

Anni Tarvainen

**Koneoppimisen hyödyntäminen metsä- ja maastopalojen
havaitsemisessa droneilmakuvista**

Tietotekniikan kandidaatintutkielma

30. huhtikuuta 2023

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

Tekijä: Anni Tarvainen

Yhteystiedot: anni.e.tarvainen@student.jyu.fi

Ohjaaja: Tuomo Rossi

Työn nimi: Koneoppimisen hyödyntäminen metsä- ja maastopalojen havaitsemisessa droneilmakuvista

Title in English: The use of machine learning in detecting forest and wild fires in aerial images taken from an UAV

Työ: Kandidaatintutkielma

Sivumäärä: 21+0

Tiivistelmä: Kandidaatintutkielmassa käsitellään koneoppimisalgoritmien hyödyntämistä metsä- ja maastopalojen havaitsemiseen droneilmakuvista. Tutkielma on kirjallisuuskatsaus, ja sen tavoitteena on pohtia, kuinka toimiva ratkaisu koneoppiminen tässä käyttökohteessa on. Kirjallisuuskatsauksen perusteella koneoppimisen käyttö palojen havaitsemiseen droneilmakuvista on mahdollisesti tulevaisuudessa toimiva keino ehkäistä palojen leviämistä, mutta tällä hetkellä teknologian kehittämisessä on vielä paljon haasteita ratkaistavana.

Avainsanat: metsäpalo, maastopalo, palontunnistus, drone, koneoppiminen, optinen kaukokartoitus

Abstract: This bachelor's thesis discusses the use of machine learning algorithms in detecting forest fires and wild fires from drone aerial imagery. The thesis is a literature review, and it aims to discuss the application and functionality of machine learning in this field. The literature review finds the use of machine learning in detecting fires from drone imagery a possible solution in the future to prevent or slow down the spread of the fire, but at the moment the development of this technology still faces a lot of challenges.

Keywords: forest fire, wild fire, fire detection, UAV, drone, machine learning, optical remote sensing

Sisällys

1	JOHDANTO	1
2	METSÄ- JA MAASTOPALOJEN HAVAITSEMINEN NYKYKEINAIN	3
	2.1 Tähystystornit ja kamerat	3
	2.2 Tähystyslennot	3
	2.3 Satelliitit	4
	2.4 Dronet.....	5
3	KONEOPPIMINEN HAHMON- JA PALONTUNNISTUKSESSA	6
	3.1 Koneoppiminen.....	6
	3.2 Palontunnistus koneoppimisen avulla	7
4	KONEOPPIMISEN HYÖDYNTÄMINEN METSÄ- JA MAASTOPALOJEN HA- VAITSEMISESSA DRONEILMAKUVISTA.....	9
	4.1 Vahvuudet ja lupaavat tutkimustulokset.....	9
	4.2 Haasteet	10
	4.3 Materiaali koneoppimista varten	11
5	YHTEENVETO.....	14
	LÄHTEET	15

1 Johdanto

Sään ääri-ilmiöt, kuten äärimmäinen kuumuus ja kuivuus ovat ilmastomuutoksen myötä yleistymässä. Kuumuuden ja kuivuuden myötä myös metsä- ja maastopalojen syttymisen riski kasvaa huomattavasti, mikä aiheuttaa suuren vaaran sekä ihmisille, omaisuudelle että ympäristölle. Laajalle levinneen palon sammutuksesta ja sen jälkeisestä uudelleenrakentamisesta syntyy usein valtavat kustannukset, eikä palon tuhoama luonto palaa entiselleen vuosikymmeniin.

Metsä- ja maastopalojen varhainen havaitseminen on siis hyvin tärkeää näiden vahinkojen ja kustannusten ehkäisemiseksi. Valitettavasti varsinkin asumattomilla ja hankalakulkuisilla alueilla alkavat palot jäävät kuitenkin usein huomaamatta, kunnes palo on jo kasvanut ja levinnyt huomattavasti, ja siitä aiheutuva savupatsas ulottuu kymmenien metrien korkeuteen. Nykyiset palonhavitsemiskeinot perustuvatkin juuri tämän savupatsaan havaitsemiseen, mikä tarkoittaa, että palon täytyykin kasvaa suureksi, ennen kuin esimerkiksi satelliitti tai kilometrien päässä oleva tähystäjä voi sen havaita.

Yksi mahdollinen ratkaisu ovat dronet eli miehittämättömät ilma-alukset (engl. UAV, *Unmanned Aerial Vehicle*). Dronet luokitellaan usein kiinteäsiipisiin eli lennokkityypisiin (engl. *fixed-wing*) ja pyöriväsiipisiin eli kopterimaisiin (engl. *rotary-wing*). Ne ovat ketteriä, kevyitä ja muihin ratkaisuihin verrattuna halpoja ja pystyvät seuraamaan paloa hyvinkin läheltä aiheuttamatta vaaraa ihmisille. Droneen sijoitetun kameran kuvaamasta kuvamateriaalista voidaan koneoppimista hyödyntäen tunnistaa metsä- ja maastopaloja ja näin säästää henkilötyötunteja ja muita resursseja. Koneoppimisalgoritmin avulla tietokoneen olisi tarkoitus oppia tunnistamaan metsäpalon tyypilliset visuaaliset piirteet kuten liekit ja savu. Uusi teknologia voi tarjota uuden tehokkaan tavan havaita metsä- ja maastopaloja ajoissa, mutta sen käytännön toteutuksessa on vielä paljon haasteita.

Tämän kandidaatintutkielman on tarkoitus selvittää, millä tavoilla metsä- ja maastopaloja voidaan tunnistaa dronella otetuista ilmakuvista koneoppimista hyödyntäen. Lisäksi tutkielmassa pohditaan, mitkä ovat näiden metodien vahvuudet ja haasteet. Tutkielma keskittyy enemmän koneoppimiseen kuin droneteknologiaan, kuten reititykseen tai parviälyyn. Ensin

käydään läpi nykyään eniten käytettyjä palonhavaitsemiskeinoja, jotta saadaan kuva, minkälaisiin ongelmiin droneteknologian odotetaan tuovan ratkaisuja (luku 2). Tämän jälkeen kerrotaan koneoppimisteknologiasta yleisesti sekä palontunnistuksen näkökulmasta (luku 3). Lopuksi vielä pohditaan, mitkä ovat koneoppimisteknologian ja dronejen yhdistämisen vahvuudet ja haasteet, sekä kerrotaan yhdestä suurimmiksi osoittautuneista ongelmista tämän koneoppimisteknologian kehittämisessä eli koulutusdatan puutteesta (luku 4).

2 Metsä- ja maastopalojen havaitseminen nykykeinoin

Suuri osa metsä- ja maastopaloista asutuilla seuduilla tulee viranomaisten tietoon yleisohavaintojen perusteella. Alueilla, joissa tulipalon riski ja tulipalon mahdollisesti aiheuttamien vahinkojen suuruus on merkittävä, on kuitenkin vuoden kuivimpina ja kuumimpina kausina valvottava tilannetta, jottei se pääsisi karkaamaan käsistä. Tässä kappaleessa käsitellään nykypäivänä käytettäviä metsä- ja maastopalojen havaitsemiskeinoja yleisesti.

2.1 Tähystystornit ja kamerat

Tähystystornit ovat vanha ja jo osin käytöstä poistunut tapa havaita metsäpaloja. Ne ovat kriittisille syrjäisille alueille korkealle paikalle sijoitettuja torneja, joista on kilometrien näkyvyys ympäröivään maastoon. Torneissa on usein pieni asuttava huone sekä paikannus- ja kommunikaatiovälineet metsäpalon varalle (”Fire lookout tower — Wikipedia” 2023). Tähystystornien heikkous kuitenkin on rajattu näkyvyys ja korkeat rakennuskustannukset. Tuuli myös pahimmassa tapauksessa saattaa tuhota itse tornin, mikä aiheuttaa lisäkustannuksia (Bouguettaya ym. 2022).

Torneihin tai pylväisiin kiinnitettävät kamerat ja muut sensorit ovat osittain korvanneet tähystystornit. Kamerat vaativat asennuksen jälkeen vain vähän huoltoa ja vievät vähän energiaa, mutta voivat silti helposti havaita savua yli 50 kilometrin päästä (Govil ym. 2020). Kamerapylväidenkin ongelmana on kuitenkin se, että ne ovat kiinni maassa. Kaikkialla ei ole tarpeeksi korkeita paikkoja kamerapylväille, jotta saataisiin koko alueen kattava näkyvyys, tai jos maasto on todella epätasaista, aiheuttavat mäet ja kukkulat sokeita pisteitä.

2.2 Tähystyslennot

Tähystyslentoja ei varsinaisesti käytetä metsäpalojen havaitsemiseen, vaan tilanteen seuraamiseen ja tarkastamiseen. Esimerkiksi savuhavainnon yhteydessä saatetaan käyttää suuren metsäalueen tarkastamisen nopeuttamiseksi helikopteria. Myös palon aikana sammuttamiseen ja palon leviämisen seuraamiseen käytetään lentokoneita ja helikoptereita. Tähystys-

lentojen hyöty on, että paikalle saadaan suhteellisen nopeasti ihmissilmiä tilanteen arvioimiseksi. Toisaalta helikopteri- ja lentokonelennot ovat kalliita, ja metsäpalon tapauksessa saattavat asettaa lentäjän ja muun miehistön hengen ja terveyden vaaraan.

2.3 Satelliitit

Satelliitteja pidetään käytetyimpänä metsäpalojen etätunnistusmenetelmänä (Bouguettaya ym. 2022). Satelliittien hyöty on, että niiden avulla voidaan havaita paloja asumattomilta ja vaikeakulkuisiltakin alueilta. Satelliiteilla pyritään havaitsemaan metsäpalosta aiheutuva savupatsas.

Satelliitteja on monen tyyppisiä, kuten geostationaarisia (engl. GEO, *Geostationary Earth Orbit*) ja matalan maan kiertoradan satelliitteja (engl. LEO, *Low Earth Orbit*). GEO-satelliitit kiertävät maapalloa päiväntasaajalla kerran vuorokaudessa noin 35 786 kilometrin etäisyydellä, mikä tarkoittaa että ne kiertävät maapalloa samalla nopeudella kuin maapallo pyörii akselinsa ympäri. LEO-satelliitit taas kiertävät maapalloa alle 2000 kilometrin etäisyydellä ja kiertävät näin maapallon useamman kerran päivässä. GEO-satelliittien hyöty on, että ne tarkkailevat samaa kohtaa maapallosta jatkuvasti, eli niillä on korkea ajallinen resoluutio ja voivat näin havaita metsäpalon mahdollisimman aikaisin. LEO-satelliiteilla, joiden paikka suhteessa maapalloon vaihtuu jatkuvasti, ajallinen resoluutio on matala, eli ne käyvät saman alueen yläpuolella vain muutaman kerran päivässä. Toisaalta taas LEO-satelliittien spatiaalinen resoluutio on korkea, eli niiden ottama kuvamateriaali on tarkempaa, sillä ne kiertävät maapalloa suhteellisen pienellä etäisyydellä. GEO-satelliittien spatiaalinen resoluutio on matala, eli ne eivät etäisyytensä takia voi havaita yhtä pieniä kohteita kuin LEO-satelliitit (Bouguettaya ym. 2022), (Govil ym. 2020).

Satelliittien ongelmaksi koituu siis joko spatiaalinen tai ajallinen resoluutio. Lisäksi huonot sääolosuhteet, kuten pilvet tai myrskyt, voivat heikentää tunnistusherkkyyttä haittaamalla näkyvyyttä. Satelliitit, niiden asettaminen kiertoradalle ja niissä käytettävät huipputarkat kamerat ovat myös ymmärrettävästi hyvin kalliita (Bouguettaya ym. 2022), (Zhao ym. 2018). Govil:n ym. (2020) mukaan maan kiertoradalla ei tällä hetkellä olekaan yhtäkään satelliittia juuri metsä- ja maastopalojen nopeaa havaitsemista varten.

2.4 Dronet

Dronet ovat metsä- ja maastopalojen havaitsemisessa suhteellisen uusi työkalu, mutta niiden käyttö teoriassa ratkaisee aikaisemmin mainittujen palontunnistusmetodien ongelmia: Verrattuna tähystystorneihin ja kamerapylväisiin dronejen vahvuus on liikkuvuus. Niillä voidaan sujuvasti valvoa suuriakin alueita ja havaita savua aikaisemmin kuin tähystystornista tai kamerapylvästä (Barmpoutis, Papaioannou ym. 2020). Palojen varhainen havaitseminen on erityisen tärkeää palon hallintaan saamisen kannalta (Hossain, Zhang ja Tonima 2020). Dronejen vahvuus verrattuna helikoptereihin taas on miehittämättömyys, ketteryys ja pieni koko. Koska dronen kyydissä ei ole lentäjää, ei suurienkaan palojen valvomisessa vaarannu lentäjän henki (Barmpoutis, Papaioannou ym. 2020). Helikoptereihin verrattuna dronet ovat myös kevyitä, minkä takia ne vievät joko huomattavasti vähemmän polttoainetta tai toimivat kokonaan sähköllä. Satelliitteihin verrattuna vahvuudeksi nousee hinta. Sekä itse drone että droneen kiinnitettävät kamerat ovat huomattavasti satelliitteja ja niiden mukana olevia mittalaitteita halvempia. Dronet valvovat alueita huomattavasti satelliitteja lähempää, joten niiden kyydissä olevien kameroiden ei tarvitse olla huipputarkkoja, toisin kuin satelliitin.

3 Koneoppiminen hahmon- ja palontunnistuksessa

Tässä kappaleessa kerrotaan koneoppimisen hyödyntämisestä hahmon- ja erityisesti palontunnistuksessa. Kappaleessa 3.1 kerrotaan koneoppimisesta ja hahmontunnistuksesta yleisluontoisesti, minkä jälkeen kappaleessa 3.2 käsitellään hahmontunnistusta koneoppimisen avulla käyttäen palontunnistusta esimerkkinä.

3.1 Koneoppiminen

Koneoppiminen on tekoälyn osa-alue, jonka avulla tietokoneet voivat niille annetun datan avulla oppia tekemään päätöksiä (Alexandrov ym. 2019). Koneoppiminen jaetaan usein kolmeen kategoriaan: ohjattu oppiminen, ohjaamaton oppiminen ja vahvistusoppiminen. Ohjatussa oppimisessa annettu data ja haluttu oppimistulos tunnetaan ennalta, kun taas ohjaamattomassa oppimisessä ei ole mitään tiettyä tulosta, johon algoritmin halutaan päätyvän, eikä dataa ole tutkittu tarkkaan. Ohjaamaton oppiminen on vähän kuin ihmisen suhtautuminen ympäristöönsä: algoritmi tutkii annettua dataa ja alkaa vähitellen hahmottaa korrelaatioita eri asioiden välillä. Vahvistusoppiminen on lähellä ohjaamatonta oppimista, mutta siinä algoritmille annetaan jokin päämäärä, ja sen oppimista valvotaan. Algoritmin tekemiä päätöksiä ja ratkaisuja arvioidaan sen perusteella, kuinka hyviä tai haluttuja ne ovat.

Yksi koneoppimisen käyttökohde on hahmontunnistus. Hahmontunnistuksessa algoritmi opettelee tunnistamaan jonkin tietyn asian, esimerkiksi tulipalon, ominaispiirteitä datasta, kuten kuvista tai videosta. Koneoppiminen vaatii oppiakseen valtavasti materiaalia, kuvista tunnistettaessa vähintään useita satoja kuvia. Tuhannetkaan kuvat eivät ole liioittelua, sillä yleensä mitä enemmän oppimismateriaalia on, sitä paremmin algoritmi oppii. Lisäksi ajan kuluessa, kun kuvamateriaalia kertyy lisää, on hyvä käyttää tätä uutta aineistoa algoritmin tarkentamiseen.

Tätä kuvamateriaalia kutsutaan datajoukoksi (engl. *dataset*). Datajoukko jaetaan usein osiin sen mukaan, käytetäänkö kuvia koneoppimisalgoritmin koulutukseen vai sen testaamiseen. Kuvamateriaalin on oltava mahdollisimman monipuolista ja mielellään sisällettävä myös negatiivisia esimerkkikuvia, jotta oppimistulos on tarpeeksi tarkka. Negatiivisella kuvalla tar-

koitetaan kuvaa, jossa tunnistettavaa asiaa, esimerkiksi tulipaloa, ei esiinny. Näin algoritmi ei ainoastaan opi, mikä on tulipalo, vaan myös, mikä ei ole tulipalo. Esimerkkinä Park ym. (2020) tekemä tutkimus: Ongelmaksi ilmeni, ettei koulutuskuviissa ollut mitään ”epäluonnollisia” objekteja kuten teitä, rakennuksia tai muuta infrastruktuuria. Tällöin algoritmi ei kyennyt tunnistamaan näitä asioita, vaan se merkitsi esimerkiksi kuvan reunassa näkyvän kasvihuoneen tulipaloksi.

3.2 Palontunnistus koneoppimisen avulla

Tulipaloja, olivat ne sitten rakennus-, maasto- tai metsäpaloja, voidaan tunnistaa koneoppimisen avulla hyödyntäen tulipalon kahta tärkeintä piirrettä: liekkejä ja savua (Bouguettaya ym. 2022), (Gaur ym. 2020). Liekit ja savu ovat piirteitä, jotka esiintyvät säännöllisesti tulipaloissa. Ihmissilmälläkin havaittaessa palot yleensä havaitaan näiden piirteiden perusteella, joten on järkevää opettaa koneoppimisalgoritmi tunnistamaan kuvista tai videosta liekkejä ja savua.

Liekkien tunnistamisessa on etuna liekkien väri ja kirkkaus: Kirkkaat punaisen, oranssin ja keltaisen sävyt erottuvat hyvin ympäristöstä, etenkin havumetsässä sekä keväisessä ja kesäisessä lehtimetsässä. Liekkejä on myös mahdollista havaita pimeässä, toisin kuin savua.

Toisaalta esimerkiksi Khanin ym. (2022) tutkimuksessa eräs koneoppimisalgoritmi sekoitti liekit esimerkiksi auringonnousuun tai -laskuun, erilaisiin heijastuksiin ja ruskan kirkkaisuun sävyihin metsässä. Liekkienkaltaiset ja -väriset asiat siis herkästi hämäävät algoritmeja ja aiheuttavat vääriä positiivisia tuloksia. Liekkientunnistuksen yksi huomattava heikkous on myös, että alkavissa tulipaloissa ei aina ole havaittavissa liekkejä, tai ne jäävät paksun savun tai ilmasta katsottaessa puiden latvuston peittoon, jolloin paloa ei voi havaita liekkien perusteella (Hossain, Zhang ja Tonima 2020), (Harjoko ym. 2022). Tämän vuoksi liekkientunnistuksen on todettu olevan varsinkin alkavien palojen tapauksessa epäluotettava palontunnistuskeino (Bouguettaya ym. 2022), sillä näkyvät liekit usein tarkoittavatkin jo laajalle levinnyttä paloa.

Toinen selkeä piirre tulipaloissa on savu. Savuntunnistuksen etu on, että vanhan sanonnankin mukaan ei savua ilman tulta, eli alkava tai kyteväkin palo savuttaa, vaikkei liekkejä vielä oli-

si. Tällöin on tärkeää, että savu tulee havaituksi, sillä kyteväkin palo usein leviää ja roihauttaa myöhemmin. Savu myös levitessään nousee korkealle latvustojen yläpuolelle ja näkyy näin kilometrienkin päähän, mikä nopeuttaa autioiden ja hankalakulkuisten seutujen tulipalojen havaitsemista (Bouguettaya ym. 2022).

Savuntunnistuksen heikkoudeksi usein muodostuu savun epämääräinen ja joskus myös läpi-kuultava olomuoto (Hossain, Zhang ja Tonima 2020). Algoritmilla on hyvin usein vaikeuksia erottaa savua esimerkiksi sumusta tai pilvistä (Guede-Fernández ym. 2021), (Rahman ym. 2021), jossain tapauksissa jopa paljaasta harmaasta kalliosta (Zhan ym. 2021). Savun väri myös vaihtelee lähes valkoisesta ruskeaan ja lähes mustaan, mikä saattaa hankaloittaa tunnistamista, koska valkoista savua voi olla hankalaa erottaa pilvistä tai ruskeaa savua muusta maastosta (Hossain ym. 2019). Toinen savuntunnistuksen heikkous on, että savua on hyvin vaikeaa havaita pimeässä ilman muita sensoreita kuten infrapunakameraa (Zhan ym. 2021).

Koska kummallakin palontunnistusmenetelmällä on puolensa, yksi hyvä vaihtoehto on etsiä kuvista sekä liekkejä että savua. Tutkimuksessaan Hossain ym. (2019) toteavat, että useiden paloindikaattorien, eli sekä liekkien että savun, etsiminen helpottaa palon havaitsemista mahdollisimman aikaisin, tekee valaistuksen ja muiden olosuhteiden muutoksista siedettävämpiä järjestelmälle ja mahdollistaa palonhavaitsemisen sekä päivällä että yöllä. Savua voidaan myös käyttää indikaattorina alkavasta palosta: Gaur ym. (2020) mukaan yksi toimiva tapa on ensin etsiä savua ja savua havaittaessa varmistaa palo etsimällä liekkejä.

4 Koneoppimisen hyödyntäminen metsä- ja maastopalojen havaitsemisessa droneilmakuvista

Tässä kappaleessa käsitellään koneoppimisen hyödyntämistä palojen havaitsemisessa droneilmakuvista. Ensin käsitellään metodin vahvuuksia ja lupaavia tutkimustuloksia. Seuraavaksi pohditaan metodin kehittämisessä ilmenneitä haasteita ja kehityskohteita, ja lopuksi selvitetään, miten koneoppimisen vaatimaa materiaalia on hankittu ja minkälaisia haasteita sen hankkimisessa on ilmennyt.

4.1 Vahvuudet ja lupaavat tutkimustulokset

Koneoppimisen ja droneteknologian hyödyntäminen metsä- ja maastopalojen havaitsemiseen perustuu seuraavaan toimintamalliin: Automaattisesti ohjautuvaan droneen on kiinnitetty kamera, joka lähettää kuvamateriaalia tietokoneelle. Samaan aikaan tietokone käy reaaliajassa koneoppimisalgoritmia hyödyntäen kuvamateriaalia läpi. Tietokone antaa varoituksen, jos se havaitsee alkavan tai käynnissä olevan palon.

Koneoppimistekoälyn käyttämisessä metsä- ja maastopalojen automaattiseen havaitsemiseen tärkeimpänä vahvuutena on, ettei palojen havaitsemiseen tarvita ihmisiä tarkkailemaan maastoa kellon ympäri. Ihmisten huomiokyky heikkenee pitkäveiteistä monotonista työtä tehdessä (Govil ym. 2020), mikä kasvattaa riskiä palon syttymiselle ja voimakkaalle leviämislle ennen kuin se havaitaan. Konenäkö tunnistaa palot luotettavammin kuin ihminen (YAN-DOUZI ym. 2022).

Monissa tutkimuksissa, kuten Barmpoutis, Stathaki ym. (2020), Wang ym. (2021) ja YAN-DOUZI ym. (2022), palontunnistustarkkuus on lupaava, jopa yli 90 %. Näitä testituloksia tarkastellessa täytyy kuitenkin pitää mielessä, että koneoppimisalgoritmit on testattu eri datajoukolla, eli tunnistustarkkuudet ovat enemmänkin suuntaa antavia. Tarkkuusprosentteja ei voi siis suoraan vertailla keskenään.

Lupaavana esimerkkinä koneoppimisalgoritmien käytön vahvuudesta on Govil:n ym. (2020) tekemä tutkimus: He ovat kehittäneet koneoppimiseen perustuvan järjestelmän, joka kiin-

teässä havainnointipaikassa olevan kameran avulla tunnistaa maastopaloista nousevan savun 15 minuutin sisällä palon syttymisestä. Järjestelmä on ollut toiminnassa Etelä-Kaliforniassa ympäri vuorokauden, ja se on jo onnistunut havaitsemaan maastopaloja nopeammin kuin esimerkiksi GEO-satelliitit. Järjestelmän kerrotaan myös antavan vääriä positiivisia havaintoja vain alle kerran vuorokaudessa. Koneoppimisjärjestelmää testattiin arkistokuvamateriaalilla Etelä-Kaliforniasta vuoden 2018 *Holy Fire* -tulipalosta, joka roihusi yli kuukauden tuhoten noin 92 km^2 maastoa ja 18 rakennusta (“Holy Fire (2018) — Wikipedia” 2023). Kuvamateriaalissa palosta nouseva savu on havaittavissa ensimmäistä kertaa 6.8.2018 kello 13:05, ja ensimmäinen soitto hätäkeskukseen on tallennettu kello 13:17. Testeissä Govil:n ym. (2020) koneoppimisjärjestelmä havaitsi palon kuvasta, joka oli otettu kahdeksan minuuttia ennen ensimmäistä soittoa hätäkeskukseen, eli kello 13:09. Todellisessa tilanteessa järjestelmä olisi voinut siis säästää kahdeksan minuuttia aikaa ja näin mahdollisesti hidastaa palon leviämistä. Alun perin palo myös varmennettiin ja merkittiin alkaneeksi vasta kello 13:20, sillä sen paikantaminen vei aikaa. Koneoppimisjärjestelmä olisi mahdollisesti voinut lyhentää tätäkin viivettä, sillä kameran sijainnista ja suuntauksesta voitaisiin päätellä palon sijainti (Govil ym. 2020). Govil ym. (2020) toteavatkin järjestelmänsä olevan optimaalisissa olosuhteissa tehokkaampi kuin mikään muu heidän tiedossaan oleva automaattinen palontunnistusjärjestelmä.

Yhdistettynä muihin palonhavaitsemiskeinoihin, kuten satelliitteihin, Govil:n ym. (2020) kehittämän koneoppimisjärjestelmän tyypiset ratkaisut voisivat osoittautua hyvinkin tehokkaiksi tavoiksi ehkäistä metsä- ja maastopalojen leviämisen aiheuttamia vahinkoja. Dronen ja konenäön yhdistelmässä on sekin hyvä puoli, että niiden avulla palon sijainnin määrittäminen helpottuu (Sarkar ym. 2021).

4.2 Haasteet

Palontunnistuksessa koneoppimisen ja dronejen avulla on myös heikkoutensa. Sääolosuhteet vaikuttavat droneen enemmän kuin esimerkiksi kiinteässä pylväässä olevaan kameraan (Barmpoutis, Papaioannou ym. 2020). Voimakas tuuli tai sade saattaa aiheuttaa dronen epävakautta, jolloin kuvista tulee epätarkkoja. Myös dronen moottori ja liike voivat aiheuttaa jonkinlaista epätarkkuutta kuvamateriaaliin (Tian ym. 2017), eli saatetaan tarvita erikseen

laitteistoa ja ohjelmistoa vakauttamaan kuvia (Yuan, Zhang ja Liu 2015). Lisäksi metsä- tai maastopaloista nouseva kuumuus saa ilmassa aikaan pyörteitä. Itse palokin saattaa siis aiheuttaa dronen epävakautta. Ongelmana koneoppimisalgoritmin kehittämisessä on myös se, että kuten jo osiossa 4.1 todettiin, ei ole vielä olemassa yhtä tiettyä hyvää datajoukkoa algoritmien testaamiseen, mikä tarkoittaa ettei algoritmeja voida vertailla keskenään luotettavasti (Aslan ym. 2020). Ei voida siis varmasti sanoa, mitkä algoritmit toimivat parhaiten.

Toisaalta myös riippuu täysin koneoppimisalgoritmin koulutukseen käytetystä datajoukosta, missä ympäristössä algoritmi edes toimii. Esimerkiksi jos datajoukossa on kuvia vain havumetsien metsäpaloista, ei algoritmi todennäköisesti tule tunnistamaan heinikkopaloja. Zhanin ym. (2021) tutkimuksessa osa palokuvista oli otettu maasta käsin, eli kuvien näkökulma oli väärä, sillä algoritmin oli tarkoitus oppia tunnistamaan metsäpaloja ilmakuvista. Tämä aiheutti hankaluuksia koneoppimisalgoritmin kanssa. Jiao ym. (2019) totesivat tutkimuksessaan, että alkamassa olevista metsä- ja maastopaloista ei ole saatavilla tarpeeksi kuvia. Tämän vuoksi heidän tutkimuksessaan ilmeni, että algoritmi keskittyy tunnistamaan suuria paloja, muttei havaitse pienempiä, alkamassa olevia paloja. Juuri alkamassa olevien palojen havaitseminen olisi tärkeää, jotta sammutustyöt voitaisiin aloittaa ennen tilanteen riistäytymistä käsistä. Guede-Fernandesilla ym. (2021) oli samankaltaisia havaintoja alkavien metsä- ja maastopalojen havaitsemisesta. Wangin ym. (2021) mukaan jos datajoukossa on vain savuja/tai liekkikuvia, tunnistustarkkuus heikkenee, sillä algoritmi ei opi erottamaan liekkejä ja savua muista niiden kaltaisista objekteista.

Palontunnistus droneilmakuvista koneoppimisalgoritmien avulla on loppujen lopuksi kuitenkin alkutekijöissään. Vaikka haasteita on paljon, ei se vielä tarkoita, etteikö tällaista automaattista järjestelmää joskus saataisi kehitettyä käyttökuntoon.

4.3 Materiaali koneoppimista varten

Yksi suuri haaste koneoppimisalgoritmien koulutuksessa metsä- ja maastopalojen havaitsemiseen on, että tällä hetkellä ei ole vielä olemassa monta vapaasti saatavilla olevaa datajoukkoa tekoälyn kouluttamiseen palontunnistukseen (Hossain, Zhang ja Tonima 2020), (Treneska ja Stojkoska 2021). Varsinkaan drone- tai muuta ilmakuvamateriaalia metsä- ja

maastopaloista ei ole saatu kerättyä juuri ollenkaan kuin vasta viime vuosina (Bouguettaya ym. 2022). Materiaalin hankkimista ymmärrettävästi vaikeuttaa metsä- ja maastopalojen tapauksessa se, että paloja ei voi vain sytyttää, kun on tarve lisämateriaalille, eikä jo syttyneistä paloista ole helppo saada kuvia niiden vaarallisuuden takia. Paloja myös harvoin havaitaan aivan syttymisvaiheessa, josta juuri olisi tarvetta saada kuvamateriaalia, kuten osiossa 4.2 mainittiin.

Eri tutkimusryhmillä on ollut erilaisia tapoja hankkia tarvittavaa materiaalia algoritmiensa koulutukseen ja testaamiseen: Jotkin tutkimusryhmät, kuten Chen ym. (2019), ovat dronen avulla itse kuvanneet materiaalia metsäpaloista koneoppimisalgoritmin koulutukseen. Myös internetistä, esimerkiksi Googlestä, Pixabaystä, YouTubeista ym., on etsitty ja kasattu ilma-kuvia metsä- ja maastopaloista, kuten Hossain, Zhang ja Tonima (2020) ovat tehneet. Tässä kuvamateriaalin hankkimistavassa hyötynä on, että kuvat ovat hyvin erilaisia, mikä auttaa tekemään tekoälystä tarkemman. Ongelmana tosin usein on, että kuvat ovat eri kokoisia ja vaihtelevat laadultaan, minkä takia niitä usein joudutaan rajaamaan ja muokkaamaan itse. Jotkin tutkimusryhmät, kuten Nguyen ym. (2021) ja Zhan ym. (2022) taas ovat keränneet ja yhdistelleet muiden tutkimusryhmien keräämiä materiaaleja saadakseen mahdollisimman monipuolista oppimismateriaalia. Lisäksi ehkä hieman uudempana metodina on luotu synteettisiä metsäpalokuvia muokkaamalla metsäkuviin savupatsaita, kuten Zhang ym. (2018) ovat tehneet. Synteettiset metsä- ja maastopalokuvat ratkaisevat materiaalin hankkimisongelmat, mutta kuvien luominen käsin käyttämällä kuvankäsittelyohjelmia on hyvin työlästä, ja kuvien generointi algoritmien avulla virhealtista. Algoritmit voivat nimittäin tuottaa silloin tällöin epärealistisia kuvia tai kuvia, joissa ei näytä olevan savua ollenkaan, koska algoritmi on esimerkiksi sijoittanut vaalean savupatsaan harmaata taivasta vasten. Tällöin koneoppimisalgoritmi saa tiedon, että kuvassa on savua, muttei voi sitä havaita, mikä voi pitemmän päälle aiheuttaa ongelmia, jos tällaisia kuvia on paljon.

Viime vuosina on kuitenkin luotu lisää datajoukkoja erilaisista dronemateriaaleista juuri metsä- ja maastopalojen havaitsemista varten. Esimerkkejä näistä ovat muun muassa *Deep-Fire dataset* (Khan ym. 2022), *FLAME dataset* (Shamsoshoara ym. 2021) ja *Fire detection 360-degree dataset* (Barmpoutis, Stathaki ym. 2020). FLAME-datajoukko on ollut näistä suosituin, mutta se on saanut kritiikkiä, että vaikka kuvat ovat hyvälaatuisia ja materiaalia on

paljon, kuvat on kuitenkin kaikki otettu hyvin samankaltaisissa ympäristöissä. Tämä yksipuolisuus saattaa algoritmin koulutuksessa aiheuttaa ongelman, jossa algoritmi osaa tunnistaa palot vain kuvista, joissa ympäristö on samankaltainen kuin koulutuskuviissa. Ongelma on kuitenkin saatu ratkaistua käyttämällä tutkimuksissa yhdistelmiä eri datajoukoista, jolloin saadaan vaihtelua kuvamateriaaliin. Voisi kuitenkin jopa sanoa, että datanpuute hidastaa koneoppimisalgoritmien kehitystä, kun tutkimuksissa joudutaan käyttämään aikaa itse datajoukkojen luomiseen.

Yksi hyvä mahdollisuus saada uutta kuvamateriaalia metsä- ja maastopaloista voisivat olla kulotukset: Kulotuksia käytetään maa- ja metsätaloudessa muun muassa hallitsemattomien metsäpalojen ehkäisemiseen ja metsän uudistamiseen. Kulotuksessa metsän pohjalla kasvaava kasvillisuus ja mahdolliset hakkuujätteet sytytetään hallitusti palamaan. Paloalue on rajattu palokujilla, ja alueen rajoilla on valmiudessa sammuttajia. Kulotuksen jälkeen tehdään vielä jälkisammutus. Kulotukset voisivat siis olla hyvä tilaisuus turvallisesti hankkia lisää mahdollisimman realistista kuvamateriaalia koneoppimisalgoritmien koulutusta varten. Tällöin olisi mahdollista saada kuvamateriaalia myös alkavista metsäpaloista, mikä parantaisi algoritmien mahdollisuutta tunnistaa palo jo sen ensivaiheissa.

5 Yhteenveto

Koneoppimista voidaan hyödyntää metsä- ja maastopalojen havaitsemisessa droneilmakuvista etsimällä niistä liekkejä ja/tai savua. Liekkien ja savun visuaaliset ominaisuudet ovat keskenään erilaiset ja vaihtelevat olosuhteiden mukaan, ja kummankin tunnistamisessa on omat haasteensa. Sekä savun- että liekintunnistuksessa suurin haasteita aiheuttava tekijä vaikuttaisi kuitenkin olevan tarpeeksi monipuolisen koulutusdatan puute. Sekä drone- että koneoppimisteknologia ovat vielä pitkälti kehitysvaiheessa, joten näihinkin haasteisiin ollaan kehittämässä ratkaisuja. Hyvin lupaaviakin tutkimustuloksia on jo saatu. Suomessa esimerkiksi FireMan-konsortio pyrkii kehittämään tällaista droneihin ja tekoälyyn pohjautuvaa teknologiaa (“FireMan” 2023).

Tekemäni kirjallisuuskatsauksen perusteella uskon, että menee vielä vuosia, jos ei vuosikymmeniä, ennen kuin tällaista automaattista teknologiaa saadaan kunnolla käyttöön. Järjestelmän kustannuksia ei myöskään vielä tiedetä, joten vielä ei voida edes sanoa, olisiko tällainen järjestelmä kustannuksiltaan järkevä.

Kirjallisuuskatsaus sopii hyvin aiheeseen perehtymiseen, sillä aiheen varsinainen tutkiminen vaatisi muun muassa algoritmien kehittämistä ja testaamista sekä koelentoja. Nämä eivät tietenkään kandidaatintutkielman mittakaavassa ole mahdollisia, mutta jo kirjallisuuskatsauksella saa hyvän kuvan, missä vaiheessa teknologian kehitys on.

Lähteet

Alexandrov, Dmitriy, Elizaveta Pertseva, Ivan Berman, Igor Pantiukhin ja Aleksandr Kapitov. 2019. “Analysis of machine learning methods for wildfire security monitoring with an unmanned aerial vehicles”. Teoksessa *2019 24th conference of open innovations association (FRUCT)*, 3–9. IEEE.

Aslan, Süleyman, Uğur Güdükbay, B Uğur Töreyn ja A Enis Çetin. 2020. “Deep convolutional generative adversarial networks for flame detection in video”. Teoksessa *International Conference on Computational Collective Intelligence*, 807–815. Springer.

Barmpoutis, Panagiotis, Periklis Papaioannou, Kosmas Dimitropoulos ja Nikos Grammalidis. 2020. “A review on early forest fire detection systems using optical remote sensing”. *Sensors* 20 (22): 6442.

Barmpoutis, Panagiotis, Tania Stathaki, Kosmas Dimitropoulos ja Nikos Grammalidis. 2020. “Early fire detection based on aerial 360-degree sensors, deep convolution neural networks and exploitation of fire dynamic textures”. *Remote Sensing* 12 (19): 3177.

Bouguettaya, Abdelmalek, Hafed Zarzour, Amine Mohammed Taberkit ja Ahmed Kechida. 2022. “A review on early wildfire detection from unmanned aerial vehicles using deep learning-based computer vision algorithms”. *Signal Processing* 190:108309.

Chen, Yanhong, Youmin Zhang, Jing Xin, Guangyi Wang, Lingxia Mu, Yingmin Yi, Han Liu ja Ding Liu. 2019. “UAV image-based forest fire detection approach using convolutional neural network”. Teoksessa *2019 14th IEEE conference on industrial electronics and applications (ICIEA)*, 2118–2123. IEEE.

“Fire lookout tower — Wikipedia”. 2023. Viitattu 27. helmikuuta 2023. https://en.wikipedia.org/wiki/Fire_lookout_tower.

“FireMan”. 2023. Viitattu 16. huhtikuuta 2023. <https://www.maanmittauslaitos.fi/tutkimus/fireman>.

- Gaur, Anshul, Abhishek Singh, Anuj Kumar, Ashok Kumar ja Kamal Kapoor. 2020. “Video flame and smoke based fire detection algorithms: A literature review”. *Fire technology* 56 (5): 1943–1980.
- Govil, Kinshuk, Morgan L Welch, J Timothy Ball ja Carlton R Pennypacker. 2020. “Preliminary results from a wildfire detection system using deep learning on remote camera images”. *Remote Sensing* 12 (1): 166.
- Guede-Fernández, Federico, Leonardo Martins, Rui Valente de Almeida, Hugo Gamboa ja Pedro Vieira. 2021. “A deep learning based object identification system for forest fire detection”. *Fire* 4 (4): 75.
- Harjoko, Agus, Andi Dharmawan, Faisal Dharma Adhinata, Gamma Kosala ja Kang-Hyun Jo. 2022. “Real-time forest fire detection framework based on artificial intelligence using color probability model and motion feature analysis”. *Fire* 5 (1): 23.
- “Holy Fire (2018) — Wikipedia”. 2023. Viitattu 5. huhtikuuta 2023. [https://en.wikipedia.org/wiki/Holy_Fire_\(2018\)](https://en.wikipedia.org/wiki/Holy_Fire_(2018)).
- Hossain, FM Anim, Youmin Zhang, Chi Yuan ja Chun-Yi Su. 2019. “Wildfire flame and smoke detection using static image features and artificial neural network”. Teoksessa *2019 1st international conference on industrial artificial intelligence (iai)*, 1–6. IEEE.
- Hossain, FM Anim, Youmin M Zhang ja Masuda Akter Tonima. 2020. “Forest fire flame and smoke detection from UAV-captured images using fire-specific color features and multi-color space local binary pattern”. *Journal of Unmanned Vehicle Systems* 8 (4): 285–309.
- Jiao, Zhentian, Youmin Zhang, Jing Xin, Lingxia Mu, Yingmin Yi, Han Liu ja Ding Liu. 2019. “A deep learning based forest fire detection approach using UAV and YOLOv3”. Teoksessa *2019 1st International conference on industrial artificial intelligence (IAI)*, 1–5. IEEE.
- Khan, Ali, Bilal Hassan, Somaiya Khan, Ramsha Ahmed ja Adnan Abuassba. 2022. “Deep-Fire: A Novel Dataset and Deep Transfer Learning Benchmark for Forest Fire Detection”. *Mobile Information Systems* 2022.

- Nguyen, AQ, HT Nguyen, VC Tran, Huy X Pham ja J Pestana. 2021. “A visual real-time fire detection using single shot multibox detector for uav-based fire surveillance”. Teoksessa *2020 IEEE Eighth International Conference on Communications and Electronics (ICCE)*, 338–343. IEEE.
- Park, Minsoo, Dai Quoc Tran, Daekyo Jung ja Seunghee Park. 2020. “Wildfire-detection method using DenseNet and CycleGAN data augmentation-based remote camera imagery”. *Remote Sensing* 12 (22): 3715.
- Rahman, Ehab Ur, Muhammad Asghar Khan, Fahad Algarni, Yihong Zhang, M Irfan Uddin, Insaf Ullah ja Hafiz Ishfaq Ahmad. 2021. “Computer vision-based wildfire smoke detection using UAVs”. *Mathematical problems in engineering* 2021:1–9.
- Sarkar, Mrinmoy, Xuyang Yan, Berat A Erol, Ioannis Raptis ja Abdollah Homaifar. 2021. “A novel search and survey technique for unmanned aerial systems in detecting and estimating the area for wildfires”. *Robotics and Autonomous Systems* 145:103848.
- Shamsoshoara, Alireza, Fatemeh Afghah, Abolfazl Razi, Liming Zheng, Peter Z Fulé ja Erik Blasch. 2021. “Aerial imagery pile burn detection using deep learning: The FLAME dataset”. *Computer Networks* 193:108001.
- Tian, Hongda, Wanqing Li, Philip O Ogunbona ja Lei Wang. 2017. “Detection and separation of smoke from single image frames”. *IEEE Transactions on Image Processing* 27 (3): 1164–1177.
- Treneska, Sandra, ja Biljana Risteska Stojkoska. 2021. “Wildfire detection from UAV collected images using transfer learning”. Teoksessa *Proceedings of the 18th International Conference on Informatics and Information Technologies, Skopje, North Macedonia*, 6–7.
- Wang, Shengying, Jing Zhao, Na Ta, Xiaoye Zhao, Mingxia Xiao ja Haicheng Wei. 2021. “A real-time deep learning forest fire monitoring algorithm based on an improved Pruned+KD model”. *Journal of Real-Time Image Processing* 18 (6): 2319–2329.

YANDOUZI, Mimoun, Mounir GRARI, Idriss IDRISSE, Mohammed BOUKABOUS, Omar MOUSSAOUI, Mostafa AZIZI, Kamal GHOUIMID ja Aissa KERKOUR ELMIAID. 2022. “Forest Fires Detection using Deep Transfer Learning”. *International Journal of Advanced Computer Science and Applications* 13 (8).

Yuan, Chi, Youmin Zhang ja Zhixiang Liu. 2015. “A survey on technologies for automatic forest fire monitoring, detection, and fighting using unmanned aerial vehicles and remote sensing techniques”. *Canadian journal of forest research* 45 (7): 783–792.

Zhan, Jialei, Yaowen Hu, Weiwei Cai, Guoxiong Zhou ja LiuJun Li. 2021. “PDAM–STPNNet: A small target detection approach for wildland fire smoke through remote sensing images”. *Symmetry* 13 (12): 2260.

Zhan, Jialei, Yaowen Hu, Guoxiong Zhou, Yanfeng Wang, Weiwei Cai ja LiuJun Li. 2022. “A high-precision forest fire smoke detection approach based on ARGNet”. *Computers and Electronics in Agriculture* 196:106874.

Zhang, Qi-xing, Gao-hua Lin, Yong-ming Zhang, Gao Xu ja Jin-jun Wang. 2018. “Wildland forest fire smoke detection based on faster R-CNN using synthetic smoke images”. *Procedia engineering* 211:441–446.

Zhao, Yi, Jiale Ma, Xiaohui Li ja Jie Zhang. 2018. “Saliency detection and deep learning-based wildfire identification in UAV imagery”. *Sensors* 18 (3): 712.