Wang ja muut, 2025, s. 2). Suurin osa objektintunnistusalgoritmeista on suunniteltu käytettäväksi näkyvän valon kuvilla (Zhang ja muut, 2025). Objektintunnistusalgoritmit eivät aina suoriudu toivotusti, kun on kyse komplekseista ja yksityiskohtaisista ympäristöistä tai tehtävistä (Zhang ja muut, 2025). Multisensorisella ja multimodaalisella objektintunnistuksella voidaan parantaa objektintunnistuksen tarkkuutta ja parantaa mallin kykyä toimia luotettavasti eri tilanteissa (Zhang ja muut, 2025).

Li ja muiden (2017, s. 105) mukaan fuusoidussa kuvassa täytyy säilyä suurin osa alkuperäisten kuvien hyödyllisistä ja komplementaarista tiedoista. Heidän mukaansa fuusioalgoritmi ei myöskään saa tuottaa kuvavirheitä, jotka häiritsevät kuvan jatkoprosessointia, ja fuusioalgoritmin täytyy toimia myös epätäydellisissä olosuhteissa. Fuusioalgoritmien suorituskykyä voidaan verrata subjektiivisesti tai objektiivisesti (Kaur ja muut, 2021, s. 4440). Kaurin ja muiden (2021, s. 4440) mukaan subjektiivisessa arvioinnissa fuusoidun kuvan laatua arvioidaan ihmisen näön perusteella, kun taas objektiivisessa arvioinnissa fuusioalgoritmeja arvioidaan kvantitatiivisesti käyttämällä erilaisia arviointimittareita. Heidän mukaansa osa arviointimittareista käyttää referenssikuvaa, johon fuusioitua kuvaa verrataan, ja osa on referenssistä riippumattomia. Esimerkkejä arviointimittareista ovat keskimääräinen neliövirhe (engl. mean of the square error) ja rakenteellisen samakaltaisuuden indeksi (engl. structural similarity index metric) (Kaur ja muut, 2021, s. 4440).

Fuusiometodit voidaan karkeasti jakaa perinteisiin metodeihin ja uudempiin syväoppimiseen pohjautuviin metodeihin. Tämä luku priorisoi näkyvän valon kuvien ja infrapunakuvien fuusiointia syväoppimispohjaisilla metodeilla, koska sitä tutkitaan tällä hetkellä eniten ja siitä löytyy eniten lähteitä. Näkyvän valon kuvien ja infrapunakuvien fuusiointimeteodeista on olemassa useampia kokoavia artikkeleita. Osa artikkeleista keskittyy sekä perinteisiin että syväoppimispohjaisiin metodeihin, kuten Ma ja muut (2023) sekä Luo ja Luo (2023). Toiset taas keskittyvät ainoastaan syväoppimispohjaisiin metodeihin, kuten Zhang ja muut (2021), Zhang ja Demiris (2023), Yang ja muut (2024) sekä Li ja muut (2025). Näkyvän valon kuvien ja infrapunakuvien fuusio tehdään yleensä pikselitasolla (Zhang & Demiris, 2023, s. 10536). Tämän tutkielman käsittelemältä sovellusalalta on saatavilla vain todella rajallinen määrä tutkimuksia, minkä takia kaikki käytetyt lähteet eivät välttämättä liity henkilöetsintöihin maastossa tai UAS-järjestelmillä tuotettuun dataan.

4.2 Anturiyhdistelmät

Valitsemalla fuusioitavaksi komplementaariset anturit voidaan hyödyntää kunkin anturin vahvuuksia ja kompensoida niiden heikkouksia (Li ja muut, 2017, s. 100). Antureiden valinnassa on huomioitava myös, onko järjestelmää tarkoitus käyttää ainoastaan etsintöihin vai myös muihin käyttötarkoituksiin. Zhangin ja muiden (2025) mukaan tällä hetkellä suosittuja yhdistelmiä ovat muun muassa näkyvän valon ja infrapunavalon yhdistelmä ja näkyvän valon ja LiDARin yhdistelmä. He mainitsevat artikkelissa myös muita suosittuja yhdistelmiä, jotka perustuvat antureihin, joita ei tässä työssä käsitellä. Golcarenen ja muiden (2022, s. 2) mukaan yleisimpiä antureita UAS-järjestelmissä ovat RGB-kamerat ja lämpökamerat, minkä tekee niiden yhdistämisestä luontevaa. Yhdistämällä eri sensoreiden dataa, kuten lämpökameran ja RGB-kameran, voidaan parantaa objektintunnistuksen luotettavuutta ja tarkkuutta (Wang ja muut, 2025, s. 1).

Näkyvään valoon perustuvat objektintunnistusalgoritmit eivät monesti toimi haastavissa olosuhteissa, kuten yöllä tai sumuisella säällä (Wang ja muut, 2025, s. 1). Yhdistämällä RGB-kamera ja infrapunakamera, voidaan kompensoida RGB-kameran huono suorituskyky pimeällä ja epäsuotuisissa sääolosuhteissa (Zhang ja muut, 2025). Lämpökamerasta saadaan dataa ympäristön lämpösäteilystä ja RGB-kamera antaa suotuisissa valo-olosuhteissa paljon dataa ympäristön yksityiskohdista ja tekstuurista (Wang ja muut, 2025, s. 1–2). Näkyvän valon kuvien ja infrapunakuvien yhdistämistä vaikeuttaa erot resoluutioissa, pikseliarvoissa, spektrialueissa ja kuvien piirteissä (Samadzadegan ja muut, 2025, s. 1374). Zhangin ja muiden (2025) tekemän tutkimuksen mukaan pelkästään infrapunakameran tuottaman datan lisääminen RGB-kameralla tuotettuun dataan ei parantanut objektintunnistusalgoritmin suorituskykyä. Heidän mukaansa datan yhdistämisestä oli hyötyä vasta silloin, kun parannettiin myös piirreprosessointiin liittyviä vaiheita.

LiDAR-anturi tuottaa spatiaalisesti ja struktuurisesti tarkkaa dataa, mutta ei kuitenkaan spektrisesti (Samadzadegan ja muut, 2025, s. 1336). Toisin kuin RGB-kamera LiDAR suoriutuu myös epäsuotuisissa valo-olosuhteissa hyvin. Epäsuotuisat sääolosuhteet, kuten sade tai sumu, vaikuttavat kuitenkin negatiivisesti sekä LiDAR-anturin että RGB-kameran tuottamaan dataan (Yeong ja muut, 2021). Fuusioimalla RGB-kamera ja LiDAR-anturi voidaan kompensoida LiDARin matala spektrinen tarkkuus ja samaan aikaan RGB-kameran heikko suoriutuminen huonossa valaistuksessa. LiDAR-datan yhdistäminen kuviin yleensä tehostaa analyysia, mutta heikko resoluutio ja kohina voivat myös heikentää tarkkuutta (Samadzadegan ja muut, 2025, s. 1336).

Choi ja Kim (2023) tutkivat LiDAR-anturin ja lämpökameran fuusiointia objektintunnistukseen autonomisissa ajoneuvoissa. Tutkimuksessaan he testasivat fuusiota autolla eivätkä UAS-järjestelmällä. He vertasivat lopussa kahden eri anturiyhdistelmän suoriutumiskykyä: RGB-kamera + LiDAR ja lämpökamera + LiDAR. Tutkimuksesta kävi ilmi, että päivällä molemmat yhdistelmät suoriutuvat lähes yhtä

hyvin, mutta yöllä lämpökameran ja LiDARin yhdistelmä suoriutui huomattavasti paremmin.

Multispektrikameran ja LiDAR-anturin fuusiota on käytetty UAS-järjestelmissä maanviljelyyn liittyvissä sovelluksissa, joissa se on parantanut datankäsittely- ja analyysiprosessia (Samadzadegan ja muut, 2025, s. 1336–1337). Multispektrikameraa on fuusioitu myös RGB-kameralla (Samadzadegan ja muut, 2025, s. 1335). Samadzadegan ja muiden (2025, s. 1335) mukaan fuusioimalla multispektrikameran ja RGB-kameran ottamia kuvia saadaan edullisempi vaihtoehto hyperspektrikameralle, joka tuottaa dataa tärkeimmiltä spektrialueilta ja jolla on parempi spatiaalinen resoluutio kuin yksittäisillä kameroilla.

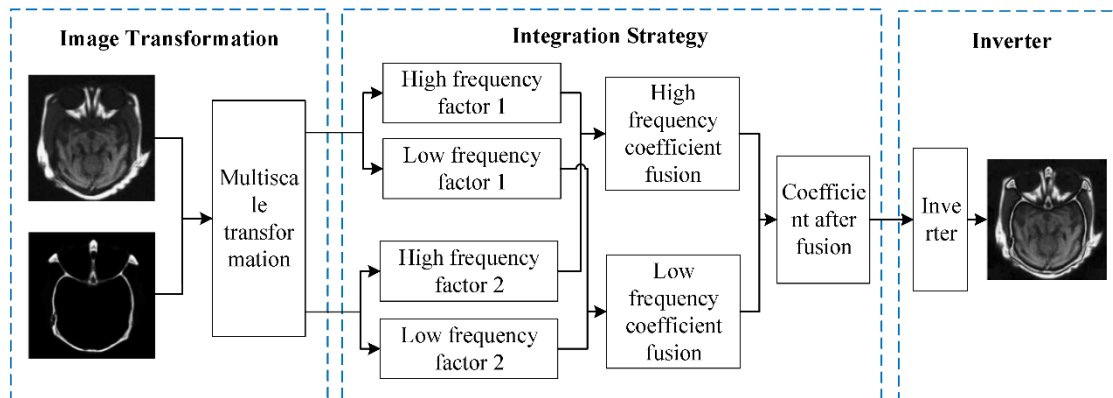
4.3 Perinteiset fuusiometodit

Yleisesti perinteiset fuusiometodit voidaan jakaa multi-scale transformation -pohjaisiin, sparse representation -pohjaisiin, subspace analysis -pohjaisiin, digitaaliseen signaalinkäsittelyyn perustuviin, ja erilaisiin hybridimetodeihin (Yang ja muut, 2024, s. 1). Tässä alaluvussa tarkastellaan kuitenkin ainoastaan multi-scale transformation ja sparse representation -pohjaisia menetelmiä. Perinteiset fuusiometodit toteuttavat kuvafusion hyödyntämällä sopivia matemaattisia muunnoksia kuvan piirteiden analysointiin ja fuusiosääntöjen määrittämiseen (Zhang ja muut, 2021, s. 323). Matemaattiset mallit ja muunnokset suunnitellaan käsin, mikä vaatii laajaa asiantuntemusta ja kasvattaa algoritmien monimutkaisuutta (Yang ja muut, 2024, s. 1). Fuusiosäännöistä saattaa puuttua teoreettinen pohja, jos niiden suunnittelijat nojaavat liikaa henkilökohtaiseen kokemukseensa, tietämykseensä tai kokeellisiin arvoihin (Yang ja muut, 2024, s. 1). Perinteisten metodien heikkous on, että samaa muunnosta käytetään erilaisten kuvien piirteiden poimimiseen, jolloin yksittäisten kuvien erilaisuuksia ei huomioida prosessissa (Zhang ja muut, 2021, s. 323). Lisäksi perinteiset fuusiometodit ovat karkeita ja yksinkertaistettuja, mikä heikentää fusion suorituskykyä (Zhang ja muut, 2021, s. 323). Perinteiset fuusiometodit jättävät usein huomioimatta

kuivissa esiintyvät korkean tason piirteet, mikä heikentää mallin yleistämiskykyä (Yang ja muut, 2024, s. 1). Perinteiset fuusiometodit eivät myöskään toimi kovin hyvin kompleksissa ja dynaamisessa ympäristössä (Wang ja muut, 2025, s. 3).

4.3.1 Multi-scale transformation -pohjainen fuusio

Man ja muiden (2023, s. 3) mukaan multi-scale transformation -pohjaiset fuusiometodit koostuvat kolmesta askeleesta. Heidän mukaansa ensin valitaan multi-scale decomposition -metodi, jolla hajautetaan kuva korkeataajuisiin ja matalataajuisiin alikaistakerroksiin. Seuraavaksi heidän mukaansa suunnitellaan sopiva fuusiolaskentamenetelmä ottaen huomioon alikaistakerroksien eri ominaisuudet, ja suoritetaan fuusio erikseen korkeataajuus- ja matalataajuuskerrosten kertoimille. Viimeiseksi invertoidaan lopulliset fuusiokertoimet eli suoritetaan käänteismuunnos, jotta saadaan fuusioitu kuva (Ma ja muut, 2023, s. 3). Tämä prosessi on näkyvässä kuvassa 5. Hajotusmenetelmän ja fuusiosääntöjen valinta on keskeinen osa fuusioprosessia, sillä ne määrittävät, kuinka paljon tietoa fuusioitu kuva säilyttää alkuperäisestä kuvasta (Ma ja muut, 2023, s. 3). Suosituimpia menetelmiä ovat pyramidimuunnos (engl. pyramid transform) ja wavelet-muunnos (engl. wavelet transform), kuten laplacion pyramid tai diskreetti wavelet-muunnos (Li ja muut, 2017, s. 101). Multi-scale transformation -pohjaisten fuusiometodien huonoja puolia ovat matala kuvakontrasti, tiedon redundanssi, matala häiriönkestävyys, alkuperäisen kuvan rakenteellisen tiedon menetys ja kuvan matala signaali-kohinasuhde (Ma ja muut, 2023, s. 4).



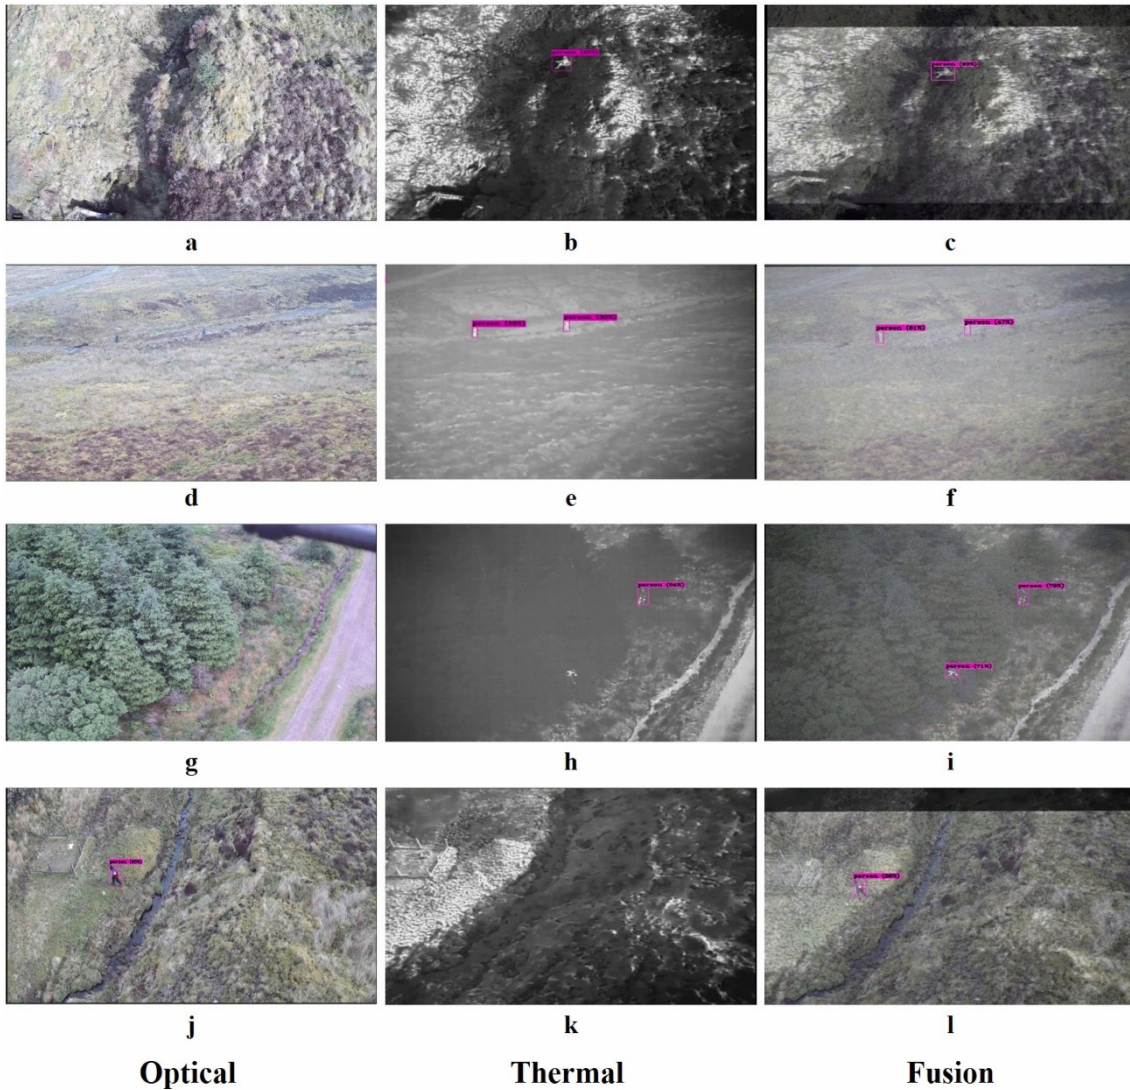
Kuva 5. Multi-scale transform -pohjainen kuvafuusio (Ma ja muut, 2023, s. 3).

4.3.2 Sparse representation -pohjainen fuusio

Sparse representation -pohjaiset fuusiomenetelmät käyttävät sanakirjoja (engl. dictionary), jotka sisältävät peruselementtejä, joiden avulla kuva voidaan esittää (Luo & Luo, 2023, s. 9). Tavoitteena on esittää kuva mahdollisimman vähillä tietokomponenteilla, mutta niin, että tärkeä tieto silti säilyy (Luo & Luo, 2023, s. 9). Luon ja Luon (2023, s. 9) mukaan sparse representation -pohjainen fuusio koostuu neljästä vaiheesta. Heidän mukaansa ensimmäisessä vaiheessa lähdekuvat hajotetaan päällekkäisiin lohkoihin. Sitten käytetään sanakirjaa ja suoritetaan sparse encoding, jotta saadaan jokaisen lohkon sparse-kertoimet, jotka kuvaavat lohkon tärkeimpiä piirteitä (Luo & Luo, 2023, s. 10). Tämän jälkeen sparse-kertoimet fuusioidaan fuusiosääntöjen mukaan ja viimeiseksi fuusioitu kuva rekonstruoidaan (Luo & Luo, 2023, s. 10). Sparse representation -pohjaisien fuusiometodien huono puoli on, että tekstuuriset yksityiskohdat jäävät helposti huomioimatta ja metodin toiminnallinen tehokkuus on matala (Ma ja muut, 2023, s. 5). Lisäksi metodi on herkkä kohinalle, mikä pienentää fuusioidun kuvan signaali-kohinasuhdetta (Ma ja muut, 2023, s. 5).

4.3.3 Esimerkki perinteisestä fuusiosta

Golcarenen ja muut (2022) tutkivat näkyvän valon kuvien ja lämpökuvien fuusiota käyttämällä perinteistä kuvafuusiometodia, joka perustuu kuvien aritmeettiseen yhteenlaskuun. Heidän fuusiotekniikkansa koostuu kolmesta vaiheesta: kalibrointi, rekisteröinti ja fuusio. Itse fuusion he suorittivat käyttämällä kuvien aritmeettista yhteenlaskua mukautetuilla painokertoimilla. Painokertoimet valitaan kuvan piirteiden tärkeyden mukaan. Esimerkiksi jos lämpökameran ottaman kuvan piirteet ovat merkittävämpiä ihmisen havaitsemisen kannalta kuin RGB-kameran, annetaan lämpökameralle suurempi painokerroin (Golcarenen ja muut, 2022, s. 8). Koska painokertoimet ovat mukautettavia, pystyy käyttäjä muokkaamaan niitä kuvaolosuhteiden mukaan ja siten kontrolloimaan fuusioprosessia (Golcarenen, 2022, s. 5). Lisäksi Golcarenen ja muut (2022) suunnittelivat ja kehittivät uuden reaaliaikaisen konvoluutioneuroverkon ihmisten havaitsemiseen nimeltä BendNet. Todetakseen fuusion hyödyllisyyden, he käyttivät BendNetiä, jonka avulla he vertasivat ihmisten tunnistusta näkyvän valon kuvista, lämpökameran ottamista kuvista ja fuusioituista kuvista. Tulokset näkyvät kuvassa 6, jossa ensimmäisessä sarakkeessa on RGB-kameralla otettu kuva, toisessa sarakkeessa lämpökameralla otettu kuva ja viimeisessä sarakkeessa fuusioitu kuva. Kuvasta käy ilmi, että ihmiset onnistuttiin havaitsemaan fuusioituista kuvista jokaisessa tapauksessa, toisin kuin vain yhden anturin kuvista.



Kuva 6. Esimerkki kuvafuusiosta perinteisellä menetelmällä (Golcarenarenji ja muut, 2022, s. 11).


4.4 Syväoppimispohjaiset fuusiometodit

Nykyään kuvafuusiotekniikat ovat siirtyneet perinteisistä fuusiometodeista syväoppimispohjaisiin metodeihin, minkä myötä kuvafuusio on kehittynyt ja tehostunut (Ma ja muut, 2023, s. 18). Kehittämällä syväoppimiseen perustuvia fuusiointimenetelmiä halutaan ratkaista perinteisten menetelmien rajoitteet (Zhang ja muut, 2021, s. 323). Syväoppimispohjaisen fuusion etuihin kuuluu parempi havaittu laatu, suurempi luotettavuus ja parempi laskentatehokkuus (Li ja muut, 2025, s. 2). Lisäksi


syväoppimis pohjaiset ratkaisut vähentävät inhimillisten tekijöiden vaikutuksia tuloksiin (Luo & Luo, 2023, s. 14). Syväoppimisteknologiaa on hyödynnetty onnistuneesti kuvafuusiassa, mutta siihen liittyy vielä haasteita (Ma ja muut, 2023). Lin ja muiden (2025, s. 2) mukaan syväoppimiseen perustuvien fuusiometodien tutkimuksessa keskitytään nykyään yhä enemmän datayhteensopivuuteen ja tehtäväkohtaisuuteen, eikä pelkästään visuaaliseen miellyttävyyteen, kuten kontrastiin, tekstuuriin tai yksityiskohtiin. Syväoppimiseen perustuvat fuusiointitekniikat pohjautuvat yleensä autoenkooderiin (engl. autoencoder, AE), konvoluutioneuroverkkoihin (engl. convolutional neural network, CNN), generatiivisiin kilpaileviin verkostoihin (engl. generative adversarial network, GAN) tai transformer-malleihin (Li ja muut, 2025, s. 3).

4.4.1 Autoenkooderi

Autoenkooderi koostuu enkooderista, joka poimii piirteitä kuvista, ja dekooderista, joka rekonstruoi kuvia (Yang ja muut, 2024, s. 7–8). Autoenkooderiin perustuva fuusio koostuu kahdesta vaiheesta (Li ja muut, 2025, s. 5). Ensin autoenkooderi koulutetaan luomaan kuvia, jotka ovat mahdollisimman samannäköisiä kuin syötekuvat (Yang ja muut, 2024, s. 8). Toisessa vaiheessa koulutettua enkooderia käytetään piirteiden poimintaan kuvista ja koulutettua dekooderia kuvien rekonstruointiin (Zhang ja Demiris, 2023, s. 10541). Autoenkooderiin perustuvien fuusiometodien toimintaperiaate on näkyvissä kuvassa 7, jossa kohta (a) kuvaa ensimmäistä vaihetta ja kohta (b) toista vaihetta. Jotkut autoenkooderiin perustuvat metodit koulutetaan vain näkyvän valon kuvilla, vaikka niillä käsitellään koulutuksen jälkeen myös infrapunakuvia (Zhang & Demiris, 2023, s. 10541). Tällöin fuusion suorituskyky voi laskea, minkä takia koulutukseen kannattaa käyttää sekä näkyvän valon kuvia että infrapunakuvia (Zhang & Demiris, 2023, s. 10541). Autoenkooderiin perustuvilla fuusiointimeteodeilla on rajattu kyky tunnistaa pitkän matkan riippuvuuksia, eli riippuvuuksia kaukana toisistaan olevien alueiden välillä (Li ja muut, 2025, s. 12). Esimerkkejä autoenkooderiin perustuvista fuusiometodeista ovat DeepFuse ja TCPMFNet (Luo & Luo, 2023, s. 15)



(a) Pretraining of autoencoder.



(b) Autoencoder-based VIF methods.

Kuva 7. Autoenkooderiin pohjautuvien fuusiomethodien toimintaperiaate (Zhang & Demiris, 2023, s. 10541).

4.4.2 Konvoluutioneuroverkot

Konvoluutioneuroverkkoja voidaan käyttää kuvafuusiossa kahdella eri tavalla (Zhang ja muut, 2021, s. 324). Ensimmäisessä tavassa koko fuusiointiprosessi toteutetaan samalla konvoluutioneuroverkolla alusta loppuun asti hyödyntämällä hyvin suunniteltuja häviöfunktioita ja verkkorakenteita (Zhang ja muut, 2021, s. 324). Toisessa lähestymistavassa konvoluutioneuroverkkoa käytetään yhdessä perinteisten fuusiointimethodien kanssa, jolloin vain fuusiointivaiheeseen käytetään konvoluutioneuroverkkoa (Zhang ja muut, 2021, s. 324). Konvoluutioneuroverkko koostuu kolmesta eri kerroksesta: konvoluutiokerroksesta, poolauskerroksesta (engl. pooling-layer) ja täysin kytketystä kerroksesta (Luo & Luo, 2023, s. 15). Konvoluutiokerros poimii piirteitä kuvista ja täysin kytketty kerros hyödyntää niitä luokittelussa ja päätöksenteossa (Luo & Luo, 2023, s. 15). Poolauskerros vähentää vaaditun laskennan

määrää ja auttaa mallia oppimaan abstraktimpia ja semanttisesti merkityksellisempiä piirteitä (Yang ja muut, 2024, s. 4). Konvoluutioneuroverkon kerrokset voidaan määritellä myös eri tavalla ja esimerkiksi Yang ja muut (2024, s. 2) laskevat neljänneksi kerrokseksi normalisointikerroksen. Hyvin suunniteltu häviöfunktio määrittää, minkälainen tieto syötekuvista säilytetään fuusoidussa lopputuloksessa ja ohjaa verkkoa toimimaan sen mukaan (Yang ja muut, 2024, s. 4) Esimerkkejä fuusiometodeista ovat FusionDN, IFCNN ja VGG-19 network (Luo & Luo, 2023, s. 15).

4.4.3 Generatiiviset kilpailevat verkostot

Generatiivisiin kilpaileviin verkostoihin perustuvat menetelmät suorittavat kaikki kolme fuusioinnin vaihetta samassa verkostossa samanaikaisesti (Zhang ja muut, 2021, s. 324). Generatiivinen kilpaileva verkosto koostuu generaattorista ja diskriminaattorista (Zhang ja muut, 2021, s. 324). GAN-mallin koulutusvaiheessa generaattori käyttää kohinaa luodakseen synteettisiä kuvia, jotka näyttävät mahdollisimman realistisilta (Luo & Luo, 2023, s. 17). Diskriminaattorin tehtävä on erottaa aidot kuvat, jotka ovat peräisin jostain aineistosta, generaattorin luomista synteettisistä kuvista (Luo & Luo, 2023, s. 17). Koulutusvaiheen jälkeen generaattoria voidaan käyttää luomaan fuusiokuvia (Luo & Luo, 2023, s. 17). Useat generatiivisiin kilpaileviin verkostoihin perustuvista fuusiometodeista käyttävät yhden diskriminaattorin sijaan kahta (Li ja muut, 2025, s. 8). GAN-pohjaiset fuusiometodit parantavat fuusioitujen kuvien realistisuutta ja kohteen havaittavuutta (Li ja muut, 2025, s. 12). Niiden haasteet liittyvät yleisimmin koulutusvaiheeseen (Yang ja muut, 2024, s. 7) sekä mallin vakauteen ja tulkittavuuteen (Li ja muut, 2025, s. 12). Esimerkkejä fuusiometodeista ovat FusionGAN, SSGAN ja FLGCFusionGAN (Luo & Luo, 2023, s. 15).

4.4.4 Transformer-mallit

Transformer-malleihin perustuvat fuusiometodit kuuluvat uusimpiin metodeihin ja niiden tutkimus on vielä alussa (Yang ja muut, 2024, s. 2). Transformer-malleihin perustuvien metodien rakenteet vaihtelevat ja vain harvat metodit on toteutettu pelkästään transformereilla (Zhang & Demiris, 2023, s. 10544). Osassa metodeista transformereita käytetään ainoastaan fuusiovaiheeseen ja toisissa metodeissa niitä voidaan käyttää myös prosessin muihin vaiheisiin (Zhang & Demiris, 2023, s. 10544). Transformer-mallit huomioivat riippuvuuksia kaukana toisistaan olevien alueiden välillä, mikä on keskeistä kompleksien kuvien tulkinnessa (Yang ja muut, 2024, s. 10). Transformereihin perustuvien fuusiometodien heikkouksia ovat niiden vaatima korkea määrä laskentaresursseja ja niiden monimutkainen rakenne, jonka takia parametrien optimointi ja hienosäätö voi olla haastavaa (Yang ja muut, 2024, s. 10). Siitä huolimatta Li ja muut (2025, s. 9) uskovat transformer-malleihin perustuvien metodien olevan yksi merkittävimmistä tutkimussuunnista liittyen näkyvän valon ja infrapunavalon fuusiointiin. Lisäksi he näkevät transformer-metodeissa suurta potentiaalia edistää UAS-järjestelmiin liittyviä fuusioitehtäviä kompleksissa ympäristössä.

4.4.5 Muut

Yllä mainittujen metodien rinnalla tutkijat kehittävät myös vaihtoehtoisia menetelmiä (Li ja muut, 2025, s. 10). Vaihtoehtoisten metodien toivotaan parantavan kuvalaatuja, mallin vakautta ja soveltuvan paremmin UAS-järjestelmiin (Li ja muut, 2025, s. 10). Lin ja muiden (2025, s. 10) mukaan diffuusioon perustuvat menetelmät ja Mamba-pohjaiset mallit kehittyvät tällä hetkellä suurta vauhtia.

4.4.6 Syväoppimis pohjaisten fuusiometodien vertailu

Li ja muut (2025, s. 20) vertasivat tutkimuksessaan eri fuusiometodien suorituskykyä hyödyntämällä alkuperäisten tekijöiden julkaisemia koulutettuja malleja. Vertailussa he

käyttivät RoadScene-tietokantaa, joka sisältää näkyvän valon kuvia ja infrapunakuvia kuvattuna maalla liikkuvan ajoneuvon näkökulmasta, mutta ei ilmasta kuvattuja kuvia. He fuusioivat kuvapareja, joista toinen on näkyvän valon kuva ja toinen infrapunakuva, käyttämällä eri fuusiometodeja. Esimerkki heidän tekemästä vertailusta on näkyvissä kuvassa 8, jossa on käytetty kahta kuvaparia, joista toinen on otettu päiväsaikaan ja toinen yöaikaan. Ensimmäisellä rivillä on näkyvissä alkuperäiset kuvat, jotka fuusioidaan. Seuraavilla riveillä näkyy fuusion tulokset. Toisella rivillä fuusiointiin käytetään autoenkooderiin pohjautuvia menetelmiä, kolmannella rivillä konvoluutioneuroverkkoihin perustuvia metodeja, neljännellä ja viidennellä rivillä transformer-pohjaisia metodeja ja alimmalla rivillä diffuusion pohjautuvia menetelmiä.



Kuva 8. Syväoppimispohjaisten fuusiometodien vertailu (Li ja muut, 2025, s. 20).

Kuvassa 8 lyhenne MI (engl. mutual information) tarkoittaa keskinäistä tietoa, joka mittaa kuinka paljon tietoa fuusiokuva ja alkuperäiset kuvat jakavat (Li ja muut, 2025, s. 17). Qabf on reunainformaatioon perustuva mittari, jolla arvioidaan kuvafuusion laatua (Li ja muut, 2025, s. 17). Molemmilla mittareilla korkeampi arvo tarkoittaa parempaa suoriutumista (Li ja muut, 2025, s. 21). Perustuen kuvassa 8 näkyviin kuvapareihin, diffuusioon perustuva Diff-IF (3,45; yöaikaan) suoriutuu parhaiten MI-mittarin mukaan ja transformer-malliin perustuva TGFuse (0,64; päiväsaikaan) parhaiten Qabf-mittarin mukaan.

Li ja muut (2025) fuusioivat yhteensä 221 kuvaparia ja vertasivat fuusiokuvia seitsemän eri laatumittarin perusteella. Laatumittareihin lukeutuvat EN (engl. entropy), SD (engl. standard deviation, keskihajonta), SF (engl. spatial frequency, spatiaalinen taajuus), MI, SCD (engl. sum of correlation differences), VIF (engl. visual information fidelity) ja Qabf. Yangin ja muiden (2024, s. 12–13) mukaan EN mittaa kuvan sisältämän tiedon määrää ja SD kuvan kontrastia. Heidän mukaansa SF kuvaa rajojen ja tekstuurin määrää, VIF kuvalaatua ihmisen näköjärjestelmän näkökulmasta ja SCD komplementaaristen piirteiden säilymistä. Kaikilla mittareilla suurempi arvo vastaa parempaa suorituskkyä. Lin ja muiden (2025) saamat tulokset ovat näkyvissä taulukossa 3. Selkeyden vuoksi jokaisen mittarin saavuttama paras arvo on lihavoitu. Taulukon 3 mukaan sama fuusiometodi suoriutuu parhaiten korkeintaan kahden mittarin mukaan. Fuusiometodeja, jotka saavuttavat parhaan arvon yhden tai kahden mittarin mukaan ovat CDDFuse (EN ja SD), FISCNet (SF), PIAFusion (MI), PromptFusion (SCD) ja Text-IF (VIF ja Qabf).


Taulukko 3. Syväoppimispohjaisten fuusiometodien suorituskky eri mittareilla 221 kuvaparin perusteella (mukaillen Li ja muut, 2025, s. 21).

Metodi	EN	SD	SF	MI	SCD	VIF	Qabf
MaeFuse	7,19	44,28	12,24	1,71	1,71	0,56	0,46
FSFusion	7,07	48,18	12,51	2,34	1,67	0,64	0,46
FISCNet	7,09	43,85	16,62	2,20	1,26	0,59	0,55

Metodi	EN	SD	SF	MI	SCD	VIF	Qabf
PIAFusion	6,98	42,70	12,13	2,47	1,47	0,68	0,44
CDDFuse	7,43	54,66	16,36	2,30	1,81	0,69	0,52
TGFuse	7,17	43,14	14,03	1,85	1,42	0,61	0,53
PromptFusion	7,39	53,15	16,24	2,38	1,92	0,68	0,50
Text-IF	7,37	49,67	14,80	2,08	1,85	0,70	0,59
Diff-IF	7,11	43,73	14,61	2,06	1,21	0,66	0,51
Dif-Fusion	7,17	42,33	15,51	1,99	1,32	0,55	0,51

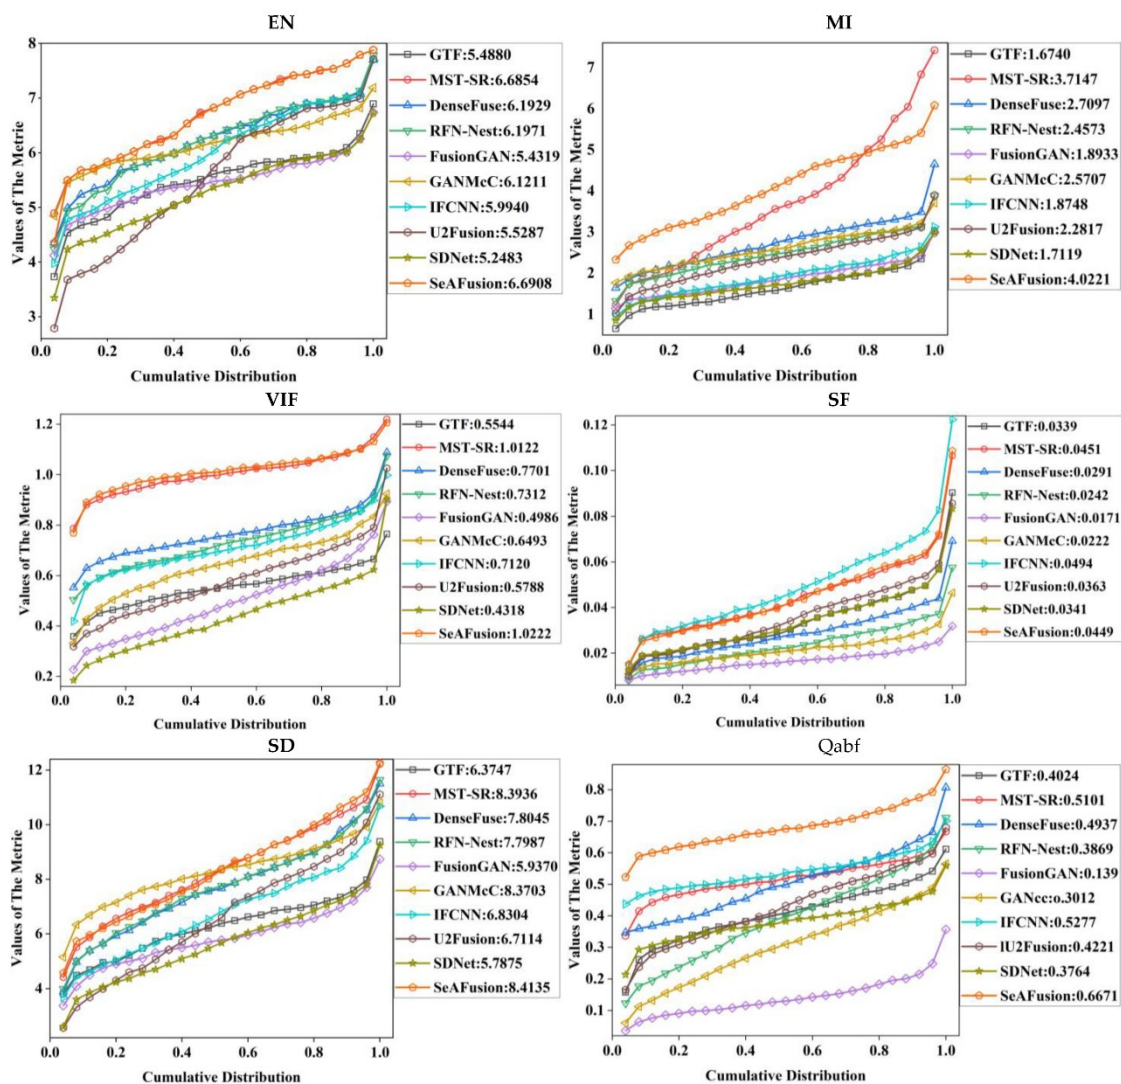
4.5 Perinteisten ja syväoppimispohjaisten fuusiometodien vertailu

Ma ja muut (2023) vertasivat tutkimuksessaan 10:tä eri fuusiometodia, joista MST-SR ja GTF ovat perinteisiä fuusiometodeja ja loput syväoppimispohjaisia. MST-SR on hybridimalli, joka perustuu perinteisiin fuusiometodeihin multi-scale transform ja sparse representation. Vertailussaan he käyttivät MFNet-aineistoa, joka sisältää kuvapareja, joista toinen kuva on näkyvän valon kuva ja toinen infrapunakuva. He käyttivät sekä päiväsaikaan että yöaikaan otettuja kuvapareja. Kuvassa 9 (a) on alkuperäinen infrapunakuva ja (b) alkuperäinen näkyvän valon kuva. Loput kuvista ovat fuusiokuvia, joiden fuusioon on käytetty (c) GTF, (d) MST-SR, (e) DenseFuse, (f) RFN-Nest, (g) FusionGAN, (h) GANMcC, (i) IFCNN, (j) U2Fusion, (k) SDNet ja (l) SeAFusion.



Kuva 9. Perinteisten ja syväoppimis pohjaisten fuusiomethodien vertailu (Ma ja muut, 2023, s. 16).

Ma ja muut (2023) arvioivat fuusiomethodien suorituskykyä kuudella eri mittarilla: EN, MI, VIF, SF, SD ja Qabf. Man ja muiden (2023, s. 17–18) saamat tulokset vertailusta perustuvat 361:een kuvapariin ja ovat näkyvissä kuvassa 10. Heidän mukaansa SeAFusion, joka on CNN-pohjainen fuusiomethodi, suoriutui parhaiten mittareilla EN, MI, SD, VIF ja Qabf. SF-mittarilla IFCNN ja MST-SR suoriutuivat paremmin kuin SeAFusion (Ma ja muut, 2023, s. 17). Kuvasta 10 voidaan huomata, että perinteinen fuusiomethodi MST-SR suoriutui yleisesti katsottuna todella hyvin ja oli jokaisessa kategoriassa parhaimpien joukossa. Toinen perinteinen fuusiomethodi GTF ei kuitenkaan saavuttanut yhtä hyviä tuloksia. Ma ja muut (2023, s. 19) huomauttavat tutkimuksessaan, että nykyiset arviointimittarit eivät kykene kuvaamaan fuusioalgoritmien suorituskykyä täysin.



Kuva 10. Perinteisten ja syväoppimispohjaisten fuusiometodien suorituskyky eri mittareilla 361 kuvaparin perusteella (Ma ja muut, 2023, s. 18).

Lin ja muiden (2025) tekemässä vertailussa sekä Man ja muiden (2023) tekemässä vertailussa käytetään samoja mittareita (EN, MI, VIF, SF, SD ja Qabf), joten niiden tuloksia voidaan verrata keskenään. On kuitenkin otettava huomioon, että Man ja muiden (2023) saamat tulokset perustuvat 361:een eri kuvapariin ja Lin ja muiden (2025) tulokset vain 221:een kuvapariin. Jos otetaan huomioon molemmissa tutkimuksissa verratut fuusiometodit, voidaan verrata keskenään 20:tä eri fuusiometodia. Tällöin EN-mittarin mukaan parhaiten suoriutuu CDDFuse (7,43), toiseksi parhaiten PromptFusion (7,39) ja kolmanneksi parhaiten Text-IF (7,37). MI-mittarin mukaan parhaiten suoriutuu

SeAFusion (4,0221), toiseksi parhaiten MST-SR (3,7147) ja kolmanneksi parhaiten DenseFuse (2,7097). VIF-mittarin mukaan kolme parhaiten suoriutuvaa metodia ovat SeAFusion (1,0222), MST-SR (1,0122) ja DenseFuse (0,7701). Qabf-mittarilla parhaiten suoriutuu SeAFusion (0,6671), toiseksi parhaiten IFCNN (0,5277) ja kolmanneksi parhaiten MST-SR (0,5101). SF- ja SD-mittareilla saadut arvot ovat Lin ja muiden (2025) ja Man ja muiden (2023) tutkimuksissa aivan eri luokkaa, joten ne on todennäköisesti laskettu eri tavalla, minkä takia ne eivät ole verrattavissa. Fuusiometodit, jotka ovat kahden tai useamman laatumittarin mukaan kolmen parhaan joukossa, ovat SeAFusion, MST-SR ja DenseFuse.

5 Johtopäätökset

Tutkielmassa tarkasteltiin UAS-järjestelmien ja monisensorisen kuvafuusion hyödyntämistä maastoetsinnöissä toiminnan tehostamiseksi. Keskeisiä aiheita tutkielmassa olivat tutkimuksen nykytilanne, UAS-järjestelmien anturit ja kuvafuusiometodit. UAS-järjestelmät ovat nykyään olennainen osa etsintätoimintaa, toisin kuin kuvafuusio, joka ei ole vielä vakiintunut käytäntö. Viime vuosina kuvafuusion tutkimus on edistynyt ripeästi syväoppimispohjaisten fuusiometodien kehittymisen myötä. Tällä hetkellä kuvafuusiota ei varsinaisesti hyödynnetä käytännössä etsintätoimimessa siitä huolimatta, että tutkimukset ovat osoittaneet, että kuvafuusio voi parantaa ihmisten havaitsemisen tarkkuutta ja tuloksien luotettavuutta haastavassa ja dynaamisessa ympäristössä.

Maastoetsinnöissä haasteita aiheuttavat muun muassa vaihtelevat valo- ja sääolosuhteet, ihmisen pieni koko sekä heikko erotettavuus ympäröivästä maastosta ja maaston peitteisyys. Jokaisella anturilla on omat heikkoutensa, mutta fuusioimalla eri antureita voidaan kompensoida yksittäisten anturien heikkoudet. Yleisimmin käytetyt anturit ovat RGB-kamera ja lämpökamera. Tutkielmassa kävi kuitenkin ilmi, että myös muut anturit, kuten LIDAR ja multispektrikamera, voivat olla hyödyksi etsinnöissä ja parantaa etsintätuloksia. Näiden antureiden soveltuvuutta on kuitenkin tutkittava lisää, jotta niitä voidaan hyödyntää parhaalla mahdollisella tavalla.

Kuvafuusion hyödyntämistä vaikeuttavat etenkin UAS-järjestelmien ominaisuudet, kuten rajallinen laskentateho, hyötykuorman kantokyky ja virtalähteen kapasiteetti. Lisäksi UAS-järjestelmillä kerätyssä kuvamateriaalissa esiintyy kohinaa ja vääristymiä, jotka johtuvat sääolosuhteista, vaihtelevista kuvakulmista sekä järjestelmän liikkeestä ja tärinästä. Tämän tutkielman tarkkaan sovellusalaan liittyviä tutkimuksia on olemassa vain todella pieni määrä ja niiden perusteella on vaikea määrittää mitkä fuusiometodit soveltuvat käyttöalueeseen parhaiten.

Suurimmaksi osaksi syväoppimispohjaiset fuusiometodit ovat korvanneet perinteiset metodit. Syväoppimispohjaisten fuusiometodien etuihin kuuluu parempi havaittu laatu ja suurempi luotettavuus sekä usein myös parempi laskentatehokkuus ja kyky tunnistaa pitkän matkan riippuvuuksia. Fuusiometodien haasteet liittyvät usein mallin koulutukseen, monimutkaisuuteen, tulkittavuuteen ja hienosäätöön. Syväoppimispohjaiset fuusiometodit, jotka tehdyn analyysin perusteella suoriutuvat erityisen hyvin, ovat SeAFusion ja DenseFuse. SeAFusion perustuu konvoluutioneuroverkkoihin ja DenseFuse autoenkooderiin. Luvussa 4.5 tehdyn vertailun perusteella kuitenkin myös perinteisellä fuusiometodilla MST-SR saavutettiin erityisen hyviä tuloksia.

On kuitenkin huomioitava, että fuusiometodeja ei ole testattu UAS-järjestelmän ottamalla ilmakuvilla maasto-olosuhteissa, joissa esimerkiksi sääolosuhteet vaihtelevat, joten fuusiometodien todellista suorituskykyä käytännön sovelluksissa on vaikea arvioida. Kuva-aineistoa, joka vastaa etsintäoperaatioiden tilannetta, on olemassa vain vähän. Tulevaisuudessa on luotava tällaisia kuvakokoelmia, jotta kuvafuusiometodien suorituskykyä voidaan testata sopivammassa ympäristössä. Monet kuvafuusiometodit keskittyvät näkyvän valon kuvien ja infrapunakuvien fuusioon. Tutkittavaksi jää, miten metodit toimivat esimerkiksi LiDAR-anturin tai multispektrikameran ottavilla kuvilla, mikäli näitä antureita haluttaisiin hyödyntää etsinnöissä.

Lähteet

- Bany Abdelnabi, A. A., & Rabadi, G. (2024). Human Detection From Unmanned Aerial Vehicles' Images for Search and Rescue Missions: A State-of-the-Art Review. *IEEE access*, 12, 152009-152035. <https://doi.org/10.1109/ACCESS.2024.3479988>
- Choi, J. D., & Kim, M. Y. (2023). A sensor fusion system with thermal infrared camera and LiDAR for autonomous vehicles and deep learning based object detection. *ICT express*, 9(2), 222-227. <https://doi.org/10.1016/j.ict.2021.12.016>
- Cruz Ulloa, C., Orbea, D., del Cerro, J., & Barrientos, A. (2024). Thermal, Multispectral, and RGB Vision Systems Analysis for Victim Detection in SAR Robotics. *Applied sciences*, 14(2), 766. <https://doi.org/10.3390/app14020766>
- Dumenčić, S., Lanča, L., Jakac, K., & Ivić, S. (2025). Experimental Validation of UAV Search and Detection System in Real Wilderness Environment. *Drones*, 9(7), 473. <https://doi.org/10.3390/drones9070473>
- Golcarenenji, G., Martinez-Alpiste, I., Wang, Q., & Alcaraz-Calero, J. M. (2022). Illumination-aware image fusion for around-the-clock human detection in adverse environments from Unmanned Aerial Vehicle. *Expert systems with applications*, 204, 117413. <https://doi.org/10.1016/j.eswa.2022.117413>
- Ikonen, T. & Rytönen, K. (2023). *Miehittämättömien ilma-alusten turvallinen ja tehokas käyttö pelastustoiminnassa*. Pelastusopisto. Noudettu 06.11.2025 osoitteesta https://info.smedu.fi/kirjasto/Sarja_D/D2_2023.pdf
- Kaur, H., Koundal, D., & Kadyan, V. (2021). Image Fusion Techniques: A Survey: Image Fusion Techniques: A Survey. *Archives of computational methods in engineering*, 28(7), 4425-4447. <https://doi.org/10.1007/s11831-021-09540-7>
- Lee, J., Kim, Y., Kim, K., & Kim, S. (2016). Estimating Clothing Thermal Insulation Using an Infrared Camera. *Sensors (Basel, Switzerland)*, 16(3), 341. <https://doi.org/10.3390/s16030341>
- Li, S., Kang, X., Fang, L., Hu, J., & Yin, H. (2017). Pixel-level image fusion: A survey of the state of the art. *Information fusion*, 33, 100-112. <https://doi.org/10.1016/j.inffus.2016.05.004>

- Li, J., Peng, Y., & Jiang, T. (2021). Embedded real-time infrared and visible image fusion for UAV surveillance. *Journal of real-time image processing*, 18(6), 2331-2345. <https://doi.org/10.1007/s11554-021-01111-0>
- Li, J., Fan, C., Ou, C., & Zhang, H. (2025). Infrared and Visible Image Fusion Techniques for UAVs: A Comprehensive Review. *Drones*, 9(12), 811. <https://doi.org/10.3390/drones9120811>
- Luo, Y., & Luo, Z. (2023). Infrared and Visible Image Fusion: Methods, Datasets, Applications, and Prospects. *Applied sciences*, 13(19), 10891. <https://doi.org/10.3390/app131910891>
- Lyu, M., Zhao, Y., Huang, C., & Huang, H. (2023). Unmanned Aerial Vehicles for Search and Rescue: A Survey. *Remote Sensing*, 15(13), 3266. <https://doi.org/10.3390/rs15133266>
- Ma, W., Wang, K., Li, J., Yang, S. X., Li, J., Song, L., & Li, Q. (2023). Infrared and Visible Image Fusion Technology and Application: A Review. *Sensors (Basel, Switzerland)*, 23(2), 599. <https://doi.org/10.3390/s23020599>
- McKenzie, Steven. (17.07.2018) *Drone spots Scots climber feared dead in Himalayas*. BBC. Noudettu 21.10.2025 osoitteesta <https://www.bbc.com/news/uk-scotland-highlands-islands-44858758>
- Mohsan, S. A. H., Othman, N. Q. H., Li, Y., Alsharif, M. H., & Khan, M. A. (2023). Unmanned aerial vehicles (UAVs): Practical aspects, applications, open challenges, security issues, and future trends. *Intelligent service robotics*, 16(1), 109-137. <https://doi.org/10.1007/s11370-022-00452-4>
- Nègre, P., Mahé, K., & Cornacchini, J. (2025). Unmanned aerial vehicle (UAV) paired with LiDAR sensor to detect bodies on surface under vegetation cover: Preliminary test. *Forensic science international*, 369, 112411. <https://doi.org/10.1016/j.forsciint.2025.112411>
- Nex, F., Armenakis, C., Cramer, M., Cucci, D., Gerke, M., Honkavaara, E., Kukko, A., Persello, C., Skaloud, J. (2022). UAV in the advent of the twenties: Where we stand and what is next. *ISPRS journal of photogrammetry and remote sensing*, 184, 215-242. <https://doi.org/10.1016/j.isprsjprs.2021.12.006>

- Ozcan, A., & Cetin, O. (2022). A Novel Fusion Method With Thermal and RGB-D Sensor Data for Human Detection. *IEEE access*, 10, 66831-66843. <https://doi.org/10.1109/ACCESS.2022.3185402>
- Poliisi. (n.d.). *Miehittämätön ilmaitu*. Noudettu 5.11.2025 osoitteesta <https://poliisi.fi/miehitamaton-ilmailu>
- Poliisi. (23.02.2023b). *Poliisin kuvauskopteri nousee ilmaan joka päivä ja toiminnassa ollaan maailman huipulla – droneilla säästetään rahaa ja aikaa ja pelastetaan ihmishenkii*. Noudettu 21.10.2025 osoitteesta <https://poliisi.fi/-/poliisin-kuvauskopteri-nousee-ilmaan-joka-paiva-ja-toiminnassa-ollaan-maailman-huipulla-droneilla-saastetaan-rahaa-ja-aikaa-ja-pelastetaan-ihmishenkia>
- Poliisi. (13.10.2023a). *Poliisi löysi kadonneen miehen metsästä tärkeällä hetkellä*. Noudettu 20.10.2025 osoitteesta <https://poliisi.fi/-/poliisi-loysi-kadonneen-miehen-metsasta-tarkealla-hetkella>
- Qi, F., Zhu, M., Li, Z., Lei, T., Xia, J., Zhang, L., Yan, Y., Wang, J. Lu, G. (2022). Automatic Air-to-Ground Recognition of Outdoor Injured Human Targets Based on UAV Bimodal Information: The Explore Study. *Applied sciences*, 12(7), 3457. <https://doi.org/10.3390/app12073457>
- Quero, C. O., & Martinez-Carranza, J. (2025). Unmanned aerial systems in search and rescue: A global perspective on current challenges and future applications. *International journal of disaster risk reduction*, 118, 105199. <https://doi.org/10.1016/j.ijdrr.2025.105199>
- Ramírez-Ayala, O., González-Hernández, I., Salazar, S., Flores, J., & Lozano, R. (2023). Real-Time Person Detection in Wooded Areas Using Thermal Images from an Aerial Perspective. *Sensors (Basel, Switzerland)*, 23(22), 9216. <https://doi.org/10.3390/s23229216>
- Samadzadegan, F., Toosi, A., & Dadrass Javan, F. (2025). A critical review on multi-sensor and multi-platform remote sensing data fusion approaches: Current status and prospects. *International journal of remote sensing*, 46(3), 1327-1402. <https://doi.org/10.1080/01431161.2024.2429784>

- Wang, C., Zhou, M., Sun, D., Gao, Q., Li, Z., & Wang, T. (2025). MMT-NET: A lightweight multi-modal fusion network for UAV target detection in adverse environments. *Journal of real-time image processing*, 22(4), 160. <https://doi.org/10.1007/s11554-025-01741-8>
- Yamamoto, Y., Tang, Z. C., Taguchi, K., & Tsuchiya, H. (2024). *Drone with Multiple Sensors for Night-time Search Missions of Disaster Victims*. IEEE. <https://doi.org/10.1109/ICIEA61579.2024.10664907>
- Yang, K., Xiang, W., Chen, Z., Zhang, J., & Liu, Y. (2024). A review on infrared and visible image fusion algorithms based on neural networks. *Journal of visual communication and image representation*, 101, 104179. <https://doi.org/10.1016/j.jvcir.2024.104179>
- Yao, H., Qin, R., & Chen, X. (2019). Unmanned Aerial Vehicle for Remote Sensing Applications—A Review. *Remote sensing (Basel, Switzerland)*, 11(12), 1443. <https://doi.org/10.3390/rs11121443>
- Yeong, D. J., Velasco-Hernandez, G., Barry, J., & Walsh, J. (2021). Sensor and Sensor Fusion Technology in Autonomous Vehicles: A Review. *Sensors (Basel, Switzerland)*, 21(6), 2140. <https://doi.org/10.3390/s21062140>
- Zhang, H., Xu, H., Tian, X., Jiang, J., & Ma, J. (2021). Image fusion meets deep learning: A survey and perspective. *Information fusion*, 76, 323-336. <https://doi.org/10.1016/j.inffus.2021.06.008>
- Zhang, X., & Demiris, Y. (2023). Visible and Infrared Image Fusion Using Deep Learning. *IEEE transactions on pattern analysis and machine intelligence*, 45(8), 10535-10554. <https://doi.org/10.1109/TPAMI.2023.3261282>
- Zhang, Z., & Zhu, L. (2023). A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications. *Drones*, 7(6), 398. <https://doi.org/10.3390/drones7060398>
- Zhang, Z., Dong, W., Bai, J., Wang, C., Qiu, J., Sun, D., & Yang, X. (2025). UAV Perspective Small Object Detection with RGB-IR Fusion Perception. *Shanghai jiao tong da xue xue bao*. <https://doi.org/10.1007/s12204-025-2835-3>