



**METSÄTUHOJA HAVAITSEVAN
TEKOÄLYSOVELLUKSEN TARKKUUDEN JA
KÄYTTÖKELPOISUUDEN KARTOITUS
KYMENLAAKSOSSA**

Nicolas Vollar

Opinnäytetyö
Joulukuu 2024
Metsätalouden YAMK-koulutus

TIIVISTELMÄ

Tampereen ammattikorkeakoulu
Monitavoitteisen metsänhoidon ylempi tutkinto-ohjelma (ylempi AMK)

VOLLAR, NICOLAS:

Metsätuhoja havaitsevan tekoälysovelluksen tarkkuuden ja käyttökelpoisuuden kartoitus Kymenlaaksossa

Opinnäytetyö 101 sivua
Joulukuu 2024

Ilmastonmuutoksen myötä metsien riskien ennustetaan muuttuvan ja lisääntyvän etenkin varttuneissa kuusikoissa. Metsä Group ja metsätalouden tekoälysovelluksiin erikoistunut CollectiveCrunch ovat tehneet sovelluksen, joka tuottaa Sentinel-2 -satelliitin avoimesta datasta metsätuhon riskiä indikoivan karttatason tekoälyn avulla. Sovellus käyttää eri näkyvän valon spektrejä yhdistettynä eri infrapunaa aallonpituuksiin analysoidessaan puiden nestevirtauksia ja niiden äkillisiä heikentymiä. Tämä tutkimus tarkastelee sovelluksen tuottaman tiedon tarkkuutta ja käyttökelpoisuutta Kymenlaakson alueella 74 pysyvän ja 74 muuttuvan koealan kaksivuotisen seurannan pohjalta. Sovelluksen laskenta-algoritmi muuttui merkittävästi vuosien 2023 ja 2024 välillä. Tutkimuskysymys pureutuu siihen, kuinka käyttökelpoinen sovellus on käyttäen puuston keskimääräistä kuolleisuutta ja altistavia riskitekijöitä mittareina.

Kuolleisuus pysyvillä koealoilla muuttui vuoden 2023 18 %:sta vuoden 2024 20 %:iin. Havaittiin, että vuonna 2023 sovellus ei aina löytänyt vakavimmin vaurioituneita alueita, sillä 2023 maastossa silmämääräisesti pahimmin vaurioituneeseen kohtaan asetetuilla lisäkoaloilla kuolleisuus oli 41 %. Uudistetun laskenta-algoritmin koealojen kuolleisuuden todettiin olevan 25 %, kun 2023 se oli vain 18 %. Terveessä vertailumetsässä vastaava kuolleisuus oli 1,6 %. Lähellä olevien aukeiden alueiden havaittiin lisäävän kuolleisuutta merkittävästi, mutta havaintojoukko lähellä aukeita olevista koealoista oli pieni. Maaperän ja hiljattain toteutetun harvennuksen ei todettu lisäävän merkittävästi kuolleisuutta. Havainnot kirjanpainajasta korreloivat vahvasti ja havainnot myrskytuhoista keskivahvasti kuolleisuuden kanssa.

Koska laskenta perustuu satelliitista havaittavaan nestevirtausten katkeamiseen, ei sitä voida pitää täysin luotettavana senkään takia, että esimerkiksi kuivuus voi näyttää hetkellistä riskiä ennen kuin metsä voi siitä palautua ennalleen. Kuitenkin koealojen suurempi kuolleisuus vuoden 2024 päivitetyn algoritmin laskeman kartan perusteella valituissa koealoissa viittaa siihen, että sovelluksen tuottama tieto on tarkentunut sovelluksen algoritmin päivityksen myötä. Siten sen käyttökelpoisuus paranee kehitystyön myötä ja jo nykyiselläänkin ohjaa alueille, missä 10 m x 10 m alueella keskimäärin 25 % puustosta on kuollut. Siten sovelluksen tuottamaa tietoa voidaan pitää hyvin metsäasiantuntijan työtä tukevana.

Asiasanat: metsätuho, kaukokartoitus, kirjanpainaja, tekoäly

ABSTRACT

Tampere ammattikorkeakoulu
Tampere University of Applied Sciences
Degree Programme in Natural Resources

VOLLAR NICOLAS:

The Accuracy and Usability of an Application for Detecting Forest Damage in Kymenlaakso

Master's thesis 101
December 2024

The predicted risk levels are raising for especially mature spruce dominated forests in Finland due to the changing climate. Metsä Group has collaborated with CollectiveCrunch which is a company specializing in artificial intelligence application for forestry use. They have created an application that uses the open data from the Sentinel 2 satellites to produce a map layer that indicates heightened levels of risk for forest damage. The application uses different wavelengths of visible light and infrared bands to analyse the flow of fluids to the treetops in order to notice the abrupt change in fluid movements due to forest damage. This study measures the accuracy and usability of the application in the region of Kymenlaakso in Finland. The study consists of 74 permanent sample plots and 74 variable sample plots and ranges from autumn of 2023 to autumn of 2024. The algorithm used by the application changed drastically between the years. The research question assesses the accuracy and usability of the map layer using the average death rates recorded at the sample plots and observing the attributes contributing to tree stress levels as the basis for the calculation.

The death rates at the permanent sample plots went from 18 % in 2023 to 20 % in 2024. It was noted that the application did not always detect the most damaged sites as the variable sample plots in 2023 that were placed in retrospect in the most damaged plots that were seen while recording the data from the permanent sample plots gave a significantly higher 41 % death rate. The renewed algorithm gave a death rate of 25 % that is comparable with the permanent sample plots. Healthy comparable spruce dominated forests had a 1,6 % death rate. Nearby clearcuts and other open areas were observed to have a significantly higher death rate but the number of samples was small. The soil type or recently done thinning did not have a significant impact for the death rate. Observed signs of Norwegian spruce bark beetle correlated strongly and storm damage moderately with the death rate.

As the data provided by the application uses indices calculated from the satellite data it can not be seen as absolutely correct. It can show a raised risk for an area that suffers momentarily from draught but is restored afterwards. Still the higher death rates of 2024 updated algorithm indicates that the accuracy of the application has been modified for the better. Therefore the usability of the application by Metsä Group forestry specialists has improved. The 2024 algorithm can already point areas that have approximately 25 % death rate of trees on a 10 x 10 m plot. This can be seen as a decent level of accuracy.

Keywords: forest damage, remote sensing, Norwegian spruce bark beetle, artificial intelligence

SISÄLLYS

1	JOHDANTO	7
1.1	Tausta	8
1.2	Työn tavoite ja tutkimuskysymys	8
1.3	Rajaus	10
2	OPINNÄYTETYÖN TIETOPERUSTA	11
2.1	Metsätuhot Suomessa	11
2.1.1	Häiriö vai tuho?	13
2.2	Kuusi (<i>Picea abies</i>)	13
2.3	Kuusen yleisimmät tuhonaiheuttajat	14
2.3.1	Kirjanpainaja (<i>Ips typhographus</i>)	14
2.3.2	Kuusentähtikirjaaja (<i>Pityogenes chalcographus</i>)	19
2.3.3	Kaatuneet ja katkenneet puut	20
2.3.4	Muut puitten stressitekijät	21
2.3.5	Häiriö on monen tekijän summa	23
3	KAUKOKARTOITUSMENETELMÄT METSÄTALouden KÄYTÖSSÄ 25	
3.1	Lentolaserkeilaus (Airborne Laser Scanning, ALS)	26
3.2	Multispektrikuvaus ja Sentinel-2 satelliitti	29
3.3	Hyönteistuhojen havaitseminen kaukokartoituskeinoin	35
3.3.1	Kaukokartoitus laajamittaisessa käytössä hyönteistuhojen havaitsemisessa	37
3.3.2	Kaukokartoitustiedon luotettavuuden metriikka	37
3.4	Neuroverkot kaukokartoitustiedon prosessoinnissa	40
4	OPINNÄYTETYÖN AINEISTO	44
4.1	Aineiston hankinta	45
4.1.1	Käytetty välineistö	46
4.1.2	Sääolosuhteet ja lämpösumma tarkasteluajanjaksoilla	47
4.1.3	Riskitekijöitten tunnistaminen ja todennäköisimmät virhetulkinnat	48
4.1.4	Aineiston tarkasteluajankohta ja muutokset vuosien välillä	49
4.2	Aineiston kuvailu	50
4.2.1	Aineiston koealoittain kerätty tieto	53
4.2.2	Aineiston analysointitavat	56
4.2.3	Otoskeskiarvo, mediaani, otoskeskihajonta ja luottamusväli	58
4.2.4	Ruutu- ja janakaavio	59

4.2.5	Hajontakaavio ja Pearsonin korrelaatiokerroin	60
4.2.6	Tilastollinen merkitsevyys p-arvolla	61
4.2.7	Koealojen elinvoimaisuuden status	62
5	TULOKSET JA TARKASTELU	63
5.1	Koealatietojen tulokset	63
5.1.1	Vertailukelpoinen perustaso	63
5.1.2	Koealojen elinvoimaisuuden status	64
5.1.3	Koealatietojen yhteenvetot pääryhmittäin.....	67
5.1.4	2023 ja 2024 pysyvät koealat	70
5.1.5	2023 pysyvät koealat ja 2024 lisäkoealat.....	73
5.1.6	2023 pysyvät koealat ja 2023 lisäkoealat.....	74
5.1.7	Pääryhmien kokoomayhteenvetot.....	76
5.1.8	Lähellä olevan aukean alan vaikutus kuolleisuuteen.....	77
5.1.9	Maaperän vaikutus kuolleisuuteen	78
5.1.10	Harvennuksen vaikutus koealoihin.....	79
5.1.11	Kohteilta löydettyjen riskitekijöiden korrelaatioanalyysi	80
5.2	Tulosten tarkastelu ja yhteenveto.....	82
6	PÄÄTELMÄT	84
6.1	Päätelmiä	84
6.2	Vaikutukset Metsä Groupin kannalta.....	89
6.3	Tutkimuksen luotettavuus ja eettisyys	90
6.4	Tutkimuksen jatkokehitysmahdollisuudet.....	93
	LÄHTEET	94

LYHENTEET JA TERMIT

Hila

Hila-aineistot ovat vektorimuotoista (polygon) paikkatietoaineistoa (Hila-aineisto 2023, 1). Metsä Groupin ja CollectiveCrunchin metsätuhoja havaitseva sovellus käyttää 10 m x 10 m hilaruutuja.

Lämpösumma

Lämpösumma on tapa mitata termisen kasvukauden kertynyttä lämmön määrää. Termisen kasvukauden ajalta summataan jokaisen päivän keskimääräisen lämpötilan $+5\text{ °C}$ rajan ylittävä osa yhteen. Lämpösumma ei voi vähetä, vaan ainoastaan kasvaa. Lämpösumman yksikkö on vuorokausiaste (°Cvrk). (Terminen kasvukausi. n.d.)

Neuroverkko

Neuroverkot ovat informaation käsittelyn ja laskennan malleja, jotka mallintavat karkeasti aivojen tapaa käsitellä informaatiota ja jotka perustuvat yhdistävään laskentaan. Käytetään mm. kuvantunnistuksessa, konenäössä, ym. Koostuu syötekerroksesta, piilokerroksista ja ulostulokerroksesta. (Tuominen ym. 2019, 6-7.)

Terminen kasvukausi

Terminen kasvukausi alkaa siitä, kun 10 vuorokauden keskilämpötila nousee pysyvästi yli $+5\text{ °C}$ ja päättyy siihen, kun keskilämpötila laskee pysyvästi alle $+5\text{ °C}$ tai saadaan pysyvä lumipeite. Termistä kasvukautta seurataan lämpösumman avulla. (Terminen kasvukausi. n.d.)

VMI

Valtakunnan metsien inventointi, jossa tuotetaan tilastolliseen otantaan perustuva inventointi Suomen metsävaroista. Eri puolilta Suomea mitataan yli sataa erilaista metsiä kuvaavaa tunnusta. Inventointeja on tehty vuodesta 1921 asti. (Valtakunnan metsien...n.d.)

1 JOHDANTO

Kokonaiskestävän metsien hoidon kannalta yhtenä suurena riskitekijänä Etelä-Suomessa on kuusikoitten terveys tulevaisuudessa, sillä niiden terveyttä uhkaavat monet tekijät ilmastosta muutoksen myötä. Erilaisten metsätuhojen, kuten hyönteistuhojen, taajuuden ja voimakkuuden ennustetaan kasvavan, mikä näkyy hyönteistuhoksi merkittyjen metsänkäyttöilmoitusten määrän kymmenkertaistumisena edellisvuosiin verrattuna. (Metsäkeskus 2022.)

Metsä Group on yhteistyössä metsätalouden tekoälysovelluksiin erikoistuneen CollectiveCrunchin kanssa kehittänyt sovellusta, joka tunnistaa Sentinel-2 -satelliitin tuottamiin avoimiin satelliittikuviin perustuen mahdollisia tuhoja metsissä. Sovelluksen on tarkoitus havaita kohonnutta riskiä erityisesti kaarnakuoriaistuhoihin jo ennen kuin ihmissilmä pystyy näkemään muutoksia metsässä. Sovelluksen kuvat tulevat päivittymään monta kertaa kasvukauden aikana, jolloin voidaan luoda seuranta riskikohteen tilanteen kehityksestä jo yhden kasvukauden aikana. Nopean reagoinnin kautta riskien hallinta tehostuu. (Metsä Group 2022.)

Metsä Groupin metsänomistaja-asiakkaille karttatason tuottama tieto edesauttaa taloudellista kestävyttä, sillä nopean reagoinnin avulla puutuoteteollisuuden käyttämiä arvokkaampia puutavaralajeja siirtyy vähemmän metsätuhojen myötä vähempiarvoisiin tavaralajeihin, kuten energiapuuksi. Sosiaalisen kestävyuden kannalta laajojen metsätuhojen välttäminen on olennaista, sillä laajat pystyyn kuolleet metsät ovat esim. maisema- ja virkistyskäyttöä selkeästi heikentävä tekijä. Ekosysteemipalveluitten kannalta terveet ja hyväkuntoiset metsät ovat keskeisiä, sillä laajan metsätuhon sattuessa myös ekosysteemipalveluille tärkeä metsäympäristö muuttuu voimakkaasti. (Metsien kestävä hoito ja käyttö. n.d.)

Tuhojen hillintä on olennaista metsien hiilitaseelle ja ilmastokestävyydelle, sillä vain yhteyttävä puu sitoo hiiltä ilmakehästä. Lahopuu on tärkeää luonnon monimuotoisuudelle, mutta äkillinen suuri määrä kuollutta puuta on vähemmän monimuotoisuutta tukeva kuin sama määrä lahopuuta ajallisesti pidemmälle aikavälille jakaantuneena. Metsien moni-

käytön kannalta laajat tuhometsät voivat olla taloudellisesti metsänomistajalle kestävämpiä, ekologisesti monimuotoisuudelle yksipuolisia, ekosysteemipalveluille haitallisia sekä maisemallisesti metsän virkistyskäytön kannalta vahvasti negatiivisesti vaikuttavia. (Metsien kestävä hoito ja käyttö. n.d.)


1.1 Tausta

Metsä Group oli jo jonkin aikaa kehittänyt hyönteistuoja havaitsevaa sovellustaan CollectiveCrunchin kanssa yhteistyössä ennen kuin ajatus opinnäytetyön aiheesta syntyi. Kesällä 2023 sovellus alkoi olemaan kenttätestausvaiheessa, jolloin sen tuottamaa dataa alettiin vertaamaan maastohavaintoihin. Tämän opinnäytetyön tekijän toimesta avustettiin CollectiveCrunchia tässä tehtävässä ja siitä syntyi ajatus opinnäytetyöstä.

CollectiveCrunchilta tuotettiin kartta-aineisto sovelluksen tuottamasta analyysistä, missä näkyi kohonneen riskin alueet. Maastossa kierrettiin alueita läpi kartoittaen silloisen laskennan osuvuutta ennen karttasovelluksen julkaisemista. Laskennan tulokset olivat jo silloin hilamuotoista tietoa ja havaintoja tehtiin hilaruuduilta vain näköhavaintoihin perustuen ja metsän tilaa arvioitiin sen mukaan, oliko puusto elävää, kuollutta vai stressaantunutta esimerkiksi hyönteistuhon vuoksi.

1.2 Työn tavoite ja tutkimuskysymys

Avoimen tiedon lähteitä hyödyntävä tekoälysovellus tuottaa karttatason, jonka on tarkoitus näyttää puiden terveydentila perustuen kaukokartoituksen eri spektreistä saataviin analyyseihin. Tieto on laskettu keskiarvona 10 m x 10 m hilaruudulle, jolloin havainnot yksittäisistä tuhoutuneista puista eivät yleensä näy karttatasolla. (Metsä Group n.d.) Tämän työn tavoite on empiirisesti tutkia tuotetun tiedon tarkkuutta ja käyttökelpoisuutta.



Kuva 1. Havainnekuva tekoälysovelluksen tuottamista karttatasoista, jossa vasemmanpuoleinen osoittaa tuhon voimakkuuden ja oikeanpuoleinen ajankohdan.

Erityinen mielenkiinnon kohde on alueet, jotka syksyllä 2023 näyttävät suurta ja tuoretta riskiä ilman maastossa havaittavaa tuhoa, mutta joissa syksyllä 2024 löytyy silmin havaittava tuho. Tämä segmentti kuvaa sellaisia koaloja, joissa sovellus on pystynyt tavoitteensa mukaan havaitsemaan nestevirtausten häiriön ja siten tulevan tuhon jo ennen kuin ihmissilmä sitä pystyy näkemään (Metsä Group n.d.). Altistavia riskitekijöitä, kuten tuulituhot, hakkuuaukeat viereisillä kuvioilla sekä maaperätekijät, pyritään tunnistamaan.

Tutkimuskysymys määritetään näin: kuinka käyttökelpoista on hyönteistuhosovelluksen tuottama tieto Kymenlaakson kuusikoitten terveydentilan selvittämisessä? Tutkimuskysymykseen vastaaminen vaatii tiedon tarkkuuden arviointia maastohavaintojen ja sovelluksen tuottaman tiedon välillä.

Tutkimuskysymys rajataan koskemaan avoimeen dataan perustuvan tekoälysovelluksen luomaa karttatietoa, josta tulkitaan metsien terveydelle haitallisten olosuhteiden ja ulkoisten tekijöiden, kuten hyönteistuhojen, kehitystä vuosien 2023 ja 2024 välillä. Työ rajataan tutkimaan metsien riskitekijöiden tuottamaa uhkaa, kuten havaittujen myrsky- ja lumituhojen tuottamaa kohonnutta riskitasoa kuusivaltaisissa metsissä Kaakkois-Suomessa. Mukaan sisällytetään tarkastelua aiheeseen liittyvistä riskitekijöistä, kuten erilaiset maaperätekijät ja tuoreet hakkuuaukeat etenkin etelän puolella. Jos mahdollista, arvioidaan puitten sairastumisen syy.

1.3 Rajaus

Tarkastelu rajataan sovelluksen toimivuuden kannalta tutkimaan sitä, kuinka tarkasti karttatason värigradientin tuottama tieto korreloi maastotarkastuksen tuottamaan tietoon. Tarkastellaan myös tiedon helppolukuisuutta.

Sovelluksen tuottamaa dataa voidaan hyödyntää myös muuten kuin hyönteistuhojen kar-toittamisessa. Sovellus voi olla apuna esim. niiden kuusikoiden havaitsemisessa, jotka ovat kuivuuden vaivaamia ja näin ollen mm. hyönteistuhoilta alttiimpia. Sovellus itsessään ei pysty määrittelemään tuhon syytä, vaan se havaitsee spektrianalyysillä heikentyneitä nestevirtauksia puissa. Tämän takia ohjelman käytöllä on myös tulkintaa vaativa puoli: miten tunnistaa varsinainen tuho hetkellisestä häiriöstä.

Aineiston keruussa maastossa tulkittavat kohteet on rajattu avoimen kuviodatan perusteella kuusivaltaisiin kohteisiin. Kohteet painottuvat vahvasti päätehakkuukypsiin 04-kehitysluokan ja varttuneisiin 03-kehitysluokan kuusivaltaisiin kohteisiin. Ajankohta rajautuu sovelluksen toimintaan vuosina 2023 ja 2024.

Vaikka sovellus itsessään pyrkii havaitsemaan ensisijaisesti heikentyneitä puita kuolleiden puitten sijaan, oli aineiston hankinnallisista syistä pakko ottaa keskiöön kuolleet puut. Syy tähän oli se, että kuolleisuuden kautta päästään käsiksi heikentyneiden puiden määrään takautuvasti. Tutkimalla ensimmäisenä vuonna elävien ja kuolleiden puiden tilanne voidaan sitä verrata seuraavan vuoden vastaavaan tilanteeseen. Jos seuraavana vuonna kuolleita puita on selkeästi enemmän kuin mitä ensimmäisenä vuonna, on alueella ollut todennäköisesti jo ensimmäisenä vuonna heikentyneitä puita. Toisin sanoen kuolleiden puiden määrien erotuksella päästään käsiksi siihen muutokseen, mitä heikentyminen on tuottanut.

Toinen syy siihen, miksi oli otettava keskiöön kuolleet puut heikentyneiden sijaan on se, että heikentyneen puun määritelmä on hyvin epämääräinen. Tutkimuksen aikana ei ollut mahdollista päästä tutkimaan puitten kuoren alla olevia terveydentilaa heikentäviä tekijöitä, joten pelkkä silmämääräinen arvio heikentymisestä olisi ollut äärimmäisen subjektiivinen tapa hankkia aineistoa, eikä sitä siksi voida hyväksyä tieteellisen tutkimuksen perustaksi.

2 OPINNÄYTETYÖN TIETOPERUSTA

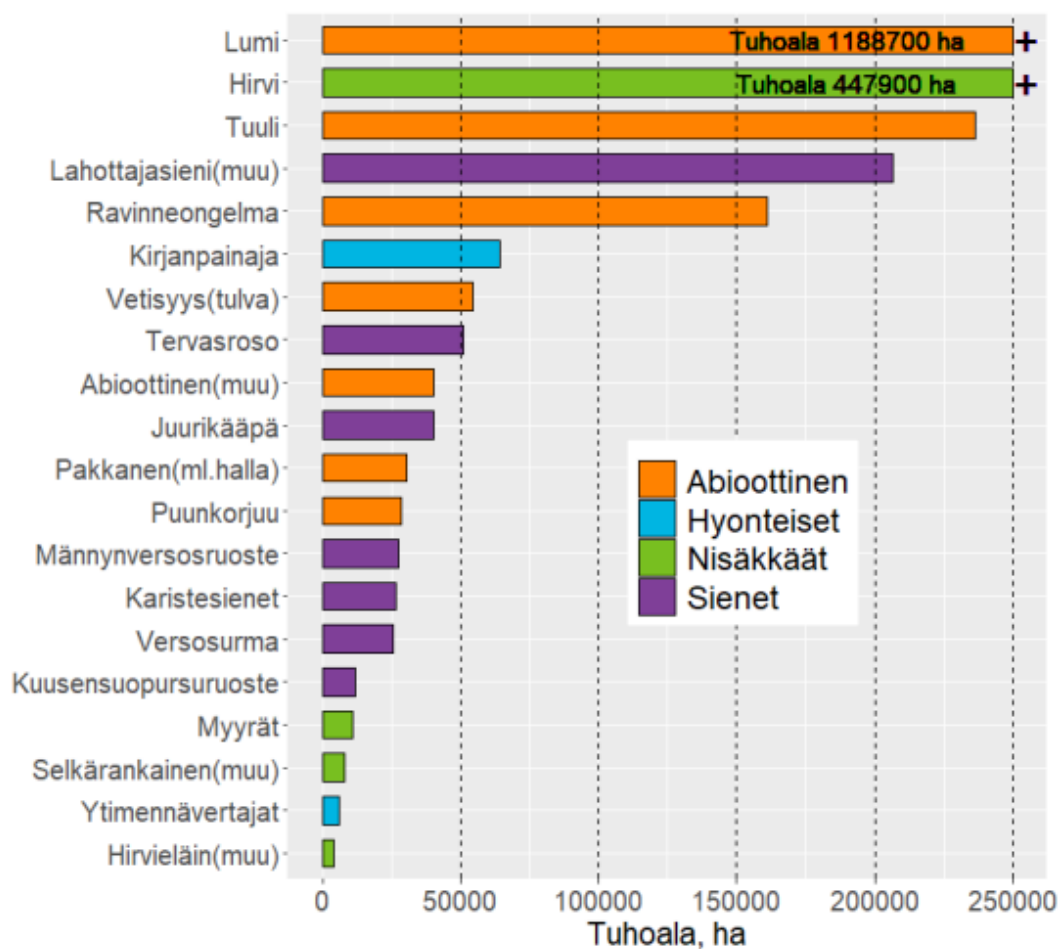
2.1 Metsätuhot Suomessa

Opinnäytetyön aihe liittyy laajempaan metsiä koskevaan olosuhteiden ja ilmaston muutokseen, mihin liittyy huomattava määrä osatekijöitä. Monet näistä tekijöistä kytkeytyvät toisiinsa monimutkaisin tavoin. Ilmasto on lämmennyt ja lämpenee edelleenkin ja sillä on vettä haihduttava vaikutus, jolloin kuivuus voi vaivata yhä useampia metsiä. Lumituhojen ennakoitaan voimistuvan idässä ja pohjoisessa kun taas etelä- ja lounaisosissa ne voivat heikentyä. Kuitenkin tuulituhojen määrä voi voimistua varsinkin Etelä- ja Länsi-Suomessa, sillä lännensuuntaisten tuulten ennakoitaan voimistuvan etenkin syystalvella, jolloin Etelä- ja Länsi-Suomessa ei vielä ole maa roudassa. Routa pitäisi puita paremmin pystyssä, mutta routaantumattomassa maassa puut voivat kaatua juurineen vaikka keskimääräiset tuulennopeudet pysyisivät samoina kuin nykyään. (Venäläinen ym. 2020, 2-3.)

Abioottisten, eli ei-eloperäisten, tuhojen lisäksi Suomessa on nykyiselläänkin lukuisia bioottisia, eli eloperäisiä, tuhonaiheuttajia (Venäläinen ym. 2020, 5-7). Tähän työhön ei ole aiheellista nostaa kaikkia mahdollisia tuhonaiheuttajia sekä sitä, miten niiden kannan oletetaan tulevaisuudessa käyttäytyvän, mutta muutaman lajin tulevaisuudennäkymät on syytä nostaa esille kytkeytyvyyden takia. Koska Metsä Groupin ja CollectiveCrunchin tekoälysovellusta markkinoidaan hyönteistuhokulmalla, otetaan tässä tuhonaiheuttajien kytkeytyvyyden kannalta kirjanpainajat ja kuusentähtikirjaajat keskiöön. (Metsä Group 2022.)

Abioottiset tuhot ovat Suomessa merkittävämpi tuhonaiheuttaja kuin bioottiset, mutta yksittäisissä kategorioissa vaihtelu voi olla huomattavaa vuosien välillä. Hyvänä esimerkkinä toimii kirjanpainaja, jonka tuhoja on vuonna 2023 VMI:n eli valtakunnan metsien inventoinnin mukaan havaittu 257 % enemmän kuin vuonna 2022. Kuusentähtikirjaaja ei vielä ole niin merkittävä tuhonaiheuttaja yksinään, että sitä olisi noteerattu itsenäisenä tuhonaiheuttajana Luonnonvarakeskuksen raportissa. (Ylioja & Sutela 2024, 12.)

Abioottisista tuhoista lumituhot aiheuttavat huomattavasti suurimman osan. Lumituhot olivat aiheuttaneet laadun heikkenemistä vuoden 2023 inventoinnissa 1 188 700 hehtaarella, mikä on 6,11 % puuntuotannollisesta metsämaasta. Tuulituhot olivat aiheuttaneet vuoden 2023 inventoinnissa laadun heikkenemistä 236 300 hehtaarella, mikä on 1,21 % puuntuotannollisesta metsämaasta. Vuonna 2023 abioottisten tuhojen prosentuaalinen määrä koko puuntuotannollisen metsämaan pinta-alasta oli kumulatiivisesti 10,15 %, selkärankaisten ja hyönteisten osuus 2,97 % ja tautien osuus 2,28 %. (Ylioja & Sutela 2024, 12.)



Kuvio 1. Merkittävimmät tuhoaiheuttajat vuonna 2023 VMI:n maastokauden mukaan. Huomaa, että ylimmät kaksi riviä on jouduttu lyhentämään, sillä ne olisivat muuten suhteettoman pitkiä. (Ylioja & Sutela 2024, 13.)

2.1.1 Häiriö vai tuho?

Metsäkontekstissa termejä ”häiriö” ja ”metsätuho” käytetään monesti tarkoittamaan samaa asiaa, mutta niille on määritelty omat merkityksensä suomen kielessä. Metsillä on oma häiriödynamiikkansa, jossa luontaisten ja pienialaisten puitten kuolemien kautta metsä uudistuu palanen kerrallaan. Häiriöitten kautta metsän rakenne pysyy vaihtelevana ja häiriö vapauttaa resursseja muuten sulkeutuneessa metsässä. Häiriö on myös ajallisesti metsän kannalta lyhytaikainen tapahtuma. Metsälle luonteenomaisia häiriöitä ovat pienialaiset metsäpalot, myrskyn kaatamat puuryhmät, pienialaiset hyönteistuhot ja rajallisesti levinneet sienitaudit. (Kulha & Honkaniemi 2022, 1.)

Metsätuho taas viittaa nykyisen metsän arvon rajuun alenemaan siinä määrin, että sen voidaan katsoa tuhoutuneen. Siten metsätuho sanana liittyy metsän taloudelliseen hyötyyn, sillä ekologiselta kannalta tarkasteltuna suurikin metsätuho voi vapauttaa resursseja muun kasvillisuuden, kuten nuorempien puusukupolvien, käyttöön sekä tuottaa ekologisesti arvokasta lahoppuuta olettaen, ettei lahoppuuta kuljeteta pois metsästä muuhun käyttöön. (Kulha & Honkaniemi 2022, 2.)

On useimmiten ekologiselta kannalta loogisempaa puhua voimakkaista metsien häiriöistä metsätuhojen sijaan, sillä metsä uudistuu useimmiten ajan saatossa alueella tuottaen monirakenteisemmän metsän. Ekologinen arvo voi siten häiriöiden kautta kasvaa, vaikka taloudellisesti arvokasta puuta tuhoutuisi. Kuitenkin metsätuho on sanana vakiintunut arkkikäyttöön vahvasti. (Kulha & Honkaniemi 2022, 2.)

Laki metsätuhojen torjunnasta (2013/1087) määrää 5 §:ssä, että mikäli metsätuhon, hakuiden tai muun syyn takia metsästä löytyy läpimitaltaan yli 10 cm kuusen rungon osia yli 10 m³ per hehtaari, tulee ylimenevä osuus poistaa sieltä tiettyyn päivämäärään mennessä. 6 §:ssä tarkennetaan, että kyseiset rajat koskevat myös vahingoittuneita puita, kuten myrskyn katkomia tai kaatamia puita.

2.2 Kuusi (*Picea abies*)

Kuusi, suomeksi myös metsäkuusi (lat. *Picea abies*, engl. Norway Spruce), on Suomessa yleinen ainavihanta mäntykasvien heimoon kuuluva puulaji. Kuusi on kasvumuodoltaan

kartiomainen ja sillä on vanhoissakin yksilöissä selkeä apikaalidominanssi, missä ylin kärkikasvu hillitsee alempien oksien muodostumista uusiksi latvoiksi. (Tjoelker ym. 2007, 9.)



Kuva 2. Kuusen taksonomia (Kuusi 2024).

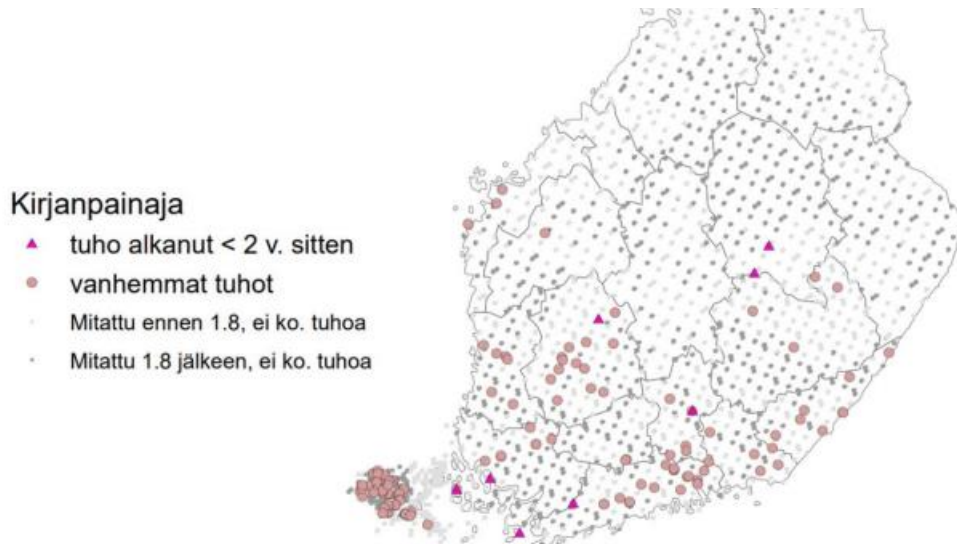
Kuusen kaarna muodostuu iän myötä paksuksi kilpikaarnaksi ja etenkin runsas altistuminen auringonvalolle lisää kilpikaarnan tuotantoa. Kuusen kasvutapa juuriston osalta on pintajuurinen, sillä juuret kasvavat enimmäkseen maaperän ylimmän 10 cm alueella vain joittenkin juurien yltäessä jopa 35cm syvyyteen etenkin sekametsissä. Pintajuurisuutensa takia kuusi on Suomen puulajeista alttein tuulituhoille, joissa puu kaatuu myrskyssä juurineen (Kuusi 2024). Kuusi ei tee paalujuurta eli suoraan alaspäin suuntautuvaa, maaperään ankkuroivaa juurta. Se on pintajuurisuutensa takia kuivumiselle arka puulaji ja siten sille sopivimmat kasvupaikat ovat kosteita ja viileitä. (Tjoelker ym. 2007, 13.)

2.3 Kuusen yleisimmät tuhoniheuttajat

2.3.1 Kirjanpainaja (*Ips typhographus*)

Kirjanpainaja (*Ips typhographus*) on metsäkuusella (*Picea abies*) elävä aikuisena noin 5mm kokoinen kaarnakuoriainen, joka kuuluu luontaisena suomalaiseen metsäluontoon. Se iskee ensisijaisesti heikentyneisiin kuusiin, mutta kannan päästessä runsastumaan, voi

kirjanpainaja päästä täysin terveidenkin kuusten puolustuksesta läpi. Kirjanpainaja hyötyy mm. tuulituhojen, kuivuuden ja muiden kaarnakuoriaisten heikentämistä puista. (Kirjanpainaja kuusikossa n.d., 4.)



Kuva 3. Valtakunnan metsien 13. inventoinnissa (VMI13) vuonna 2023 havaittujen kirjanpainajaesiintymien sijainnit kartalla kirjanpainajan yleisellä esiintymisalueella (Ylioja & Sutela 2024, 78).

Suomessa esiintyvistä kaarnakuoriaisista kirjanpainaja on aiheuttanut mittavimmat hyönteistuhot jo tähän mennessä ja tulevaisuudessa kirjanpainaja tulee hyötymään kohoavista lämpötiloista (Venäläinen ym. 2020, 5). Lämpö nopeuttaa lajin aikuistumista ja kirjanpainaja ehtiikin sitä todennäköisemmin tuottaa useamman sukupolven yhden kasvukauden aikana mitä lämpimämpää on (Ylioja & Sutela 2024, 72).

Viiden viime vuosikymmenen aikana on arvioitu kirjanpainajan tappaneen 150 miljoonaa m³ puuta Euroopassa. Häiriön myötä kirjanpainajan syömien puitten taloudellinen arvo myyntipuuna romahtaa samalla, kun se aiheuttaa metsänhoidollisia kustannuksia. Näitten lisäksi on epäsuoria negatiivisia vaikutuksia, kuten paikallisen puuston hiilensidonnan määrän romahtaminen, kohonnut riski vakavaan metsäpaloön ja paikallisesti heikentynyt biodiversiteetti. (Jamali ym. 2023, 352.)

Ennen 2010-lukua oli harvinaista kirjanpainajalle tuottaa useampi sukupolvi kasvukauden aikana, mutta nykyään niin käy säännöllisesti. Kirjanpainajan parveilu keväällä alkaa

päivälämpötilan noustessa noin +18-20 °C asteeseen. Ensimmäinen talvehtineiden aikuisten jälkeläissukupolvi aikuistuu lämpösumman saavuttaessa noin 700 vuorokausiasteen (°Cvrk) rajan. Samojen talvehtineiden aikuisten kirjanpainajien tuottama ensimmäisen jälkeläissukupolven sisärsukupolvi aikuistuu noin 1150 °Cvrk kohdalla. Jos kesä on suotuisa kirjanpainajille, voi ensimmäisen jälkeläissukupolven tuottamat omat jälkeläiset aikuistua noin 1500 °Cvrk kohdalla. (Kirjanpainaja kuusikossa n.d. 6-7.)

Kirjanpainajan aiheuttama tuho on useimmiten havaittavissa vasta siinä vaiheessa, kun metsään alkaa muodostumaan kuolleiden puiden ryhmiä. Sitä ennen on kuitenkin tapahtunut jo monta vaihetta. Ensin kirjanpainajat parveilevat ja etsivät parittelukumppaneita feromonien avulla. Feromonit ohjaavat kirjanpainajat hyökkäämään saman puuyksilön kimppuun, sillä hyönteisten on voitettava puun pihkapuolustus ennen kuin lisääntyminen voi onnistua. Kirjanpainajat iskeytyvät ensisijaisesti heikentyneisiin kuusiin, sillä niiden pihkapuolustus on helpompi voittaa. (Kirjanpainaja kuusikossa n.d. 4-5.)

Kirjanpainajan aiheuttamien kuusten kuolemien on nähty tarvitsevan myös kirjanpainajan mukanaan kuljettaman sinistäjäsienen, *Endoconidiophora polonica*, läsnäoloa. Sinistäjäsienen on arvioitu heikentävän puun puolustusta entisestään kirjanpainajan hyökkäyksen alkuvaiheessa. (Wadke ym. 2016, 914.)

Erittäin runsas pihkavuoto voi olla yksi tekijä, mikä indikoi meneillään olevaa tai hiljattain päättynyttä hyönteisten hyökkäystä. Kun kirjanpainaja on voittanut puun pihkapuolustuksen ja puu ei enää pysty pihkallaan työntämään kaarnakuoriaisia pois kuoren alta, alkaa hyönteisten sisäänmenoreikien ja puun tyven tuntumaan muodostumaan ruskeita purukasoja. (Kirjanpainaja kuusikossa n.d. 5, 12-13.)



Kuva 4. Kirjanpainajan tuottamaa ruskeaa purua kuusen rungolla.

Naaras kovertaa puun syiden suuntaisen pystysuoran emokäytävän, jonka varrelle se laskee munat. Munista kuoriutuvat toukat syövät kukin oman toukkakäytävänsä niin, että toukkakäytävät eivät risteä keskenään. Toukkien ja sinistäjäsiementen yhteistyönä puun nestevirtaukset katkeavat ja puu kuolee sen seurauksena. (Kirjanpainaja kuusikossa n.d. 4-5.)

Puun kuollessa ja kuivuessa sen kaarna alkaa tippumaan. Tässä vaiheessa toukat ovat jo aikuistuneet ja lähteneet puusta, eli kuorensa tiputtanut puu ei ole enää tuhoa levittävä. Itse asiassa kuorensa tiputtanut puu toimii kirjanpainajan luontaisten vihollisten, kuten kirjanpainajan toukkia syövien petohyönteisten ja loisten, isäntäpuina. Emokäytävä ja toukkakäytävät muodostavat kirjanpainajalle ominaisen syöntikuvion. Näistä kuolleista puista alkaa melko aikaisessa vaiheessa kuori irtoamaan niin, että kirjanpainajan ominainen syömäkuvio tulee esiin. (Kirjanpainaja kuusikossa n.d. 13-14.)



Kuva 5. Kirjanpainajan syöntikuvio kuusen rungolla.

On tunnistettu ja nimetty eri vaiheita sille, kun kirjanpainaja hyökkää puun kimppuun ja etenee puun puolustuksen läpi. Termit ovat kuitenkin vakiintuneet vasta englannin kielenä ja odottavat varsinaisia pysyviä termejä suomen kielellä. Ensimmäinen vaihe on ”green attack” -vaihe, jolle suora suomennos olisi vihreä hyökkäys. Green attack -vaihe on kolonisaation alkuvaihe, jolloin puu säilyy yleisilmeeltään vielä vihreänä siitä huolimatta, että hyökkäyksen ja pihkapuolustuksen takia nestevirtaukset alkavat jo heikkenevään. ”Red attack”, eli suoraan suomennettuna punainen hyökkäys, on kolonisaation toinen vaihe, jossa puun neulaset muuttuvat jo vihreistä punaisen ruskeiksi. Tämä vaihe ilmentää jo pitkälle edennyttä hyökkäystä. Viimeinen vaihe on ”Grey attack” -vaihe, joka on suoraan suomennettuna harmaa hyökkäys. Tässä vaiheessa neulaset varisevat maahan ja puu kuolee. (Jamali ym. 2023, 353.)

Green attack -vaiheessa oleva kirjanpainajien hyökkäys voi olla vielä vaikea havaita paljain silmin. Kuitenkin tämä on juuri se vaihe, jolloin alkava hyökkäys tulisi tunnistaa jos sen vaikutuksia halutaan hillitä. (Abdullah ym. 2019, 88.) Poistamalla kolonisoidut puut metsästä green attack -vaiheessa ovat toukat vielä kuoriutumatta, jolloin tuho ei pääse

leviämään metsässä (Jamali ym. 2023, 353). Juuri tähän tarpeeseen Metsä Groupin ja CollectiveCrunhin kehittämä sovellus pyrkii vastaamaan.

2.3.2 Kuusentähtikirjaaja (*Pityogenes chalcographus*)

Kuusentähtikirjaaja (*Pityogenes chalcographus*) on melko pienikokoinen kaarnakuoriainen, sillä aikuisena kuusentähtikirjaajan keskimääräinen pituus on noin 2mm. Kuusentähtikirjaaja elää nimensä mukaisesti pääasiallisesti metsäkuusella (*Picea abies*) ja se on yleinen niin tuulenkaadoissa, myrskyn katkomissa latvoissa kuin myös harvennuksista jäävässä oksa- ja latvusmassassa. (Hedgren 2003, 161.)



Kuva 6. Kuusentähtikirjaajan syöntikuvio kuusen rungolla.

Kuusentähtikirjaaja on mieltynyt ohuemman kuoren osiin kuusista, jolloin laji voi aiheuttaa järeille kuusille latvakuolleisuutta ja nuorten puitten osalta puun kuolemista kokonaan. Kuusentähtikirjaajaa tavataan usein myös samoista puista kuin kirjanpainajaa, jolloin voi olla hyvin vaikeaa määrittellä sitä, kumpi kaarnakuoriainen on ollut ensisijainen tuhon aiheuttaja. (Hedgren 2003, 161.)

Kuusentähtikirjaajan kyky tappaa täysin elinvoimaisia ja hyväkuntoisia kuusia vaikuttaa tutkimusten mukaan heikolta, muttei olemattomalta. Hedgren 2003 tutki, että noin 8 % kuusentähtikirjaajan hyökkäyksen kohteena olevista kuusista kuolivat. Vertailulukuna kirjanpainajalla samassa koeasetelmassa luku oli 64 %. (Hedgren 2003, 164.)

Kuusentähtikirjaajan ottaminen mukaan seurattaviin riskitekijöihin perustuu siten sen kykyyn heikentää puun elinvoimaisuutta toisia tuhonaiheuttajia vastaan, ei niinkään sen omaan kykyyn tappaa puita.

2.3.3 Kaatuneet ja katkenneet puut

Kuten kuvioista 1 sivulla 12 voidaan nähdä, on lumi- ja tuulituhojen merkitys Suomessa suuri. Lumi- ja tuulituhot ovat kumpikin kolmen Suomessa eniten tuhoja aiheuttavan tekijän joukossa.

Myrskytuuli ja lumi voivat kumpikin aiheuttaa niin puiden kaatumisen juurineen tai vaihtoehtoisesti rungon katkeamisen keskeltä. Näistä tuulituhot yleensä vaikuttavat useampaan puuhun kerrallaan kuin lumi, joka taas vaikuttaa keskimäärin useammin yksittäisiin puihin. (Vastaranta ym. 2015, 34.)

Tuulen nopeuksien ei ennusteta kasvavan merkittävästi edes ilmastonlämpenemisskenaarioiden perusteella. Arviot ovat enintään 3 % vuoteen 2050 mennessä. Kuitenkin tuulen nopeuksien pysyessä suunnilleen samoina, arvioidaan tuulituhojen määrän kasvavan, sillä suurempi osa kovista tuulennopeuksista koettelee metsikköä sellaiseen vuodenaikaan, kun routa ei ankkuroi juuria tukevasti maahan. Varsinkin pintajuurinen kuusi on altis tälle routaisen ajan ulkopuoliselle kovalle tuulelle. (Venäläinen ym. 2020, 3.)

Suomessa Euroopan mittakaavalla matalatkin tuulennopeudet voivat aiheuttaa puiden vahingoittumisia silloin, kun puilla on lumikuormasta aiheutuvaa lisäpainoa latvuksessa. Tulevaisuudessa ennustetaan myös sadannan lisääntyvän varsinkin talvella, jolloin se voi tulla niin alijäähtyneenä vetenä kuin myös lumena tarttuen herkästi puiden latvuksiin.

Tämä yhdistettynä vähäisempään roudan määrään voi tarkoittaa varsinkin Etelä-Suomessa kasvavia lumi- ja tuulituhoja. (Gregow ym. 2011, 36-37.)

2.3.4 Muut puitten stressitekijät

Ilmastonmuutoksen myötä monet metsätuho-riskit kasvavat ja vaikuttavat siten puitten yleiseen terveydentilaan. Oikea kasvupaikka puille on erittäin tärkeää puun menestymisen kannalta. Liian karulle kasvupaikalle päätyneet kuusi voi aluksi kasvaa normaalisti, mutta ajan saatossa vähäravinteisen ja kuivan maaperän puuntuotoskyky tyrehtyy ja puun kasvu alkaa hidastua merkittävästi. Kasvunmenetykset on kuitenkin vain ensimmäinen ongelma mitä tästä voi seurata. Vakavimmillaan väärälle kasvupaikalle kasvanut puu on jatkuvasti heikentyneessä tilassa, jolloin puun puolustusmekanismit eivät toimi kunnolla. Tällöin riski kuivuus- ja hyönteistuhonille kasvavat. (Viiri 2020, 2.)

Kuivuuden aiheuttamien vaikeiden kasvuolosuhteiden oletetaan yleistyvän boreaalisissa havumetsissä, sillä ilmastonmuutos aiheuttaa suurimpia muutoksia nimenomaan pohjoisella havumetsävyöhykkeellä. Kuivuus on yleensä yhdistelmä vähäistä sademäärää ja haihduntaa lisäävää korkeaa ilman lämpötilaa. Kuivuus voi aiheuttaa vakavan stressitilan puille, mikä edesauttaa seurannaistuhonien syntymistä. (Martínez-García 2024, 197.)

Runsas pihkavuoto kuusella voi viitata meneillään olevaan puun puolustautumiseen kuoren tullutta vauriota vastaan. Tämä voi indikoida esimerkiksi hyönteisten iskeytymää puuhun, sillä kaivaessaan reiän kuoren läpi hyönteinen laukaisee puun puolustusreaktion eli pihkavuodon. Pihkan lisäksi puu puolustautuu mm. tuottamallaan kemikaaleilla, kuten terpeeneillä. Jos hyönteisten hyökkäys osuu samaan aikaan kuivan kauden kanssa, on puulla kuivuuden takia vähemmän pihkaa käytettävissä puolustautumiseen. Kuitenkin pihkantuottoon näyttää tutkimusten mukaan vaikuttavan myös puun perimä, jolloin pihkantuottokyky on monen tekijän yhdistelmä. (Netherer ym. 2016, 169, 175.)



Kuva 7. Runsas pihkavuoto kuusen rungolla.

Muita kuusen stressitekijöitä on mm. runkonalkeamat, joihin muodostuu puun haavaso-
lukkua sisältävä koro. Runkoon kohdistuva vika alentaa puun rakenteellista lujuutta,
mutta haitallisempi puoli koroissa on se, että haavakohta on sieni-infektioille helppo reitti
kuoren alle. Koro voi siten altistaa puuta muille riskitekijöille. (Zeltinš ym. 2016, 57.)

Puitten välinen kilpailu on tekijä, mikä muokkaa puuta jatkuvasti. Puu reagoi jatkuvasti
siihen, miten paljon sillä on resursseja käytössään ja pyrkii maksimoimaan saatavilla ole-
vien resurssien määrän. Tämä tarkoittaa kilpailutilanteessa enemmän pituuskasvua ja vä-
hemmän läpimitan kasvua ja alaoksia, sillä se on tapa kilpailla auringonvalosta. Siten jos
kilpailua on vähemmän, puu voi käyttää enemmän resursseja läpimitan kasvuun ja säilyt-
tää enemmän alaoksia, sillä sinnekin asti pääsee auringonvaloa ja yhteyttämistä voi ta-
pahtua. (Ahmed ym. 2024, 9-10, 12.)

Kilpailun valosta, vedestä ja ravinteista on tutkittu vaikuttavan puitten selviämiseen esi-
merkiksi kuivuudesta, minkä on jo todettu olevan hyönteistuhoilta altistava tekijä. Siten
liiallisen tiheyden voidaan nähdä jättävän puut heikentyneeseen ja stressaantuneeseen ti-
laan verrattuna puihin, joilla kilpailu resursseista ei ole niin kovaa. Puut toipuvat muista

stressitekijöistä nopeammin, jos ne eivät joudu kilpailemaan resursseista liikaa. (Kohler ym. 2010, 1109.)

Kuusenjuurikäpä aiheuttaa etenkin kuusille kuusentyvilaho-nimistä tautia, missä käpä lahottaa ja heikentää kuusten juuria. Käpä voi toimia huomaamattomana piilossa rungon sisällä vuosikymmeniä kunnes hakkuitten yhteydessä runsas lahon määrä on ensimmäinen vihje sen suuntaan, että metsikköä voi vaivata kuusenjuurikäpä. Kuusenjuurikäpä heikentää puitten juuriston rakenteellista kestävyyttä ja siten edesauttaa mm. tuulituhojen syntymistä. Lisäksi puun elinvoimaisuus heikkenee juuriston kärsiessä lahosta, mutta elävä mantopuu vastustaa kuusenjuurikäpää hyvin pitkään ja siten puu voi jatkaa kasvuun keskellä olevan sydänpuun lahosta huolimatta. (Kuusentyvilaho. n.d.)

Harsuuntuminen on viimeinen tässä käsiteltävä stressitekijä tai oikeastaan stressin ilmentäjä. Harsuuntumisessa puu pudottaa erinäisistä syistä neulasia normaalia neulasten kiertokulkua nopeammin, jolloin puu on silmin nähden harvan näköinen. Neulasten ennenaikainen putoaminen voi johtua monesta eri tekijästä, kuten ilmansaasteista kuivuudesta, sienitaudista, pakkasvauriosta tai myrskytuhosta, joille yhteistä on puun elinvoimaisuuden hetkellinen tai pysyvä heikentyminen. (Solberg ym. 2015, 347).

2.3.5 Häiriö on monen tekijän summa

Hyönteistuoja tarkastellessa on havaittavissa, että hyönteistuoja on yleensä useamman riskitekijän yhtäaikainen toteutuminen, minkä seurauksena hyönteiset pääsevät runsastumaan siinä määrin, että ne pystyvät hyökkäämään terveidenkin puitten kimppuun. Etenkin yhden puulajin tasaikäisissä järeissä kuusikoissa on suurin mahdollinen määrä kirjainpainajalle sopivaa ravinto- ja lisääntymispuuta. Tällaisissa metsissä esimerkiksi ilmaston lämpenemisen takia kuusi on entistä alttiimpi tuulituhoille tai kuivuudelle, mikä mahdollistaa hyönteisten iskeytymisen osaan tai jopa kaikkiin puihin. Kannan runsastuttua esimerkiksi tuulenskaadoilla, voi niitten määrä riittää valtaamaan jo terveitäkin puita ja näin lähtee tuho etenemään metsässä. Myös juurikäpä voi heikentää puita niin, että ne kaatuvat helpommin tuulessa eivätkä silloin pysty puolustautumaan hyönteisiä vastaan. Myös hyönteiset voivat seurata toisiaan, eli esimerkiksi kuusentähtikirjaajan heikentämä puu on

alttiimpi kirjanpainajan hyökkäykselle. Siten eri riskitekijöitä on tarkasteltava kokonaisuutena. (Pukkala 2018, 263)

Kirjallisuusselvityksen ja asiantuntijakyselyn perusteella Nevalainen ja Piri (2020) päätyivät siihen, että keskimäärin tasaikäisrakenteisessa metsänkasvatuksessa riskit ovat hie-
man suuremmat kuin eri-ikäisrakenteisessa metsänkasvatuksessa. Tämän opinnäytetyön kannalta olennaisimpia tuloksia ovat se, että tuulituhoriski oli selvästi suurempi tasaikäisissä kuin eri-ikäisissä kuusikoissa.

Kirjanpainajariski todettiin eri-ikäiskasvatuksessa pienemmäksi johtuen siitä, että eri-ikäiskasvatuksessa kasvaa kerrallaan keskimäärin vähemmän kirjanpainajalle sopivaa jä-
reää runkopuuta. Muita vaikuttavia tekijöitä kirjanpainajan heikommalle menestykselle voivat olla parempi tuulenkestävyys sekä se, että eri-ikäisrakenteinen metsä saattaa suosia
tasaikäismetsiä enemmän kirjanpainajan luontaisia vihollisia. Toisaalta on arveltu, että
eri-ikäisrakenteinen metsätalous voisi suosia ohuemman kuoren alla viihtyviä kuusentäh-
tikirjaajia ja tämä voi johtaa seurannaistuhoihin, kuten kirjanpainajatuhoihin. (Nevalai-
nen & Piri 2020, 2.)

3 KAUKOKARTOITUSMENETELMÄT METSÄTALOUDEN KÄYTÖSSÄ

1990-luvulla metsäorganisaatiot alkoivat ottaa käyttöönsä silloin hiljattain digitoituja kartta-aineistoja osana metsävarojen digitalisaation ensimmäistä vaihetta. Maastokarttojen lisäksi digitoitiin ilmakuvia ja satelliittiaineistoja. 2000-luvulla mukaan tuli lentolaserkeilaus, multispektrikuvaus ja hyperspektrikuvaus eli kapeiden aallonpituusalueiden yhdistäminen yhdeksi kokonaisuudeksi. 2010-luvulla järjestelmät ovat kehittyneet ja esimerkiksi Pohjoismaissa on käyttöön otettu laajojen metsäalueiden kartoitus laserkeilamalla osana digitalisaation toista vaihetta. Suuret metsäorganisaatiot ovat kaikki ottaneet suuressa määrin haltuun digitalisaation tuomia mahdollisuuksia luoda toiminnan tehokkuutta ja asiakaskokemuksen laatua eli niin sanottua täsmämetsätaloutta. (Holopainen 2019, 1.)

Kaukokartoituksen menetelmät nykyäänkin ovat pysyneet pitkälti samoina, vaikka niistä kaikki ovat kehittyneet eteenpäin alkuperäisestä muodostaan. Käytössä ovat laserkeilaus, ilmakuvaus, satelliittikuvaus sekä maastokoealamittaukset tukemassa sitä, miten kuvattu tieto siirretään numeeriseksi dataksi, kuten puustomääräksi. Suomessa kaukokartoitukseen perustuva koko maan inventointi aloitettiin 2010 ja ensimmäinen kierros valmistui 2020. Vuonna 2020 aloitettiin toinen inventointikierros, johon kuuluu laserkeilaus- ja ilmakuvainventoinnit. Laserkeilaus on nopeutunut siinä määrin, että kierroksen oletetaan kestävän 6 vuotta. Ilmakuvainventointi tuotetaan noin 3 vuoden välein. (Metsävaratiedon laatuseloste 2023, 3.)

Vuonna 2026 alkaa suunnitelmien mukaan kolmas kansallinen inventointikierros, joka kestää vuoteen 2031 asti. Tällä hetkellä hankkeen toteutusta suunnitellaan ja siinä käytettäviä laitteistoja arvioidaan. Hankkeen osapuolina ovat Suomen Metsäkeskus, Metsähallituksen Metsätalous Oy ja Maanmittauslaitos. Tavoitteina tulevalla inventointikierroksella on saavuttaa myös eri inventointeja vertaamalla tietoa esimerkiksi kasvupaikkojen ravinteisuudesta perustuen siihen, miten alueen puiden pituuskasvu korreloi eri ravinteisuustasojen kanssa. Tavoitteena on myös tunnistaa monimuotoisuutta ilmentäviä rakennepiirteitä, kuten säästöpuita, kuolleita ja lahoppuita sekä poikkeuksellisia puuyksilöitä, kuten järeitä lehtipuita. (Metsäkeskus 2024)

Kaukokartoituksella on täysin mahdollista päästä niin sanottuun yksin puin tulkintaan, eli sellaiseen tulkintaan, missä jokainen puu pystytään tunnistamaan omana erillisenä yksilönä niin, että sille määritellään mm. pituus, läpimitta sekä puulajitieto. Kuitenkin laadullisten ja kaukokartoitusaineiston tulkinnallisten haasteiden lisäksi yksi tämän hetken ongelmista yksinpuintulkinnan yleistymiselle on kustannus, sillä tulkinnan on tuotettava riittävästi lisäarvoa tuottajalleen ollakseen kannattava investointi. Toisin sanoen yksinpuintulkinnasta on oltava jotain sellaista konkreettista hyötyä, mitä muut kaukokartoitusmenetelmät eivät pysty tuottamaan. (Holopainen 2019, 6.)

Suomen valtakunnan metsien inventointien kannalta yksinpuintulkinta nähdään myös seuraavana kehitysaskeleena. Tälläkin hetkellä kerätyn metsävaratiedon taloudelliseksi hyödyksi metsäalan toimijoille ja metsänomistajille on arvioitu olevan kymmenistä miljoonista aina 100 miljoonaan euroon asti. Metsävaratieto tuottaa jo nykyiselläänkin tietoa puuston määrästä, puulajeista, puulajijakaumasta, puuston koosta ja siten puuston määrästä per hehtaari. Näitä tietoja käytetään niin hakkuusuunnitelmien tekemiseen kuin myös esimerkiksi taimikoitten hoitotöiden ajoittamiseen ja jopa metsien tila-arvioiden tekemiseen. (Metsäkeskus 2024)

Yksinpuintulkinnan nähdään tuottavan parempaa tietoa metsän sisäisestä rakennevaihtelusta, eli saadaan parempi kuva puuston kerroksellisuudesta ja tilajärjestyksestä. Myös puulajien määrittämisen odotetaan paranevan, jolloin arvokkaita rakennepiirteitä pystytään tunnistamaan aiempaa paremmin kaukokartoitusaineistosta. Myös säästöpuiden ja lahopuiden tulkinta tarkentuu ja tarkemmalla puustotiedolla voidaan luotettavammin määrittellä puuston hiilitasetta. (Metsäkeskus 2024)

3.1 Lentolaserkeilaus (Airborne Laser Scanning, ALS)

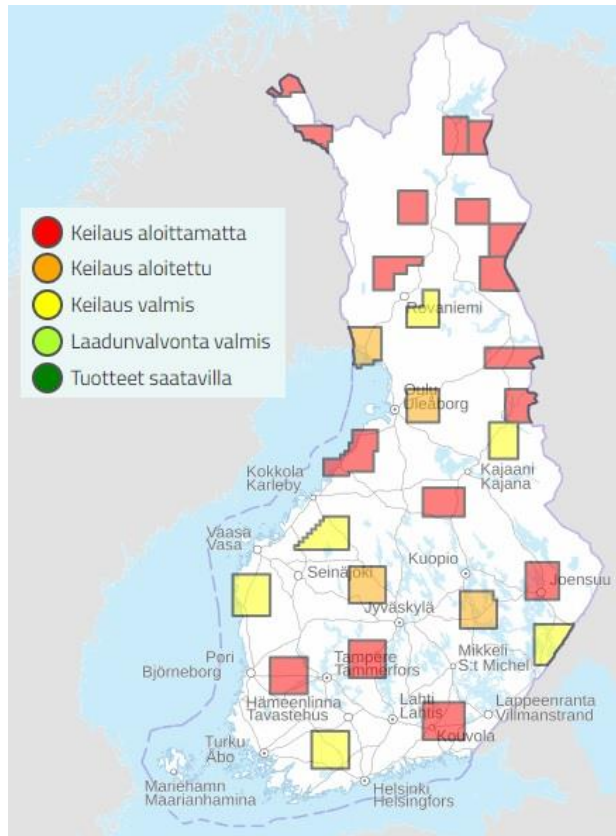
Lentolaserkeilauksessa lennetään yleensä joko lentokoneella, helikopterilla tai droonilla inventoitavan alueen päältä ja keilataan sitä samalla lähi-infrapunan (near-infrared, NIR) aallonpituudella toimivalla laserilla. Käytännön tasolla laserkeilain määrittää kohteen ja laserin välisen etäisyyden. Kun mittauspisteitä on riittävästi ja laitteen sijainti tiedetään tarkasti, voidaan sillä määrittää esimerkiksi erotus alimman ja ylimmän pisteen välillä.

Ylin pistepilvi metsikössä kuvaa puuston latvuksen tasoa ja siitä käytetään nimitystä pintamalli (engl. Digital Surface Model, DSM). Vastaavasti alin pistepilvi kuvaa maan pinnan tasoa ja siitä käytetään nimitystä maastomalli (engl. Digital Terrain Model, DTM). Kun ylimmästä pistepilvestä vähennetään alin pistepilvi, saadaan näiden kahden erotuksena puuston pituus eli latvusmalli (engl. Canopy Height Model, CHM). (Holopainen ym. 2015, 37-38.)

Laserkeilausinventointi voidaan jakaa kahteen menetelmään: aluepohjaiseen ja yksinpuin tulkintaan (Holopainen ym. 2015, 38). Lentolaserinventoinnilla mitattu pistepilvi saadaan aluepohjaisessa menetelmässä muunnettua puustotunnukseksi ainoastaan siten, että maastosta mitataan referenssikoealoja (Raitila ym. 2021, 13). Yksi yleisesti käytetyistä menetelmistä on ollut *k*-lähimmän naapurin menetelmä (*k*-nearest neighbour, *k*-nn). Siinä laserkeilattuja aloja verrataan toisiinsa ja pyritään löytämään mahdollisimman paljon toisiinsa muistuttavia keilaustietoja. Sitten kun vähintään yhdeltä näistä aloista löytyy myös maastomittauksena tehty maastomittaustieto, siirretään tämä tieto myös niille aloille, joilta ei löydy maastomittaustietoa. (Hyvönen 2002, 364)

Lentolaserkeilaus tuli mukaan kaukokartoituksen kokonaisuuteen ilmakuvien jälkeen ja sen suurin hyöty lieneekin kaksiulotteisen ilmakuvan muuttuminen kolmiulotteiseksi, sillä lentolaserkeilauksella saadaan puustolle määriteltyä korkeus ja siten tilavuus. Laserkeilauksen tarkkuus on tutkimusten mukaan vähintään yhtä hyvä kuin perinteisesti käytetyllä maastoinventoinnilla, jossa ihminen määrittelee maastossa tunnuslukuja, joilla lasjetaan puuston tilavuutta. (Raitila ym. 2021, 8-9.)

Suomen Metsäkeskus on lentolaserkeilannut Suomen metsiä erityisesti yksityismetsien osalta vuodesta 2010 alkaen. Oheisessa kuvassa on nähtävissä toisen laserkeilauskierroksen kattavuus vuonna 2024 (Maanmittauslaitos n.d.). Käytännön tasolla työ sisältää laserkeilauksen noin 1,5-2 kilometrin korkeudesta ja nykyisin ollaan siirretty aiemmasta harvapulssikeilauksesta tiheäpulsseilaukseen. Nykyisin käytettävä pistetiheys on 5 havaintopistettä per neliometri, mikä riittää jo yksinpuintulkintaan. (Metsävaratiedon laatuseloste 2023, 5.) Yksinpuintulkintaa edeltävässä aluepohjaisessa harvapulssikeilauksessa oli tulkinnaassa käytössä 0,5-2 pulssia neliometriä kohden (Raitila ym. 2021, 11).



Kuva 8. Laserkeilauksen tilanne vuonna 2024 (Maanmittauslaitos n.d.).

Puustotulkinnan tavoitetarkkuus on puuston pohjapinta-alan mittauksessa $\pm 3 \text{ m}^2/\text{ha}$, keskiläpimitan mittauksessa $\pm 3 \text{ cm}$, keskipituuden mittauksessa $\pm 2 \text{ m}$ ja vähintään nuorten kasvatusmetsien osalta puuston keskitilavuuden mittauksessa $\pm 20 \%$ kahdeksassa tapauksessa kymmenestä (80%). Laadunvarmistusmittausten perusteella edellä mainittuun tarkkuuteen on päästy pohjapinta-alassa noin 85 % tapauksista, läpimitassa ja tilavuudessa 90 % tapauksista ja pituudessa yli 95 % tapauksista. (Metsävaratiedon laatuseloste 2023, 7.)

Suurimmat virheen mahdollisuudet puustotulkinnassa ovat nuorissa, alle 2 m pituisissa taimikoissa sekä hoitamattomissa metsissä. Hoitamattomista metsistä varsinkin nuoret kasvatusmetsät ovat haastavia. Metsikön pääpuulajia heikommin saadaan arvioitua ne puulajit, joita metsikössä on vähän. (Metsävaratiedon laatuseloste 2023, 8.)

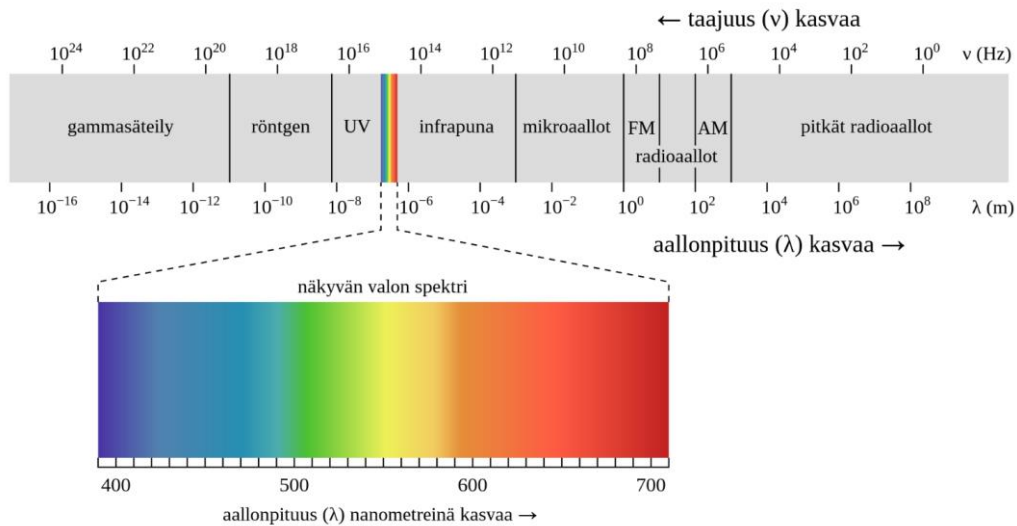
Hyönteistuhosovelluksen kannalta laserkeilauksella pystytään kyllä tulkitsemaan 3D-aineistoon perustuvilla menetelmillä kohdealueella tapahtuneita muutoksia, kuten myrskyn

tai muun metsätuhon tekemiä muutoksia puuston rakenteeseen. Kuitenkin inventointikierron ollessa tällä hetkellä 6 vuotta, ei laserkeilauksen ajallinen toistuvuus riitä tuhon ajantasaiseen tai ennakoivaan seurantaan. (Holopainen 2019, 3.) Hyönteistuhosovelluksen kannalta hyödyllistä on kuitenkin lentolaserkeilauksen tuottama pääpuulajitieto, jota pystytään tuottamaan oikein noin 95 % kuvioista (Metsävaratiedon laatuseloste 2023, 7).

3.2 Multispektrikuvaus ja Sentinel-2 satelliitti

Multispektrinen kuvaus (Multispectral imaging, MSI) on käytössä laajasti kaukokartoituksessa niin lentokaukokartoituksessa kuin myös satelliittikaukokartoituksessa. Multispektrinen kuvaus tarkoittaa sitä, että samanaikaisesti kuvataan kohdetta käyttäen useampaa eri aallonpituuden sensoria. Useimmiten aallonpituuksista on mukana kolme tai neljä näkyvän valon aallonpituutta mitä täydennetään vähintään yhdellä infrapuna-aallonpituudella. Infrapuna-aallonpituuksista voi olla käytössä esimerkiksi lähi-infrapuna (NIR) tai lyhytaaltoinfrapuna (SWIR). Multispektrikuvauksessa laite ei lähetä mitään elektromagneettista säteilyä eli se on toiminnaltaan passiivinen kamera, joka havaitsee auringon valon heijastumia kuvattavasta kohteesta. (Luotamo 2023, 14.)

Sähkömagneettisessa säteilyssä välittäjähiukkasena toimii fotoni ja sähkömagneettinen säteily on etenemissuuntaa vasten kohtisuoraa värähtelyä. Säteilyn energia muodostuu suoraan taajuuden mukaan, mutta aallonpituus on kääntäen verrannollinen taajuuteen nähden. Siten suurempi taajuus tarkoittaa pienempää aallonpituutta. Aine voi absorboida eli imeä itseensä sähkömagneettista säteilyä tai se voi myös heijastaa, taittaa tai sirottaa sitä. (Sähkömagneettinen säteily n.d.).



Kuva 9. Sähkömagneettisen säteilyn aallonpituudet (Sähkömagneettinen säteily n.d.).

Sentinel-2 -satelliitit (Sentinel-2A ja Sentinel-2B) ovat Maan kiertoradalle lähetettyjä satelliitteja, joilla on molemmilla kyky multispektrikuvaukseen. Niillä on multispektrikuvauksessa käytössään 13 kanavaa, joilta ne pystyvät tallentamaan tietoa ja ne kuvaavat saman kohdan Maan pinnasta 5 päivän välein. Kuvattavan alueen leveys kerrallaan on 290km. Sentinel-2 -satelliittien resoluutio on pienimmillään 10 m, eli 10 m x 10 m on pienin ala miltä satelliitit voivat tuottaa tietoa. (Introducing Sentinel-2 n.d.)

Sentinel-2 -satelliittien päätehtävä on ympäristön ja maatalouden tilan kaukokartoittaminen. Sentinel-2A laukaistiin vuonna 2015 ja Sentinel-2B vuonna 2017. Sentinel-2 -satelliitit tuottavat tietoa kasvien fysiologisista prosesseista kuten veden haihdunnasta, fotosynteesistä eli yhteyttämisestä, kasvien kasvusta ja jopa ravintosisällöstä. (Segarra ym. 2020, 3-4.)

Segarra ym. 2020 esittelevät Sentinel-2 -satelliitin multispektrikuvauksen käyttämiä kanavia ja niiden ominaisuuksia. Jokaiselle kanavalle on kanavatunnus (B1-B12) ja nimen tarkenne. Kanavat B2-B4 ovat näkyvän valon kanavia. Niihin kuuluu sininen (blue), vihreä (green) ja punainen (red). Infrapuna-alueelta näkyvän valon vierestä löytyy neljä kanavaa punareunan (engl. Red edge) aallonpituutta B5-B7, kasvillisuuden punareuna B8A ja lähi-infrapuna B8 (engl. Near Infrared, NIR). Kanavat B11 ja B12 ovat lyhytaaltoinfrapun kanavia (shortwave infrared, SWIR). Kanavat B1 rannikkoaerosoli, B9 vesihöyry ja B10 Cirrus lyhytaaltoinfrapuna ovat tarkoitettu pilvien, vesihöyryn ja muiden ilmaston

kuvaa vääristävien elementtien vaikutuksen poistamiseen. Jokaiselle kanavalle on määritetty spatiaalinen resoluutio (spatial resolution), eli pienin tarkkuus millä havaintoja pystytään tekemään. Kaistoille on myös määritetty käytetyn aallonpituuden keskikohta (central wavelength) ja kanavan leveys (bandwidth). (Segarra ym. 2020, 4.)

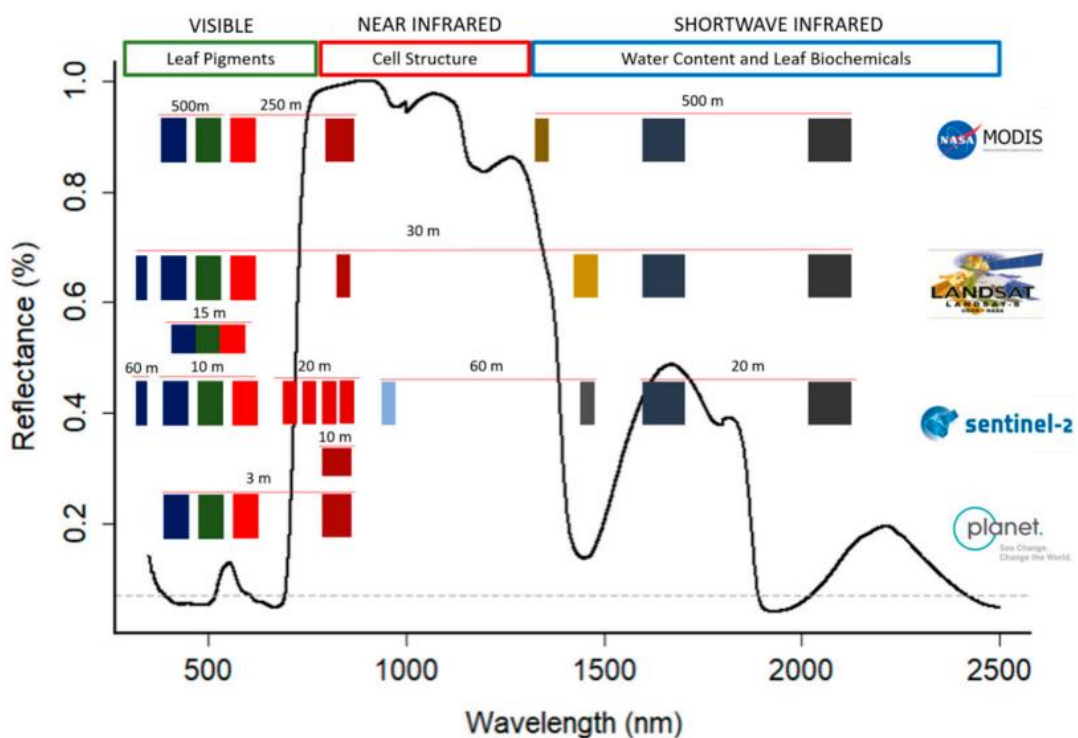
Taulukko 1. Sentinel-2 -satelliitin käyttämät multispektrikuvauksen resoluutiot, keskimäiset aallonpituudet ja kaistanleveydet (Segarra ym. 2020, 4).

MSI Band	Spatial Resolution (m)	Central Wavelength (nm)	Bandwidth (nm)
B1: Coastal Aerosol	60	443	20
B2: Blue	10	490	65
B3: Green	10	560	35
B4: Red	10	665	30
B5: Red-Edge	20	705	15
B6: Red-Edge	20	740	15
B7: Red-Edge	20	783	20
B8: NIR	10	842	115
B8A: Vegetation RE	20	865	20
B9: Water Vapor	60	945	20
B10: SWIR Cirrus	60	1375	30
B11: SWIR	20	1610	90
B12: SWIR	20	2190	180

Osa multispektrikuvauksen aallonpituuksista tuottaa suoraa mitattavaa tietoa kun taas toiset suureet joudutaan laskemaan muista mitattavista ominaisuuksista. Väripigmentit havaitaan aallonpituuksilla 400-700 nm (nanometriä, 1×10^{-9} m). Lehtien rakenteita havaitaan aallonpituuksilla 700-1100 nm. Kasvien vesipitoisuus, typpipitoisuus ja lehtimassan peittävyys eli lehtialaindeksi (Leaf Area Index, LAI) havaitaan aallonpituuksilla 1100-2400 nm. (Abdullah ym. 2019, 88.)

Näkyvän punaisen valon ja lähi-infrapun välimaasto on kasvillisuuden tutkimuksessa olennainen. Sen vakiintunut nimi on englanniksi ”Red edge”, eli suomennettuna punareuna. Punareuna alkaa punaisen valon puolelta noin 670 nm kohdalta ja jatkuu noin 760 nm asti. Punareunan alueella vihreän valon heijastuminen muuttuu erittäin nopeasti aallonpituuden muuttuessa ja tämä alue on siksi erityisen tärkeä kasvillisuuden stressitilan selvittämisessä. Käytännössä lehtivihreä imee punareunavaloa tehokkaasti itseensä, joten lisääntynyt heijastus indikoi vahvasti vähentynyttä lehtivihreää. Tämän heijastuksen avulla lasketaan normalisoitu kasvillisuusindeksi (engl. Normalized Difference Vegetation Index, NDVI) sekä normalisoitu punareunaerotus -kasvillisuusindeksi (engl. Normalized Difference Red-edge Vegetation Index, NDRE). (Ohlinger 2021.)

Näkyvän valon ja lähi-infrapunavälillä on mahdollista tulkita lehtialaindeksiä, lehtivihreän määrää (Leaf Chlorophyll Content, LCC) ja lähi-infrapunavälillä ja infrapunavälillä punaisen reunan avulla voidaan tulkita fotosynteesin tuotos erillisenä kasvin biomassasta. Lyhytaaltoinfrapuna taas imeytyy silloin kun säteily kohtaa vettä, jolloin kyseisillä aallonpituuksilla voidaan määrittää vesipitoisia osia kasvillisuudesta. Sen sijaan typen määrää ei voida suoraan mitata, sillä vesi estää typen suoran havaitsemisen. Siten typen määrä joudutaan laskemaan esimerkiksi lehtivihreän indikaattoreita käyttäen, kun tiedetään lehtivihreään sitoutunut typen määrä. Tarkastusmittauksilla on todettu, että esimerkiksi typen määrän epäsuora laskentakin on ollut varsin tarkkaa. (Segarra ym. 2020, 2, 6-7.)



Kuvio 2. Neljän eri satelliitin mitaamia aallonpituuksia sekä kuvaaja, joka näyttää kasvillisuuden heijastamaa säteilyä kyseisillä aallonpituuksilla (Segarra ym. 2020, 6).

Eri laskettavia indeksejä ovat mm. NDRE (normalisoitu punareunaerotus kasvillisuusindeksi), GLI (lehtipeiteindeksi), GNDVI (normalisoitu vihreäerotus kasvillisuusindeksi), NDVI (normalisoitu kasvillisuusindeksi), NGRDI (normalisoitu punavihererotus kasvillisuusindeksi), CIG (lehtivihreäindeksi), PGR (kasvien pigmenttisuhde), DSWI (sairastumisstressin vesi-indeksi), LWCI (lehtien vesipitoisuusindeksi), NDWI (normalisoitu infrapunaerotus indeksi), SW-SWIR (yksinkertaisen suhteen lyhytaaltoinfrapuna) ja RDI (kuivuusindeksin suhde) (Abdullah ym. 2018, 96).

Taulukko 2. Sentinel-2:n ja Landsat-8:n tiedoista laskettavat kasvillisuusindeksit. (Abdullah 2019, 90-91)

Index	Sensor		Equation	Reference
	Landsat-8	Sentinel-2		
(chlorophyll, pigments, greenness)				
Canopy Chlorophyll Content Index (CCCI)	x	✓	$\frac{NIR - Rededge1}{NIR + Rededge1}$ ----- $\frac{NIR - Red}{NIR + Red}$	(Barnes et al., 2000)
Chlorophyll Green (Chlgreen)	x	✓	$\left(\frac{Rededge3}{Green}\right)^{-1}$	(Gitelson et al., 2006)
Leaf Chlorophyll Index (LCI)	x	✓	$\frac{NIR - Rededge1}{NIR + Red}$	(Pu et al., 2008)
Normalized Difference Red-Edge 2 (NDRE2)	x	✓	$\frac{NIR - Rededge1}{NIR + Rededge1}$	(Haboudane et al., 2004)
Normalized Difference Red-Edge 3 (NDRE 3)	x	✓	$\frac{NIR - Rededge2}{NIR + Rededge2}$	This study
Chlorophyll vegetation index (CVI)	✓	✓	$NIR \left(\frac{Red}{Green^2}\right)$	(Vincini et al., 2008)
Green Difference Vegetation Index (GDVI)	✓	✓	$NIR - Green$	(Tucker et al., 1979)
Green leaf index (GLI)	✓	✓	$\frac{2 \times (Green - Red - Blue)}{2 \times (Green + Red - Blue)}$	(Gobron et al., 2000)
Green Normalized Difference Vegetation Index (GNDVI)	✓	✓	$\frac{NIR - Green}{NIR + Green}$	(Fu et al., 2008)
Normalized Difference Vegetation Index (NDVI)	✓	✓	$\frac{NIR - Red}{NIR + Red}$	(Tucker, 1979)
Normalize Green (NG)	✓	✓	$\frac{Green}{(NIR + R + Green)}$	This study
Normalized Difference Green/Red Normalized green red difference index (NGRDI)	✓	✓	$\frac{Green - Red}{Green + Red}$	(Hunt et al., 2011)

(jatkuu)

Normalized Difference NIR/Blue Blue-normalized difference vegetation index (BNDVI)	✓	✓	$\frac{NIR - BLUE}{NIR + BLUE}$	(Hancock and Dougherty, 2007)
Simple Ratio Blue / Red (SR-Blue/Red)	✓	✓	$\frac{Blue}{Red}$	This study
Chlorophyll index green (CIG)	✓	✓	$\left(\frac{NIR}{Green}\right) - 1$	(Gitelson et al., 2003)
Green Index (GI)	✓	✓	$\frac{Green}{Red}$	(Gamon and Surfus, 1999)
Plant biochemical index (PBI)	✓	✓	$\frac{NIR}{Green}$	This study
Coloration Index (CI)	✓	✓	$\frac{(RED - BLUE)}{RED}$	(Escadafal et al., 1994a)
Plant pigment ratio (PGR)	✓	✓	$\frac{Green - BLUE}{Green + BLUE}$	(Metternicht, 2003)
Water indices				
Disease Stress water index (DSWI)	✓	✓	$\frac{NIR + Green}{SWIR + Red}$	(Galvao et al., 2005)
Vegetation Moisture Index (VMI)	✓	✓	$\frac{(NIR + 0.1) - (SWIR + 0.02)}{(NIR + 0.1) + (SWIR + 0.02)}$	(Ceccato et al., 2002)
Leaf Water Content Index (LWCI)	✓	✓	$\frac{\log(1 - (NIR - SWIR))}{-\log(1 - (NIR - SWIR))}$	(Cohen, 1991)
Normalized Difference Infrared Index (NDWI)	✓	✓	$\frac{NIR - SWIR}{NIR + SWIR}$	(Hardinsky and Lemas, 1983)
Simple Ratio SWIR (SR-SWIR)	✓	✓	$\frac{SWIR1}{SWIR2}$	This Study
Ratio Drought Index (RDI)	✓	✓	$\frac{SWIR1}{NIR}$	(Pinder and McLeod, 1999)

Sentinel-2 -satelliittien tuottama multispektridata ei ole tarpeeksi tarkkaa, jotta yksittäisistä kasveista, kuten puista, saataisiin tarkkaa yksilöityä tietoa. Sentinel-2:ssa ei myöskään ole mahdollisuutta lämpökuvatulkintaan, mikä voisi auttaa havaitsemaan haihduntaa ja veden määrään liittyvää kasvillisuuden stressitilaa. Muitten satelliittien tuottamaa dataa voidaan halutessa yhdistää Sentinel-2:n tuottamaan tietoon, jotta saadaan kattavampi kokonaiskuva mitattavasta määreestä. (Segarra ym. 2020, 10, 12.)

3.3 Hyönteistuhojen havaitseminen kaukokartoituskeinoin

Kaukokartoitus tarjoaa nykyään toimiviksi havaittuja menetelmiä alkavien kaarnakuori-aistuhojen havaitsemiseksi. Myös EU kannustaa jatkuvaan tilanteen tarkkailuun laajoilla pinta-aloilla. Suurin hyöty mitä kaukokartoituksella on tarjota, on sen kattavuus, sillä maastotöillä ei ole käytännön syistä mahdollisuutta kartoittaa yhtä laajoja pinta-aloja kuin kaukokartoituksella. (Migaz-Mazur 2021, 1-2.)

Kaukokartoituksella on mahdollista havaita lehtipeitteen kattavuutta, lehtien lehtivihreän osuutta, vedenpuutosstressiä, lehtikatoa ja neulaskatoa sekä toki kuolleita pysty- ja maapuita. Abdullah ym. 2018 havaitsivat, että puitten häiriintynyttä tilaa indikoi se, että neulasissa oli vähemmän lehtivihreää ja vettä, mutta sama määrä typpeä ja kuivamateriaalia. Havaintojen vertaaminen maastotarkastuksiin osoitti, että 67 % oireilevista puista kärsi hyönteisten hyökkäyksestä. (Migaz-Mazur 2021, 2-3.)

Kasvillisuuden kokema stressi näkyy kasvista heijastuvan valon aallonpituudessa. Esimerkiksi lehtivihreän alhainen määrä ja typpivaje voidaan havaita näkyvän valon, erityisesti punaisen ja vihreän, aallonpituuksilla. Lähi-infrapuna (NIR) ja lyhytaaltoinfrapuna (SWIR) ovat taas hyvin käytettyjä biomassan sekä vesi- ja typpipitoisuuksien arviointiin. (Abdullah ym. 2018, 88)

Tutkimuksessaan Abdullah ym. 2018 tutkivat 40 tervettä ja 21 kirjanpainajan saastuttamaa 30 m x 30 m koalaa, joista mitattiin puitten rinnanympärysläpimitta, latvuksen peittävyys, puuston pituus ja puuston tiheys. Alueelta analysoitiin myös lehtivihreän määrä, lehtien tai neulasten vesipitoisuus, lehtien tai neulasten kuivamateriaalin määrä ja lehvästön typpipitoisuus. Alueitten kaukokartoitukseen käytettiin kahden eri satelliitin tuottamaa dataa, joista Sentinel-2 on tämän työn kannalta olennaisempi kuin Landsat-8 siitä syystä, että Metsä Groupin ja CollectiveCrunchin sovellus käyttää Sentinel-2:n tuottamaa dataa. Sentinel-2:n kanavista käytettiin 10 m resoluutioisia kanavia 2, 3, 4 ja 8, jotka muokattiin 20 m resoluutiolle ja yhdistettiin kanaviin 5, 6, 7, 9, 12 ja 13, jotka toimivat 20 m resoluutiolla. Kanavia 1, 10 ja 11 ei käytetty, sillä niitä käytetään yleensä ilmakehän tutkimiseen. (Abdullah ym. 2018, 89.)

Abdullah ym. 2018 havaitsivat tutkimuksessaan, että Sentinel-2:n tuottama eri aallonpituuksien spektrien avulla laskettavat kasvillisuuden indeksit (enlg. Spectral Vegetation Indice, SVI) olivat toimivia erottelemaan terveet puut häiriintyneistä. Erityisesti punareunaerotusta hyödyntävät kasvillisuusindeksit NDRE 2 ja 3 olivat käyttökelpoisia kuten myös vesipitoisuuteen liittyvät indeksit SW-SWIR, NDWI, DSWI ja LWCI. Tutkimuksessa verrattiin myös Sentinel-2:n tuottamaa tiedon hyödynnettävyyttä Landsat-8 -satelliittiin ja todettiin, että Sentinel-2:n tuottamat tulokset vastasivat 67 % maastohavaintoihin kun taas Landsat-8:n vastaava luku oli 36 %. (Abdullah ym. 2018, 88.)

Tutkimuksen tuloksina havaittiin merkittävät erot lehtien lehtivihreän ja lehtien tai neulasten vesimäärässä, mutta typpimäärässä taas ei havaittu merkittävää eroa. Lehtien kuivamassan määrä myös oli merkittävästi korkeampi hyönteisten hyökkäyksen alaisten puitten osalta. Sentinel-2:n datalla havaittiin merkittäviä eroja niin yksittäisten neulasten kuin koko lehvästönkin osalta kun taas Landsat-8:n osalta erottelukyky ei kunnolla riittänyt punaisen, lähi-infrapunan tai lyhytaaltoinfrapunien kanaville. (Abdullah ym. 2018, 93-94.)

Analysoinnin jälkeen Sentinel-2:n tuottamasta datasta laskettavista indikaattoreista hyönteistuhojen havainnointiin käyttökelpoisiksi todettiin soveltuvan NDRE-2, NDRE-3, GLI, GNDVI, NDVI, NGRDI, CIG, PGR, DSWI, LWCI, NDWI, SW-SWIR, RDI, punainen, punareunaerotukset 1 & 2, NIR ja SWIR1. NDRE-2 ja NDRE-3 olivat Sentinel-2:n merkittävimmät kanavat alkavan kolonisaation havaitsemisessa ja SWIR sen sijaan merkittävin nestevirtausten heikkenemisen havaitsemisessa. (Abdullah ym. 2018, 96.)

Lämpökameran käyttökelpoisuuden spekuloitiin olevan tutkimuksen arvoinen seuraava askel. Sentinel-2:n tuottaman 67 % osumatarkkuuden todettiin olevan riittävä siihen, että sen perusteella voidaan havahtua uusien riskialueiden ilmaantumiseen, mutta puhtaasti sen tuottaman datan perusteella ei ole syytä tehdä metsänhoidollisia päätöksiä. Siten se on erittäin hyvä työkalu siihen, että maastokäynnit osataan ohjata suurimman riskin alueille. (Abdullah ym. 2018, 98-99, 102.)

Jamali ym. 2023 havaitsivat tutkimuksessaan, että merkittävin osa kasvillisuusindikaattoreista oli muuttunut merkittävästi 15-31 päivän jälkeen kirjanpainajapopulaation parveilusta. Kasvillisuusindikaattoreista he havaitsivat lyhytaaltoinfrapun (SWIR) olevan

paras. Lähi-infrapuna (NIR), punainen näkyvä valo ja punareuna olivat myös käyttökelpoisia. He myös tutkivat, kuinka monta kuollutta puuta tarvittiin 10 m x 10 m pikselillä. He päätyivät siihen, että käyttäen normalisoitua puna-lyhytaaltoinfrapunaerotus kasvillisuusindeksiä (Normalized Distance Red & SWIR, NDRS) keskimäärin 9 kolonisoitua puuta per pikseli riitti positiiviseen havaintoon. Käyttäen normalisoitua kasvillisuusindeksiä (NDVI) tarvittiin keskimäärin 14 kolonisoitua puuta positiiviseen havaintoon. (Jamali ym. 2023, 352-353.)

3.3.1 Kaukokartoitus laajamittaisessa käytössä hyönteistuhojen havaitsemisessa

Jamali ym. 2023 päätyivät tutkimuksessaan siihen, että Sentinel-2:n spektrinen data laajalta alueelta viiden päivän kiertoajalla on riittävä laajaa pinta-alaa havaitsevan aikaisen varoituksen järjestelmien kehittämiseen, jollaiseksi Metsä Groupin ja CollectiveCrunchin sovellus lasketaan. Kuitenkin 10 m x 10 m resoluutiosta seuraa omat haasteensa, kuten se, että yhdellä pikselillä on oltava 9-14 kuollutta riittävän kokoista puuta positiivisen havainnon tekemiseksi. Samaten jos puusto ja siten puuston latvuspeittävyys on kovin pientä, on oikein luokiteltuja havaintoja haastavampaa tehdä. (Jamali ym. 2023, 364.)

Todellinen muutos metsässä ei ole ainoa syy, mikä voi johtaa kaukokartoitustiedon muutoksiin kuvauskertojen välillä. On hyväksyttävä, että dataan tulee kaukokartoituskerralle omaleimaisia häiriöitä, jotka eivät toistu joka kuvauskerralla samanlaisina. Siten on pysyttävä suodattamaan näitä olosuhdemuutoksia datasta virheellisten tulkintojen minimoimiseksi. Käyttökelpoisinta onkin, jos kaukokartoitustietoa käytetään hyönteistuhokartan sijasta ennemminkin kohonneen riskin karttana, jolloin maastoaskeleet voidaan sen mukaan ohjata riskialteimmille alueille. (Jamali ym. 2023, 364.)

3.3.2 Kaukokartoitustiedon luotettavuuden metriikka

Kaukokartoituksen luotettavuutta voidaan analysoida käyttämällä kokonaistarkkuutta (engl. Overall Accuracy), käyttäjän tarkkuutta (engl. User's Accuracy), tuottajan tark-

kuutta (engl. Producer's Accuracy) sekä kappa-kerrointa (engl. Kappa Coefficient). Tilannetta voidaan havainnollistaa käyttämällä virhematriisia, johon merkitään oikein ja väärin tunnistetut luokitukset. (Accuracy Metrics 2014.)

Taulukko 3. Esimerkki virhematriisista (Accuracy Metrics 2014, muokattu)

		Referenssidata			
		Vesi	Metsä	Asutus	Yht.
Luokiteltu data	Vesi	21	6	0	27
	Metsä	5	31	1	37
	Asutus	7	2	22	31
	Yhteensä	33	39	23	95

Oheisen virhematriisiesimerkin kohdalla kokonaistarkkuus kertoo sen, kuinka hyvin käytetty luokittelutapa on onnistunut luokittelemaan kohteet oikein. Virhematriisissa luokitukset, jotka ovat referenssidatassa ja luokitellussa datassa samassa sarakkeessa ovat oikein luokiteltu ja ovat korostettu keltaisella värillä. Siten taulukosta 3 näemme, että oikein luokiteltuja kohteita on $21 + 31 + 22 = 74$. Kohteita yhteensä taas on luokiteltu $27 + 37 + 31 = 95$. Kokonaistarkkuus, joka yleensä ilmoitetaan prosentteina, lasketaan jakamalla oikein luokitellut kaikilla luokitelluilla kohteilla, jolloin esimerkin tilanteessa kokonaistarkkuus on $74 / 95 * 100 \% = 0,778\dots$ eli noin 78 %. (Accuracy Metrics 2014.)

Käyttäjän tarkkuus tarkastelee käyttäjän näkökulmasta sitä, kuinka usein saapumalla maastossa kohteen luo, on kohde luokituksen mukainen todellisuudessaakin. Siten oheisen virhematriisin kohdalla käyttäjän kannalta esimerkiksi vesialueista oli oikein luokiteltu 21 ja väärin luokiteltu 6, jolloin vesialueita on yhteensä 27. Siten käyttäjän kannalta käyttäjän tarkkuus prosentteina vesialueille on $21 / 27 * 100 \% = 78 \%$. Vastaavasti metsillä

oikein on 31, väärin $5 + 1 = 6$ ja yhteensä luokituksia on 37 jolloin tarkkuus prosentteina on $31 / 37 * 100 \% = 84 \%$. Asutuksen kohdalla taas oikein on 22, väärin $7 + 2 = 9$ ja luokitteluja yhteensä 31. Siten tarkkuus prosentteina on $22 / 31 * 100 \% = 70 \%$. (Accuracy Metrics 2014.)

Tuottajan tarkkuus taas tarkastelee tuottajan näkökulmasta sitä, kuinka usein todellinen maastossa oleva ominaisuus saadaan luokiteltua oikein. Siten sen laskenta on hieman erilainen kuin käyttäjän tarkkuus. Vesialueitten kohdalla oikein on luokiteltu samat 21 kohdetta, mutta 5 todellisuudessa metsäistä kohdetta ja todellisuudessa 7 asutuskohdetta on luokiteltu väärin. Tällöin luokituksia on tehty yhteensä 33. Siten tuottajan tarkkuus prosentteina vesialueitten osalta on $21 / 33 * 100 \% = 64 \%$. Metsäalueiden kohdalla vastaavasti oikein on yhä 31 kohdetta, väärin on $6 + 2 = 8$ kohdetta ja kohteita yhteensä on 39. Siten tuottajan tarkkuus prosentteina metsien kohdalla on $31 / 39 * 100 \% = 80 \%$. Asutuksen kohdalla yhä 22 kohdetta on oikein, väärin on 1 ja kohteita yhteensä on 23. Siten tuottajan tarkkuus prosentteina asutuksen kohdalla on $22 / 23 * 100 \% = 96 \%$. (Accuracy Metrics 2014.)

Kappa-kerroin taas määrittelee sitä, kuinka hyvin luokittelu onnistuu suhteessa sattumanvaraisuuteen. Kappa-kerroin voi olla välillä -1 ja 1. Kappa-kerroin 0 on tasan yhtä hyvä kuin sattumanvarainen arvaus. Mitä positiivisempi kappa-kerroin on, sitä paremmin luokittelu on onnistunut verrattuna sattumaan. Vastaavasti negatiivinen kappa-kerroin tarkoittaa sitä, että sattumanvarainen arvauskin on parempi kuin käytetty luokittelu. (Accuracy Metrics 2014.)

Kaukokartoituksen onnistumisesta esimerkiksi Meddens ym. 2013 artikkelissaan ”Evaluating methods to detect bark beetle-caused tree mortality using single-date and multi-date Landsat imagery” osoittivat tutkimuksessaan, että Sentinel-2:n multispektrikuvauksella päästiin täysin kolonisoitujen luokitteluitten osalta kontortamännyn (*Pinus contorta*) ja lännenkeltamännyn (*Pinus ponderosa*) osalta hyönteistuhon tunnistuksessa 87,4 % tuottajan tarkkuuteen, 92,9 % käyttäjän tarkkuuteen, 89,6 % kokonaistarkkuuteen ja 0,86 kappa-kertoimeen. Osittain kolonisoiduilla luokitteluilla tulokset olivat hieman pienempiä, käyttäjän tarkkuus 81,3 %, tuottajan tarkkuus 85,3 %, kokonaistarkkuus 83,2 % ja kappa-kerroin 0,78. (Migaz-Mazur 2021, 2.)

Abdullah ym. 2018 tutkimuksessaan pääsivät Sentinel-2:n kirjanpainajatuhoihin liittyvän datan suhteen kuusikoissa 362 oikeinluokitteluun ja 177 virheluokitukseen, jolloin luokituksia yhteensä oli $362 + 177 = 539$. Siten heidän tutkimuksensa kokonaistarkkuus prosentteina oli $362 / 539 * 100 \% = 67,2 \%$. (Abdullah 2019, 97.)

Migaz-Mazur ym. 2021 pääsivät omassa tutkimuksessaan korkeampiin lukemiin käyttäen Sentinel-2:n multispektrikuvia sekä monimuuttujaista muutosten tunnistusta (engl. Multivariate Alteration Detection, MAD) ja tukivektorikonetta (engl. Support Vector Machine, SVM) luokitteluun. Monimuuttujainen muutosten tulkinta taas pyrkii tunnistamaan datajoukosta poikkeavia osioita. Heidän kirjanpainajaan liittyvässä tutkimuksessaan kolonisoitujen alueitten tunnistus tapahtui 97 % kokonaistarkkuudella, 92 % käyttäjätarkkuudella, 92,5 % tuottajatarkkuudella ja 0,93 kappa-kertoimella. (Migaz-Mazur 2021, 3.)

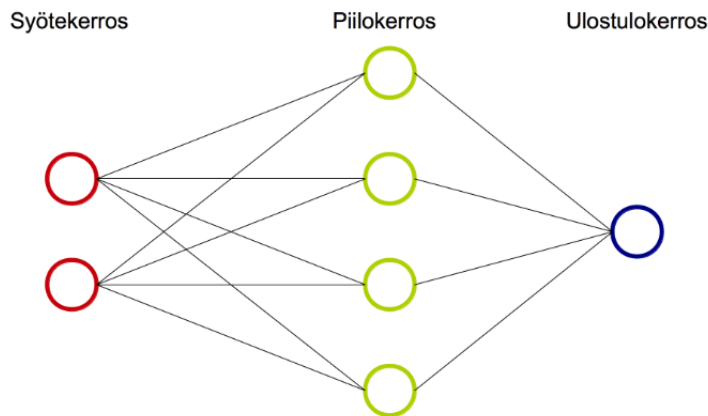
Tukivektorikone (Support Vector Machine, SVM) on tilastollisen oppimisen teoriaan pohjautuva ryhmä luokittelun ja regression menetelmiä. Tukivektorikoneen käyttö soveltuu luokitteluun eri luokkien välille ja se oikeastaan keskittyykin eri luokkien välisen raja-alueen tulkintaan. SVM korostaa luokkien välisiä eroja erottaakseen tarkasteltavat kohteet niin, että SVM saa kohteet luokiteltua, minkä jälkeen luokitellun ryhmän arvo yleistetään kuvaamaan koko ryhmää. SVM:ää on käytetty esimerkiksi metsien biofysikaalisten ominaisuuksien arviointiin muutamissa tutkimuksissa. (Shataee ym. 2012, 6258)

3.4 Neuroverkot kaukokartoitustiedon prosessoinnissa

Neuroverkot ovat tietokoneelle ohjelmoituja laskentamatriiseja, jotka saavat innoituksensa aivojen toiminnasta. Neuroverkoja käytetään mm. kuvantunnistamiseen, konenäköön, puheentunnistukseen ja moniin muihinkin tehtäviin (Tuominen ym. 2019, 7). Käytännön tasolla neuroverkko sisältää yleensä huomattavan ison määrän tietokoneelle ohjelmoituja ”neuroneita”, eli yksinkertaisia laskutoimitusyksiköitä, jotka ovat linkitetty toisiinsa muodostaen neuroneitten verkoston. (Shalev-Shwartz & Ben-David 2014, 268.)

Neuroverkoston rakenteessa on ensimmäisenä tasona tiedon syötekerros (engl. input layer), johon syötetään alkuperäinen tieto, jota halutaan prosessoida. Tämän jälkeen on


ns. piilokerrokset (engl. hidden layers), joissa varsinainen laskenta tapahtuu. Kun tieto on prosessoitu vuorollaan kaikkien piilokerrosten läpi, tulee neuroverkon prosessoima lopputulema ulostulokerrokseen (engl. output layer), mikä on taas näkyvä kerros. (Tuominen ym. 2019, 24.)



Kuva 10. Yksinkertaisen neuroverkon perusrakenne (Tuominen ym. 2019, 24).

Jokainen syötekerroksen neuronin on jokin tarkasteltava ominaisuus, mille voidaan antaa numeerinen arvo. Siten tarkasteltavien ominaisuuksien määrä määrittää sen, kuinka monta syöteriviä tarvitaan. Jokainen syötteistä painotetaan (engl. bias) halutulla tavalla, jolloin tiettyihin ominaisuuksiin neuroverkko ei reagoi liian herkästi, vaan vasta, kun tietty kynnyksiarvo on ylitetty. Vastaavasti joitain toisia ominaisuuksia voidaan korostaa, jolloin niiden arvojen muutokset vaikuttavat lopputulokseen enemmän. (Shalev-Shwartz & Ben-David 2014, 269.)

Kun syötekerrokseen on annettu lukuarvot, käynnistetään neuroverkon laskenta. Siinä jokaisen syötekerroksen neuronin painotettu arvo on yhteydessä yhteen tai useampaan ensimmäisen piilokerroksen neuronin. Piilokerroksen neuronin arvo määrittyy siten kaikkien kyseiseen neuronin yhteydessä olevien syötekerroksen painotettujen arvojen perusteella, jolloin mikään yksittäinen neuronin syötekerroksessa ei määrittele piilokerroksen neuronin arvoa vaan se tapahtuu kokonaisuuden perusteella. Vastaavasti ensimmäisen piilokerroksen neuronit jatkavat arvot saatuaan määrittämään seuraavan piilokerroksen arvoja ja näin jatkuu kunnes piilokerrokset loppuvat. Viimeinen piilokerros tuottaa ulostulokerroksen eli lopputuloksen, joka on syötekerroksen jälkeen seuraava näkyvä vaihe. Piilokerrokset ovat nimensä mukaisesti piilossa. (Shalev-Shwartz & Ben-David 2014, 269-270.)



Kuva 11. Syvä neuroverkko. (Tuominen ym. 2019, 25).

Piilokerrosten määrä määrittää sen, kutsutaanko neuroverkkoa syväksi neuroverkoksi (Deep Neural Network, DNN). Mikään ei teknisesti estä tekemästä jopa tuhansia piilokerroksia tai tuhansia syöterivejä syötekerrokseen. Kuitenkin neuroverkkolaskenta vaatii varsinkin syvien neuroverkkojen osalta paljon laskentatehoa ja siksi neuroverkot eivät yleistyneet kuin vasta 2010-luvulla vaikka alun perin ne kehitettiin jo 1940-luvulla. (Tuominen ym. 2019, 6-7, 25.)

Käytännön tasolla neuroverkko voidaan opettaa tulkitsemaan raakadataa niin, että haluttuja ominaisuuksia löydetään suurestakin datamassasta. Mäyrä ym. 2021 tutkimuksessaan käyttivät neuroverkkoa tulkitsemaan multispektri- ja valotutka- eli LiDAR-dataa (engl. Light Detection and Ranging, LiDAR) etsiessään haapoja muitten puulajien seasta. Heidän kokeessaan kokonaistarkkuus oli 87 % parhaalla ja 85 % huonoimmalla syvällä CNN-neuroverkkolla (engl. Convolutional Neural Network) kun taas verrokkina perinteisempi tukivektorikone pääsi parhaimmillaan 82,4 % tulokseen ja ei-syvä neuroverkko (engl. Artificial Neural Network, ANN) pääsi vain 81,7 % kokonaistarkkuuteen. (Mäyrä ym. 2021, 1.)

Neuroverkkojen merkittävin hyöty verrattuna perinteisempiin koneoppimismalleihin on neuroverkkojen kyky löytää haluttuja ominaisuuksia suoraan syötetystä datasta ilman perinteisten koneoppimismallien käsityönä tehtyä parametrien säätämistä. Neuroverkolle voidaan antaa palautetta onnistumisista ja epäonnistumisista, jolloin neuroverkko säätää itse itseään palautteen pohjalta. Toinen vaihtoehto on antaa neuroverkon opettaa itse itseään opetusmateriaalin perusteella, jolloin se saattaa ihmistä paremmin löytää ne ominaisuudet, mitkä korreloivat haluttujen luokitteluitten kanssa. Myös erittäin tärkeää on opetusmateriaalin hyvä tarkkuus, sillä se korreloi parempien luokitusten kanssa. Kuitenkin jo nykyisellään neuroverkot pärjäävät kilpailussa perinteisten koneoppimismallien kanssa, joten neuroverkkojen potentiaalia tullaan hyödyntämään käytännön toteutuksissa. (Mäyrä ym. 2021, 2, 14.)

4 OPINNÄYTETYÖN AINEISTO

Koska tämän opinnäytetyön tavoite on selvittää sovelluksen käyttökelpoisuutta, aloitettiin aineiston kerääminen simuloiden tilannetta, missä kartalla on havaittu kohonnut riskialue. Käytännössä tämä toteutettiin niin, että Kymenlaakson alueelta tarkasteltiin silmämääräisesti havaittuna suurimpia riskikeskittymiä niin, että ne olisivat samalla myös maantieteellisesti mahdollisimman kattavasti hajautettuna ympäri Kymenlaakson alueen.

Aineiston kerääminen oli luonteeltaan harkinnanvarainen otantatutkimus, mikä tarkoittaa sitä, että tietyistä perusjoukosta (kaikki mahdolliset tarkastelun kriteerit täyttävät kohteet) otetaan tietyin ehdoin koko perusjoukkoa keskimäärin mahdollisimman hyvin kuvaava otanta harkinnanvaraisesti. Tutkittava otantaryhmä on valittava mahdollisimman objektiivisesti, vaikka kohteet ovatkin harkinnanvaraisesti valittuja. Riskikohteiden vertailuksi kerättiin myös otanta terveistä, kuusivaltaisista metsistä, joissa ei ole sovelluksen havaitsemaa kohonnutta riskiä lähellä. Näin saatiin selville alueen kuusikoitten kuolleisuuden perustaso. (Holopainen & Pulkkinen 2013, 36).

Tässä tutkimuksessa riskikohteiden otanta tapahtui niin, että kaikista mahdollisista hila-ruuduista tarkasteltiin vain niitä, joissa mahdollinen tuho tai riski sille on karttasovelluksen perusteella vakavimmassa luokassa. Tämä määriteltiin perusjoukoksi. Koska karttasovellus ei tuota käyttäjälle taulukkomuodossa tietoa tai muuta numeerista tietoa vaan ainoastaan karttamuotoista tietoa, ei aineistosta ollut mahdollista valikoida kohteita todellisella satunnaisotannalla niin, että kaikki mahdolliset perusjoukon jäsenet olisi listattuna ja siitä joukosta otettaisiin satunnaisotannalla otanta. Sen sijaan tässä työssä satunnaisotanta toteutettiin perusjoukosta valitsemalla kohteet satunnaisesti kartalta etsimällä ilman ennakkotietoa kohteista. Tällöin valintaa ei vääristänyt ennakkotieto paikallisesta tilanteesta.

Sovellus tuottaa tietoa värikoodeilla, jolloin sopivien kohteiden tuli olla tummimman punaista väritykseltään indikoiden siten suurinta riskiä. Jos sovellus olisi tuottanut numeerista dataa, oltaisiin voitu valita tietty raja-arvo minkä olisi tullut ylittyä, mutta sovelluksen käyttäjän kannalta tällaista numeerista tietoa ei ollut saatavilla. Oletettavaa kuitenkin on, että taustalla algoritmi laskee numeerisen riskiarvon joka kohteelle ja sen mukaan

tuottaa sille soveltuvan värisävyn kartalle. Näin voidaan olettaa, että valitsemalla kohteita, missä on tummimman punaista riskiarviota, ollaan käytännön tasolla tehty samanlainen kynnsarvo, jonka on ylityttävä, jotta kohde voisi tulla valituksi. Kohteita valittiin 40 ympäri Kymenlaakson edellä kuvatulla tavalla.

Kohteiden välinen etäisyys pyrittiin pitämään vähintään useassa kilometrissä, jottei minäkään yhden alueen paikallinen tilanne vääristäisi tuloksia. Etäisyydelle ei kuitenkaan asetettu alinta raja-arvoa sen takia, ettei edustavia kohteita myöskään jäisi käyttämättä vain valitun raja-arvon perusteella. Tämä toimintamalli on kuin käänteinen versio ryväsotannasta. Ryväsotanta on otannan malli, jossa esimerkiksi maantieteellisesti pyritään järkevöittämään otantakohteiden välisiä matkoja. Esimerkiksi haastattelututkimuksen kannalta voi olla edullista, jos välimatkat haastateltavien välillä eivät ole kohtuuttoman pitkiä. Kuitenkin tämän työn kannalta maantieteellisesti kattava otanta vaatii käytännössä käänteisen version tästä niin, että välimatkat ovat kohteiden välillä mahdollisimman pitkiä pysyen kuitenkin Kymenlaakson rajojen sisällä. (Karjalainen 2010, 33).

4.1 Aineiston hankinta

Kun kaikki kohteet oli kartoitettu karttatyönä loppuun asti, aloitettiin syksyllä 2023 ensimmäinen maastokartoituskiertäminen. Siinä elokuussa aloitettu kartoitustyö tehtiin lokakuuhun mennessä valmiiksi. Kartoituksessa pelkän karttatiedon perusteella valittiin kaksi riskiarvion kannalta vakavimman uhan koealaa, jotka maastossa tarkastettiin ja kartoitettiin. Koealat ovat saman kokoisia kuin kartta-aineiston tuottama hilakoko eli 10 m x 10 m neliö.

Kahden ennalta valitun koealan lisäksi valittiin vuoden 2023 aineistoa kerätessä maastossa silmämääräisesti samalta riskialueelta vakavimman uhan alainen koeala, josta suoritettiin samanlainen mittaus kuin pysyviltä koealoilta. Tämän lisäkoealan tarkoitus on pienentää sitä riskiä, että satelliitin tuottaman tiedon kohdistaminen kartalla ei osuisi täysin oikeaan kohtaan.

Maastotöissä kohteille navigoitiin käyttäen Metsä Groupin omaa kännykällä toimivaa karttasovellusta. Sovelluksen GPS-signaali voi tulla joko puhelimen omasta GPS-tiedosta

tai se voi hyödyntää ulkoisen laitteen tuottamaa GPS-signaalia. Tarkkuutena kuitenkin nähtiin puhelimen GPS-tarkkuuden olevan riittävä, sillä työn lähtökohtana on sovelluksen käyttökelpoisuus ja valtaosa sovelluksen kaikesta käytöstä tulee olemaan puhelimen GPS:n tarkkuudella.

Maastossa kohteelle navigoinnin jälkeen kohde merkittiin kulmistaan maastoon. Näin ol-
len 2024 suoritettavassa jälkimmäisessä tiedonkeruussa saadaan tieto täsmällisesti sa-
moista puista. Maastomerkintöjen yhteydessä kulmiin jätettiin myös muovilaminoitu
viesti koealan tarkoituksesta sekä yhteystiedot lisätietoja toivoville henkilöille. Tällä py-
rittiin vähentämään mahdollista koealoihin kajoamista.

Kun koealat oli merkitty maastoon, laskettiin alueelta kaikki puut. Puista tallennettiin
puulaji, statukseksi elävä tai kuollut ja mittasaksilla mitattu rinnankorkeusläpimitta. Sen
lisäksi jokaisesta puusta tallennettiin mahdolliset löydetyt riskitekijät, jotka luokiteltiin
seuraaviin luokkiin: kirjanpainaja, kuivunut latva, kaatunut/myrsky, katkennut latva, kil-
pailu, pihkavuoto, koro, harsuuntunut tai muu riskitekijä. Kuivunut latva korreloi oletet-
tavasti erittäin vahvasti kuusentähtikirjaajatuhojen kanssa, mutta tämän työn kannalta ei
ollut tarkoituksenmukaista käydä latvassa tutkimassa tilannetta tarkemmin. Lopuksi jaet-
tiin koealat kahteen ryhmään sen perusteella, olivatko ne kivennäismaalla ja turvemaalla
sekä tarkasteltiin etäisyyttä lähimpään avoimeen alueeseen sekä sitä, onko alue harven-
nettu hiljattain.

4.1.1 Käytetty välineistö

Käytettävä välineistö toimistotöissä sisälsi:

- 1) Metsä Groupin tietokonepohjaisen karttaohjelman

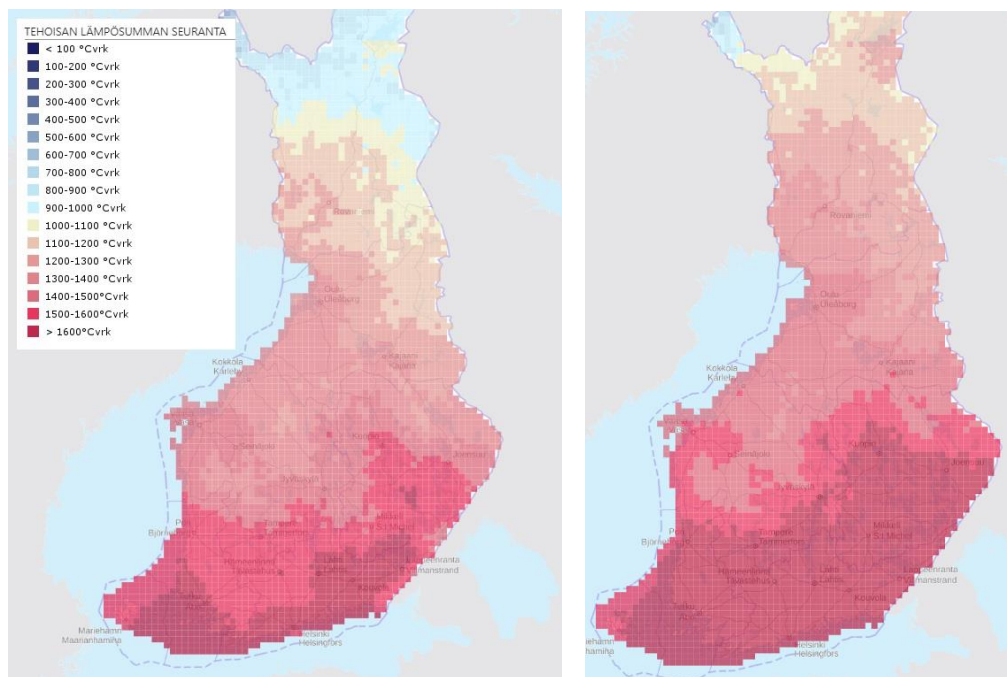
Käytettävä välineistö maastossa sisälsi:

- 1) Metsä Groupin älypuhelinsovellus
- 2) kuitunauhaa koealojen maastomerkintään
- 3) muovilaminoituja viestilappuja
- 4) 15m metsurinmitta kulmien etäisyyden mittaamiseen toisistaan
- 5) mittasakset läpimitan mittaamiseen

4.1.2 Sääolosuhteet ja lämpösumma tarkasteluajanjaksoilla

Sääolosuhteet syksyllä 2023 olivat lämpötilan suhteen Etelä-Suomessa hieman keskimääräistä korkeammat, etelärannikolla oli jopa 0,5 astetta lämpimämpää kuin vertailukauden keskiarvo ja etenkin syyskuu oli tavanomaista lämpimämpi. Sademäärä oli suuressa osassa maata tavanomaista suurempi. Etelä-Suomessa sademäärä oli lähellä tavanomaista tai tavanomaista suurempi. (Vuoden 2023 sääyhteenveto. n.d.)

Vuoden 2023 lämpösumma ylisi koko Kymenlaaksossa yli 1500 astevuorokauteen ja vuoden 2024 vastaava ylisi yli 1600 astevuorokauteen. Kuten kappaleessa 2.2.3 Kirjanpainaja esitetään, ehtii tässä vaiheessa kuoriutumaan niin ensimmäinen sukupolvi, sen sisarsukupolvi kuin myös ensimmäisen sukupolven jälkeläissukupolvikin. (Luonnonvaratieto n.d.)



Kuva 12. Vasemmalla vuoden 2023 ja oikealla vuoden 2024 terminen lämpösumma astevuorokausina (Luonnonvaratieto n.d.).

Valtakunnan metsien inventoinnin maastotöissä vuonna 2023 havaittiin kirjanpainajan aiheuttamia muutoksia 64 300 hehtaarilta, mikä on 46 300 hehtaaria enemmän kuin vuonna 2022. (Ylioja & Sutela 2024, 12).

4.1.3 Riskitekijöitten tunnistaminen ja todennäköisimmät virhetulkinnat

Riskitekijöitten kartoituksen osalta toimittiin varovaisuusperiaatteen mukaisesti, eli vain riittävän varmat tunnistukset laskettiin. Myrskyn kaatamien puitten, katkenneiden latvojen ja korojen kohdalla tunnistaminen on käytännössä kiistatonta eikä virhetulkintojen vaaraa oikeastaan ole. Runsaan pihkavuodon, harsuuntumisen ja kilpailun aiheuttaman stressin arviointi taas on jo subjektiivista, sillä niiden osalta on vaikea löytää nopeasti mitattavissa olevaa kynnsarvoa joka tulisi ylittyä. Mahdollista kynnsarvon luominen olisi, mutta työkuorman suhteutettuna saavutettava hyöty olisi hyvin pieni. Niinpä päädyttiin vain arvioimaan tilannetta niin sanotusti metsäasiantuntijan silmin eli samalla tavoin, kuin metsäasiantuntija silmämääräisesti arvioi metsää siellä kulkiessaan.

Hyönteistuhojen osalta kirjanpainajan syömäkuvio erottuu helposti kuusentähtikirjaajan syömäkuvioista. Kuitenkin jotta kirjanpainajan syömäkuvion pääsee näkemään, on puun oltava siinä määrin kuollut, että kuori alkaa tippumaan maahan. Tällöin kirjanpainajan syömäkuvio näkyy niin kuorenpalasissa kuin myös rungossa, sillä syödessään puun nilakerrosta se jättää jälkensä kummallekin puolelle nilakerrosta. Siten tunnistamattomia kirjanpainajapuita on varmasti aineiston joukossa, sillä osassa kuolleista puista kuori oli vielä tiukasti kiinni rungossa. Elävät puut, jotka olivat kirjanpainajien hyökkäyksen alla, lukeutuivat todennäköisesti runsaan pihkavuodon alle, sillä siinä vaiheessa on hyvin vaikea tunnistaa hyökkäystä kirjanpainajan hyökkäykseksi. Pitkälle edennyt, puun puolustuksesta läpi päässyt hyökkäys voidaan kuitenkin havaita ruskeista purukasoista puun tyvellä ja hyönteisten sisäänmenoaukoilla silloin, kun nämä jatkuvat tyvelle asti. (Kirjanpainaja kuusikossa n.d. 5, 12.)


Kuusentähtikirjaajan osalta tunnistaminen perustui joko kuolleella puulla syömäkuvion tunnistamiseen tai elävällä puulla siihen, että sen latva on kuollut vaikka tyvi on vielä pitkään elossa. Koska kuivuneen latvan tunnistus tapahtuu silmämääräisesti maasta katsottuna, oli tässä selkeä virhetulkintojen mahdollisuus. Kuitenkin todennäköisin tuhonaiheuttaja, johon kuusentähtikirjaajan tuhon virheellisesti tunnistaisi, on aitomonikirjaaja. Aitomonikirjaaja on tuhon aiheuttamistavoiltaan ja vaikutuksiltaan hyvin samankaltainen kuin kuusentähtikirjaaja, jolloin luokka ”kuivunut latva” voitiin käytännön tasolla tulkita tarkoittavan ”kuusentähtikirjaaja tai aitomonikirjaaja”.

4.1.4 Aineiston tarkasteluajankohta ja muutokset vuosien välillä

Kun kohteet oli valittu vuonna 2023 kartalta, otettiin niiden karttakuvasta leike siitä näkymästä, minkälaisen riskiarvion sovellus kullekin kohteelle oli tuottanut. Koettiin tärkeäksi ottaa leike kartoitusajankohdan hetkellä, sillä sovelluksen karttakuvat päivittyvät useita kertoja kasvukauden aikana ja jälkikäteen tarkasteltuna riskikartoitus näyttää erilaiselta. Leikkeet otettiin niin riskin voimakkuudesta kuin myös sen ajankohtaisuudesta.

Kun vuoden 2024 aineistoa alettiin keräämään syksyllä 2024, huomattiin algoritmin laskennassa tapahtuneen merkittäviä muutoksia. Myös aineiston esittämistapaan oli tullut lisäominaisuus, millä pystyi tarkastelemaan uusimman aineiston lisäksi vanhempiakin aineistoja. Sen lisäksi aineistoon oli tullut violetilla värillä kuvattuna näkymään havainnot niistä hilaruuduista, joissa on pysähtyneeksi todettu vanha tuho.

Tarkasteltaessa aineistojen välisiä muutoksia havaittiin, että vaikka vuonna 2023 pysyvät koealat olivat sijoitettu silloisen kartan vakavimman riskin hiloihin, oli vuonna 2024 näistä yhteensä 120:stä yksittäisestä koealasta vain yhdeksän sellaisessa kohdassa, että uuden algoritmin mukaisella kartalla koeala osui edes lievän tai pysähtyneen riskin alueelle silloin, kun tarkasteluajankohdaksi valittiin takautuvasti syyskuu 2023. 111 koealaa osuivat alueille, joille vuoden 2024 algoritmi ei näyttänyt minkäänlaista riskiä tai tuhoa.



Kuva 13. Vasemmanpuoleinen leike on otettu 29.9.2023 ja oikeanpuoleinen leike on otettu 14.9.2024 niin, että ajankohdaksi on valittu syyskuu 2023.

Näin merkittävä muutos algoritmissa kuuluu normaaliin sovelluksen kehittämistyöhön, mutta muutti koeasetelmaa suunnitellusta, sillä vuonna 2024 algoritmi näytti riskialueita huomattavasti vähemmän kuin vuonna 2023. Työn vertailukelpoisuuden kannalta päädyttiin pitämään pysyviksi määritellyt koealat edelleen pysyvinä, sillä niitten avulla on mahdollista takautuvasti verrata vanhan algoritmin ennustamiskykyä vuosien 2023 ja 2024 välillä. Kuitenkin lisäkoealojen osalta päädyttiin muuttamaan valintatapaa.

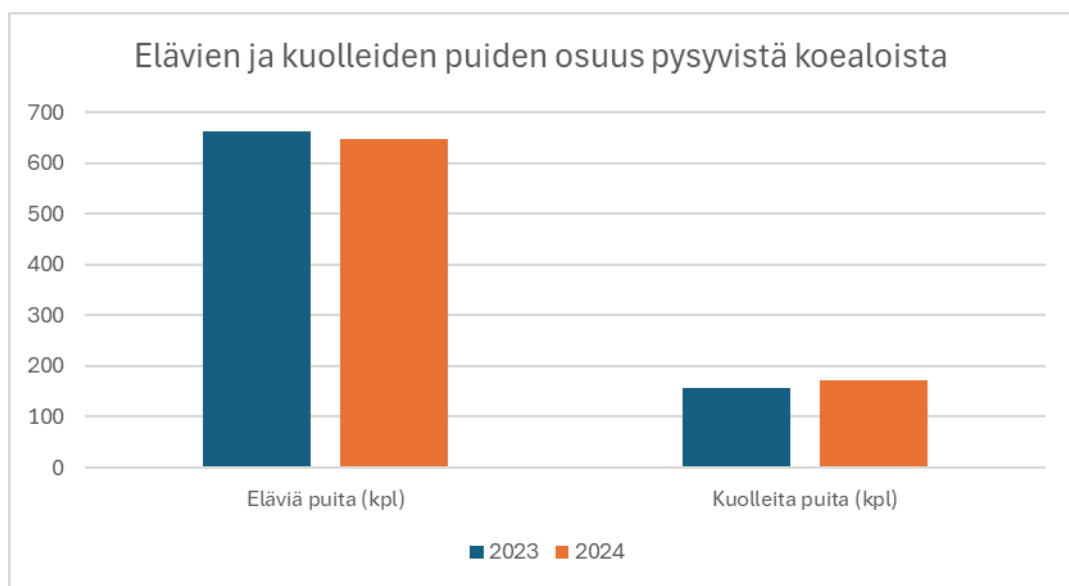
Maastossa valittavan lisäkoealan määräytymisehtoja muutettiin aiemmasta niin, että lisäkoealoja ei määritelty maastohavaintojen perusteella suurimman tuhon kohtaan vuonna 2024, vaan se sijoitettiin kartalla pysyvistä koealoista katsottuna vuoden 2024 algoritmin mukaisen kartan lähimpään merkittävän tuhon hilaruutuun. Näin saatiin vertailukelpoista tietoa uuden ja vanhan algoritmin merkittävien tuhojen väliltä, jolloin päästiin vertaamaan sitä, kumpi algoritmi oli todellisuudessa parempi arvioimaan todellista tilannetta maastossa.

4.2 Aineiston kuvailu

Kerättyä aineistoa saatiin 37 kohteelta eli yhteensä 148 koealalta kahden eri vuoden ajalta. Alun perin vuonna 2023 kohteita oli 40 ja koealoja 120, mutta kolme kohdetta eli yhdeksän koealaa niistä menivät hakkuuseen eli puusto poistettiin kohteilta. Näin ollen vuoden 2024 lukemia oli mahdoton saada näiltä koealoilta ja kyseiset 9 koealaa päätettiin hylätä aineistosta. Vuonna 2024 lisäkoealat eivät olleet samassa paikassa kuin vuonna 2023, joten siitä saatiin 37 uutta lisäkoealaa. Siten molemmille vuosille pysyviä koealoja oli 37 kohteella yhteensä 74 kappaletta, minkä lisäksi lisäkoealoja oli 37 kumpanakin vuonna. Aineisto on kerätty koealoittain, mutta esitetään tiedon suuren määrän takia ryhmittäin.


Vuonna 2024 kerättiin maastosta riskialueitten ulkopuolelta terveistä kuusivaltaisista metsistä koealatiedot, joista muodostettiin tervettä metsää kuvaava perustaso, johon sovelluksen tuottamaa tietoa voitiin verrata. Näitä tervettä metsää kuvaavia koealoja mitattiin 20 ympäri Kymenlaaksoa. Koealat valittiin ilman ennakkotietoa kohteiden maasto-olosuhteista ja kartalta valittiin ennakkoon mittauspiste.

Kerättyä aineistoa voidaan tulkita monella eri tavalla, kunhan eri aineistoryhmät on ensin tunnistettu ja eroteltu toisistaan. Yksi tapa erotella aineistoa eri luokkiin on muodostaa aineistosta aikasarjoja. Aikasarjoilla pyritään ennustamaan tulevia tapahtumia sen perusteella, minkälaisia havaintoja menneisyydestä on tehtävissä. Aikasarjat ovat tietyn ajan kuluessa tapahtuneiden havaintojen sarja ja ne voidaan jakaa jatkuviin ja epäjatkuviin eli diskreetteihin aikasarjoihin. Tämän työn aineisto voidaan nähdä diskreettinä eli epäjatkuvana aineistona, sillä mittausajankohdiksi valikoitui syksy 2023 ja syksy 2024 sen sijaan, että mittauksia toteutettaisiin jatkuvasti näiden ajankohtien välillä. (Holopainen & Pulkkinen 2013, 305.)



Kuvio 3. Esimerkki diskreetteistä aikasarjoista.

Aikasarjoja voidaan verrata toisiinsa tuottamalla indeksilukuja. Indeksiluku sidotaan vertaamaan myöhempiä havaintoja johonkin aiempaan vertailuvuoteen nähden. Käytännössä vertailuvuosi saa indeksiluvun 100 ja seuraavat tarkasteltavat aikasarjat saavat luvun suhteessa siihen muutokseen, mikä aikasarjalla on suhteessa vertailuvuoteen eli ne lasketaan prosenttiosuuksina suhteessa vertailuvuoteen. Edellisen kuvion 3 tiedot voidaan siten muuntaa indeksiluvuksi seuraavan kuvion 4 mukaisesti. (Holopainen & Pulkkinen 2013, 307.)



Kuvio 4. Esimerkki elävien ja kuolleiden puiden indeksiluvusta.

Vuosina 2023 ja 2024 kerätty aineisto voidaan jakaa kahteen aikasarjaan, mutta kumpikin aikasarja voidaan vielä luokitella kahteen toiminnalliseen luokkaan. Vuodelle 2023 luokat ovat ”Pysyvä koeala” ja ”Lisäkoala”, sillä 80 kpl koealoista luotiin alun perin pysyviksi ja 40kpl valittiin paikan päällä maastossa lisäkoaloiksi. Vuodelle 2024 lisäkoalojen valintatapaa jouduttiin muuttamaan, mikä kuvaa vuosien välillä tapahtuneen algoritmin muutoksen aiheuttamaa luokittelumuutosta. Maastovalinta siten korvattiin sillä, että uuden algoritmin mukaisen kartta-aineiston perusteella valittiin lähialueelta vakavimman uhan alainen koeala näkemättä sitä maastossa ensin. Näin ollen uuden algoritmin mukainen valinta on luonteeltaan lähempänä pysyviä koealoja kuin vuoden 2023 maastovalintaa. Eri luokkiin jakautuva aineisto voidaan siten jakaa neljään pääluokkaan ja yhteen vertailtavaan kontrolliryhmään keräysvuoden ja keräystavan perusteella:

Taulukko 4. Koealojen lopullinen jakautuminen pääluokkiin.

	Pysyvä koeala	Lisäkoala	Terveen metsän vertailukoeala
Vuosi 2023	N=74	N=37	
Vuosi 2024	N=74	N=37	N=20

Jokaisesta pääluokasta laskettiin omat muuttujat, kuten kuolleiden puiden suhteellinen osuus, elävistä puista havaittujen riskitekijöitten määrä suhteutettuna elävien puiden määrään ja kuolleista puista havaittujen riskitekijöitten määrään suhteutettuna kuolleitten puitten määrään. Pääluokkien sisällä tarkasteltiin myös sitä, onko havaittavissa eroavaisuuksia sellaisten koealojen osalta, jotka olivat joko turvemaalla tai lähellä avointa alaa kuten peltoa tai tuoretta uudistushakkuuta. Lähellä oleminen tulkittiin työssä merkitsemään 0-20m etäisyyttä avoimesta alasta.

4.2.1 Aineiston koealoittain kerätty tieto

Aineistoa kertyi 74 sivun edestä, joten sitä ei liitetä tähän työhön vaan koealoittainen aineisto voidaan toimittaa pyydettyäessä. Aineisto on anonymisoitu niin, ettei siitä voida tunnistaa koealojen sijainteja. Jokaisesta kohteesta on kolme koealaa kummaltakin vuodelta esitettynä niin, että koeala kerrallaan esitellään kyseisen koealan molempien vuosien mittaustulokset vasemmalla puolella ylhäällä ja keskellä. Ylimpänä vasemmalla on kohteen numero, koealan numero ja tieto siitä, onko koeala pysyvä koeala vai vuonna 2023 kohteella valittu tai vuonna 2024 ennakkoon uuden algoritmin mukaiselta kartalta valittu koeala. Koealatiedon alla on mainittu, jos kohde on hiljattain harvennettu eli maastossa on näkyvästi tuoreita kantoja ja alueelta on tehty hiljattain metsänkäyttöilmoitus. Harvennustieto ilmoitettiin niin, että jos metsänkäyttöilmoitus on tehty vuonna 2020, niin koealatiedon alle tulee näkymään, että kohde on harvennettu 2020 jälkeen. Ylhäällä oikealla on tieto vuoden 2023 ja 2024 osalta siihen, sijaitsevatko koealat kivennäismaalla vai turvemaalla sekä siihen, ovatko ne 20 metriä lähempänä avointa hakkuuaukeaa, peltoa tai muuta vastaavaa.

Taulukko 5. Koealojen mittaustulokset esitettynä.

Kohde 06 Koeala 1 (ennakkovalinta, pysyvä koeala)														
2023	Kpl	Keski lpm (cm)	Elä- viä	Kuol- leita	Kuol- leita % os. naja	Kirj- paj- jaaja	Täh- tikir- tu- nut	Kaa- tu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Mänty	3	16,7	1	2	67				1	1				
Kuusi	14	17,1	11	3	21		2		1	1	1			
Koivu														
Haapa														
H.leppä														
T.leppä														
Pihlaja														
Yhteensä	17	17,1	12	5	29		2		2	2	1			

2024	Kpl	Keski lpm (cm)	Elä- viä	Kuol- leita	Kuol- leita % os. naja	Kirj- paj- jaaja	Täh- tikir- tu- nut	Kaa- tu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Mänty	3	16,7	1	2	67				1	1				
Kuusi	14	17,3	10	4	29		2		1	1	1			
Koivu														
Haapa														
H.leppä														
T.leppä														
Pihlaja														
Yhteensä	17	17,2	11	6	35		2		2	2	1			

Muutos	Elä- viä	Kuol- leita	Kuol- leita % os. naja	Kirj- paj- jaaja	Täh- tikir- tu- nut	Kaa- tu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Mänty												
Kuusi	-1	1	7									
Koivu												
Haapa												
Harmaaleppä												
Tervaleppä												
Pihlaja												
Yhteensä	-1	1	6									

Koealoittain mitattiin puitten määrä, puulaji ja keskiläpimitta. Tämän lisäksi havainnoitiin onko puu elossa vai kuollut sen perusteella, onko havupuilla neulasia tai lehtipuilla lehtiä. Elävien ja kuolleitten puitten määrästä laskettiin kuolleitten puitten prosentuaalinen osuus. Jokaisesta puusta myös havainnoitiin erilaisia riskitekijöitä, kuten kirjanpajan näkyvät tuhot, kuusentähtikirjaajan näkyvät tuhot, myrskyssä tai vastaavassa kaatuneet puut, katkenneet latvat, kilpailussa selkeästi muille puille hävinneet puut, runsaasti pihkavuotoiset puut, korot, harsuuntuneet puut sekä muut vastaavat.

Pysyvillä koealoilla on vasemmalla puolella mittaustulosten alla laskettu omaan taulukoon muutoksen suuruus vuosien välillä samoissa yksiköissä, kuin missä mittaustuloksetkin on ylempänä vasemmalla ilmoitettu. Kuolleiden puitten prosenttiosuus on ilmoitettu prosentteina muitten tietojen ollessa kappalemääriä. Jos 2024 kuolleita puita on yksi enemmän kuin vuonna 2023, näkyy se elävien puitten määrässä miinus yhtenä puuna ja kuolleitten puitten määrässä plus yhtenä puuna.

Koealamittautustietojen oikealla puolella on esitetty mittaustuloksista laskettuja prosenttiosuuksia. Prosenttiosuudet on laskettu puulajikohteisesti osuutena sen puulajin kokonaismäärästä. Siten jos joka toisessa puussa on jokin riskitekijä tai tuhonaiheuttaja havaittu, on prosenttiosuuksien yhteenlaskettu summa 50 %. Vastaavasti jos jokaisessa puussa on useampi riskitekijä, voi yhteenlaskettu prosenttien summa ylittää 100 %. Prosenttiosuuksien alle on alimpaan taulukkoon oikealla puolella laskettu prosenttiosuuksien muutokset vuosien välillä.

Taulukko 6. Koealojen mittauksista laskettuja prosenttiosuuksia.

2023 Kivennäismaa, etäisyys avoimelle 20+									
2024 Kivennäismaa, etäisyys avoimelle 20+									
2023	Kirj.	Täh-	Kaa-	Kat-	Kil-	Pih-	Koro	Har-	Muu
% osuudet	pai-	tikir-	tu-	ken-	pai-	kav.		suun-	
Puulaji	naja	jaaja	nut	nut	lu			tunut	
Mänty				33	33				
Kuusi	14			7	7	7			
Koivu									
Haapa									
H.leppä									
T.leppä									
Pihlaja									
Yhteensä	12			12	12	6			


2024	Kirj.	Täh-	Kaa-	Kat-	Kil-	Pih-	Koro	Har-	Muu
% osuudet	pai-	tikir-	tu-	ken-	pai-	kav.		suun-	
Puulaji	naja	jaaja	nut	nut	lu			tunut	
Mänty				33	33				
Kuusi	14			7	7	7			
Koivu									
Haapa									
H.leppä									
T.leppä									
Pihlaja									
Yhteensä	12			12	12	6			

Muutos %	Kirj.	Täh-	Kaa-	Kat-	Kil-	Pih-	Koro	Har-	Muu
	pai-	tikir-	tu-	ken-	pai-	kav.		suun-	
Puulaji	naja	jaaja	nut	nut	lu			tunut	
Mänty									
Kuusi									
Koivu									
Haapa									
H.leppä									
T.leppä									
Pihlaja									
Yhteensä									

Jokaisen kohteen koeala 3:ssa on jätetty vuosien välisen muutoksen vertaaminen pois, sillä koeala 3 on eri alueelta mitattu vuonna 2023 kuin vuonna 2024. Siten muutosta ei voi verrata, vaan huomio on kiinnitettävä suhteellisiin osuuksiin.

Koealatietojen jälkeen on esitetty kohteesta tallennetut neljä karttakuvaa. Ylärivillä on esitetty vasemmalla puolella vuonna 2023 näyttökuvana tallennettu vanhan algoritmin

mukainen karttakuva syksyltä 2023, joka ilmentää tuhon voimakkuutta ja ylärivillä oikealla taas on karttakuva, joka ilmentää tuhon ajankohtaa. Tuhon voimakkuudessa mitä punaisempi väritys on, sitä vakavammasta tuhosta on kyse. Tuhon ajankohdan osalta taas keltainen väri osoittaa tuoreen tuhon kun taas vihreä osoittaa hieman vanhemman tuhon ja violetti väri kaikkein vanhimman tuhon. Vuoden 2023 karttatieto ei enää ole saatavilla tietojärjestelmässä, sillä laskentaan käytettyä algoritmia on muutettu myös takautuvasti. Vuoden 2024 osalta on vastaavat karttakuvat kuin vuoden 2023 osaltakin eli tuhon voimakkuus ja ajankohta syksyllä 2024.



2023 tuhon voimakkuus



2023 tuhon ajankohta



2024 tuhon voimakkuus



2024 tuhon ajankohta

Kuva 14. Havainnekuva karttaleikkeistä.

4.2.2 Aineiston analysointitavat

Eri pääluokkia verrattiin toisiinsa, jotta voitiin analysoida tarkasteltavan sovelluksen tuottaman tiedon kehittymistä vuosien välillä. Pelkästään vuoden 2023 aineistosta voidaan jo tarkastella sitä, kuinka hyvin algoritmi onnistui löytämään vakavimmin vaurioituneita kohtia metsästä. Tämä selviää vertaamalla pysyviä koealoja vuodelta 2023 lisäkoealoihin

vuodelta 2023. Näin on mahdollista selvittää, oliko maastokäynnillä löydettävissä selkeästi vakavammin vaurioituneita kohteita kuin mitä algoritmi oli kartalle laskenut. Tällä tarkastelulla selviää myös se, onko algoritmin laskemat vakavimmin vaurioituneet hila-ruudut osuneet oikeisiin kohtiin kartalla.

Koska tarkasteltavan sovelluksen on tarkoitus nähdä jo ihmissilmää aiemmin alkavat tuhot, voidaan sen onnistumista tarkastella vertaamalla pysyviä koealoja vuosien 2023 ja 2024 välillä. Näin voidaan havainnoida pysyvien koealojen tilanteen kehitystä, sillä samat koealat on mitattu molempina vuosina. Huomion arvoista kuitenkin on se, että näin voidaan selvittää ainoastaan vanhan algoritmin mukaisen laskennan kehitystä vuosien 2023 ja 2024 välillä. Uuden algoritmin kohdalla vastaava tarkastelu vaatisi koealojen tutkimista vuonna 2025 syksyllä.

Kolmas pääryhmien välinen tarkastelu on verrata pysyviä koealoja vuodelta 2023 lisäkoealoihin vuodelta 2024. Nämä molemmat ryhmät on etsitty lähes identtisiä menetelmiä käyttämällä, eli ennakkoon pelkän tarkasteltavan sovelluksen tuottaman kartan vakavimman tuhon mukaan. Ainoa ero näitten välillä on se, että lisäkoealat vuonna 2024 valittiin melko läheltä pysyvien koealojen sijaintia kun taas pysyviä koealoja määritettäessä ei ollut tällaista rajoitetta. Kuitenkin vuoden 2024 lisäkoealojen osalta priorisoitiin tuhon voimakkuutta eikä etäisyyttä pysyviin koealoihin. Tarkastelemalla näitten kahden pääryhmän tuloksia keskenään voitiin arvioida sitä, kumman vuoden algoritmi oli arvioinneissaan tarkempi.

Kerätystä aineistosta taas lasketaan elävien ja kuolleiden puitten suhteelliset osuudet niin koko aineistolle kuin myös eriteltynä kivennäismaan koealoille ja turvemaan koealoille. Näin voidaan verrata sitä, onko maaperällä tilastollisesti merkitsevää vaikutusta aineistossa. Elävien ja kuolleiden puitten suhteelliset osuudet analysoidaan myös niin, että verrataan sellaisia koealoja, jotka ovat alle 20 m etäisyydellä joko hakkuuaukeasta, pellostaa tai muuten avoimesta alueesta sellaisiin koealoihin, jotka ovat tätä etäämmällä. Näin voidaan verrata sitä, onko etäisyys avoimeen alueeseen tilastollisesti merkitsevä tekijä. Kolmantena vastaavanlaisena vertailuna verrataan koealoja, jotka on harvennettu 2018 jälkeen sellaisiin koealoihin, joissa mahdolliset käsittelyt on tehty aiemmin tai niitä ei ole tehty ollenkaan.

4.2.3 Otoskeskiarvo, mediaani, otoskeskihajonta ja luottamusväli

Keskiarvo on yksi lukujoukkoa kuvaavista keskiluvuista ja lienee tunnetuin niistä. Keskiarvo saadaan jakamalla havaintoarvojen summa lukumäärällä. Kuitenkin kun otetaan perusjoukosta otos kuvaamaan perusjoukkoa, voi otoksen keskiarvo eli otoskeskiarvo olla sattuman ja yksittäisten poikkeavien havaintojen myötä altis vääristymille. (Karjalainen 2010, 87-88.)

Mediaani tarkoittaa havaintoarvojen keskimmäistä lukua silloin, kun havaintojoukon luvut asetetaan suuruusjärjestykseen. Jos havaintoarvoja on parillinen määrä, ei keskimmäistä lukua ole, jolloin käytetään keskimmäisten kahden luvun keskiarvoa. Mediaanin kummallakin puolella on lukumäärällisesti yhtä monta havaintoarvoa, mutta mediaani ei ole välttämättä havaintoarvojen keskiarvo. (Karjalainen 2010, 90.)

Keskihajonta on yksi käytetyin ja tärkein hajontaluku. Keskihajontaa laskettaessa verrataan kaikkia havaintoja niiden väliseen keskiarvoon ja määritetään havaintojen keskimääräinen poikkeama keskiarvosta. Kun keskihajonta otetaan otoksesta, kutsutaan sitä otoskeskihajonnaksi. Otoskeskihajonta lasketaan kaavalla

$$\sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad (1)$$

mikä poikkeaa hieman perusjoukon keskihajonnan kaavasta. Kaavassa \bar{x} on arvojen aritmeettinen keskiarvo, x_i yksittäinen arvo ja n arvojen lukumäärä. (Karjalainen 2010, 97.)

Otoskeskiarvoa ja otoskeskihajontaa tarvitaan keskiarvon keskivirheen ja keskiarvon luottamusvälin laskemiseen. Keskiarvon keskivirhe on yhtä kuin otoskeskiarvojen keskihajonta. Luottamusväliä laskettaessa käytetään yleisimmin 95 % varmuudella ilmoitettua luottamusväliä, mikä tarkoittaa, että 95 % todennäköisyydellä perusjoukon keskiarvo sijaitsee otoksesta lasketun luottamusvälin alueella. Perusjoukon odotusarvon eli oletetun keskiarvon luottamusväli μ lasketaan kaavalla

$$\left[\bar{x} - 1,96 \frac{s}{\sqrt{n}} ; \bar{x} + 1,96 \frac{s}{\sqrt{n}} \right], \quad (2)$$

missä s on keskihajonta, \bar{x} otoksesta laskettu keskiarvo ja n otoksen koko. Luottamusväli on olennainen tunnusarvo sen takia, että perusjoukko on yleensä tuntematon ja otos on vain pieni osa perusjoukkoa ja kuvaa sitä enemmän tai vähemmän hyvin. Sen takia kun tehdään otoksen perusteella oletuksia perusjoukosta, on siihen sisällytettävä virhemarginaali. (Karjalainen 2010, 103.)

Jos taas luottamusväli lasketaan suhteellisesta osuudesta, lasketaan se kaavalla

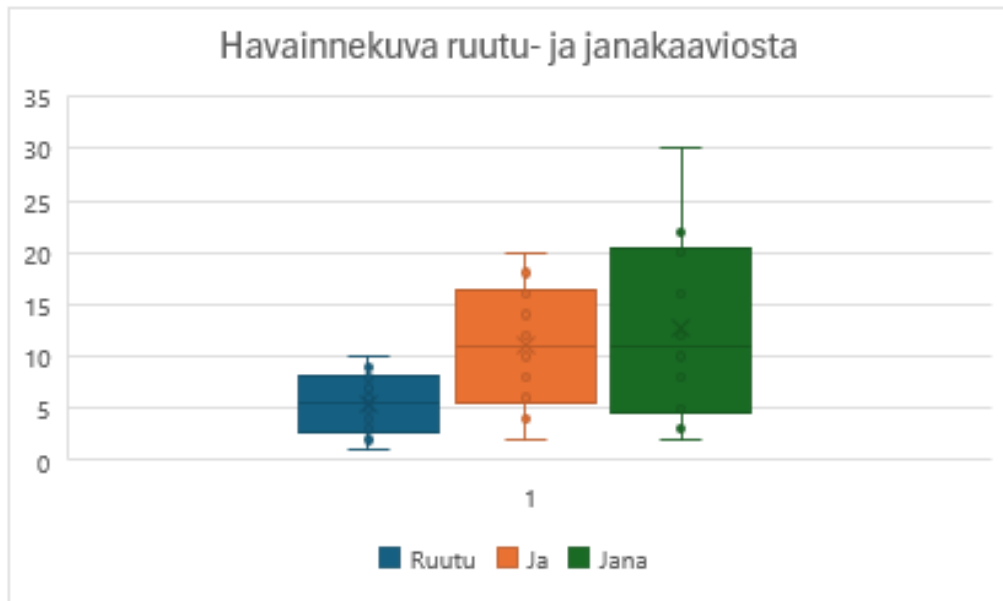
$$[\hat{p} - 1,96s ; \hat{p} + 1,96s], \quad (3)$$

missä \hat{p} on otoksesta laskettu suhteellinen osuus, n otoksen koko ja s on suhteellisen osuuden otosjakauman keskihajonta, joka lasketaan kaavalla

$$s = \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}. \quad (4)$$

4.2.4 Ruutu- ja janakaavio

Ruutu- ja janakaavio on erittäin tiivis tapa esittää runsaasti tilastollista aineistoa. Siinä esitetään havaintoarvot luokiteltuina useamman analyysityökalun avulla yhdellä kaavioilla. Kaavio muodostuu leveämmästä keskiosasta (ruutu) ja viivamaisesta hännästä ylä- ja alapuolella (jana). Alemman janan päästä ruudun alareunaan sijoittuvalle alueelle osuu 25 % havaintoarvoista, ruudun alareunasta ruudun keskelle toiset 25 %, ruudun keskeltä ruudun yläreunaan seuraavat 25 % ja ruudun yläreunasta ylemmän janan päähän viimeiset 25 %. Ruudun sisällä näkyvä ”x” merkitsee keskiarvon kohtaa ja ruudun halkaiseva viiva taas mediaania. Havaintoarvot näkyvät pisteinä janan alueella ja ympyröinä ruudun alueella. (Boxplot 2024.)



Kuvio 5. Esimerkki ruutu- ja janakaaviosta.

4.2.5 Hajontakaavio ja Pearsonin korrelaatiokerroin

Pearsonin korrelaatiokerroin on yksi käytetyimmistä korrelaatiota tulkitsevistä kaavoista silloin, kun pyritään selvittämään kahden järjestysasteikolla sijaitsevan havaintojoukon välillä olevaa korrelaatiota. Pearsonin korrelaatiokertoimen tukena voidaan käyttää hajontakaaviota, mutta korrelaatiokerroin r on laskettavissa matemaattisesti kaavalla

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x} \right) \left(\frac{y_i - \bar{y}}{s_y} \right), \quad (5)$$

missä n on havaintoyksiköiden lukumäärä, \bar{x} on havaintoarvojen x_i keskiarvo, \bar{y} on havaintoarvojen y_i keskiarvo, s_x havaintoarvojen x_i keskihajonta ja s_y on havaintoarvojen y_i keskihajonta. (Karjalainen 2010, 124-126.)

Tulkittaessa korrelaatiokertoimen lukemia, on yleisesti ottaen riippuvuus voimakasta silloin, kun kerroin on 0,7 ja kohtalaista silloin, kun kerroin on 0,3 ja 0,7 välillä. Alle 0,3 kerroin yleensä tulkitaan vähäiseksi korrelaatioksi tai niin, että korrelaatiota ei ole ollenkaan. Korrelaatiokerroin on herkkä poikkeaville havaintoarvoille. (Karjalainen 2010, 125-126.)

Korrelaatiokertoimen tulkinnassa on huomioitava, että korkeakaan korrelaatiokerroin ei tarkoita, että asioitten välillä on pakko olla yhteys. Korrelaatio voi olla sattumaa tai liittyä toiseen, ei mitattuun, suureeseen. Siten korrelaatiokertoimen lukemiin tulee suhtautua sopivalla varauksella. Olennaista on myös riittävä havaintopisteiden määrä, sillä liian pieni määrä havaintoja on erittäin altis satunnaisvaihtelun aiheuttamalle vääristymälle. (Karjalainen 2010, 128-129.)

4.2.6 Tilastollinen merkitsevyys p-arvolla

Tilastollista merkitsevyyttä määritettäessä on ensin muodostettava nollahypoteesi ja sille vastahypoteesi. Nollahypoteesi on aina sellainen hypoteesi, että tutkittavalla asialla ei ole tilastollista merkitsevyyttä hypoteesiin ja vastahypoteesi taas vastaavasti muodostetaan niin, että tutkittavalla asialla on tilastollista merkitystä tutkittavaan asiaan. (Karjalainen 2010, 219)

Esimerkki nollahypoteesista ja vastahypoteesista:

H_0 : koealan sijaitseminen lähellä avointa alaa ei vaikuta puuston kuolleisuuteen

H_1 : koealan sijaitseminen lähellä avointa alaa vaikuttaa puuston kuolleisuuteen

Yleensä tutkijalla voi olla ennakkoon oletus, että H_1 voisi olla totta, mutta lähtökohdan on silti aina oltava niin, että H_0 on totta jos ei toisin todisteta. Tätä korostetaan sillä, että nollahypoteesin hylkäämisvirhettä pidetään vakavampana virheenä kuin hyväksymisvirhettä. Hylkäämisvirhe tarkoittaa sitä, että nollahypoteesi hylätään vaikka se on todenmukainen kun taas hyväksymisvirhe tarkoittaa sitä, että nollahypoteesi hyväksytään vaikka se ei ole todenmukainen. Toisin sanoen, mieluummin hyväksytään virheellisesti nollahypoteesi kuin virheellisesti sen vastahypoteesi. Näin ollen nollahypoteesi on aina se mikä hyväksytään jos ei aineisto toisin todista. (Karjalainen 2010, 219-221.)

Tilastollinen testi on keino selvittää sitä, kuuluuko H_0 pitää vai hylätä ja hyväksyä H_1 . Sopiva testi on valittava sen mukaan, mihin käytetty data soveltuu. Ensin on tarkasteltava sitä, vertaillaanko keskiarvoja vai muuttujien välisiä yhteyksiä. Sen lisäksi valintaan vai-

kuttaa se, ovatko vertailtavat ryhmät toisistaan riippuvia vai riippumattomia. Lopuksi valintaan vaikuttaa se, käytetäänkö esimerkiksi normaalijakaumaa vertailussa vai jotain muuta jakaumaa. (Karjalainen 2010, 219-221.)

Todettiin, että tässä tutkimuksessa vertaillaan keskiarvojen perusteella kahta eri ryhmää, jotka eivät ole toisistaan riippuvaisia, eli mittaukset on suoritettu toisistaan riippumattomina. Todettiin, että normaalijakaumasta ei ole syytä poiketa. Koealojen tietoja analysoitaessa päädyttiin käyttämään kahden riippumattoman otoksen t-testiä, johon sijoitetaan otoskoko, keskiarvo ja keskihajonta. Sen vaatimuksia on, että otokset ovat poimittu satunnaisesti ja että ne ovat toisistaan riippumattomia. Sen lisäksi muuttujien on oltava välimatka- tai suhdeasteikon muuttujia ja jakauman suunnilleen normaalijakauman mukainen. Kahden riippumattoman otoksen t-testissä alle 0,05 p-arvoa voidaan pitää tilastollisesti merkitseväenä eli sellaisena, että nollahypoteesi voidaan hylätä. (Karjalainen 2010, 221, 230.) Laskenta suoritettiin Statistics Kingdom -nimisellä verkosta löytyvällä laskurilla (statisticskingdom.com).

4.2.7 Koealojen elinvoimaisuuden status

Koealoja verrattiin toisiinsa myös muodostamalla koealojen terveydentilaa kuvaava elinvoimaisuuden status, jonka tarkoituksena on antaa nopea yleissilmäys koealojen elinvoimaisuudesta. Tässä analysointitavassa jaettiin koealat kolmeen ryhmään: terve, stressaantunut ja vahingoittunut metsä. Analysoinnin perustana käytettiin yhdistelmää koealalta löytyneistä kuolleista puista sekä riskitekijöistä.

Terve metsä määriteltiin niin, että työssä kerättyjen terveen metsän vertailukoealojen vaihteluväli mahtuu terveen metsän määritelmään. Siten kun terveissä vertailukoealoissa oli enimmillään kaksi kuollutta puuta tai puuta heikentävää tekijää, määriteltiin terveen metsän status sellaisille koealoille, joilla kuolleita puuta tai havaittuja riskitekijöitä oli 0-2 kappaletta yhteensä. Stressaantuneeksi metsä määriteltiin silloin, kun kuolleita puuta ja riskitekijöitä oli yhteensä 3-5 kappaletta ja vaurioituneeksi koeala määriteltiin, jos määrä oli 6 tai yli.

5 TULOKSET JA TARKASTELU

Tuloksia tarkastellaan ensin pääryhmittäin koealojen yhteenvetoina ja sen jälkeen laskettuina keskimääräisinä lukuina per koeala. Luettavuuden parantamiseksi eri pääryhmiin viittaavat tietosarakkeet on eroteltu toisistaan myös värityksellä, joka pidetään yhteneväisenä läpi sen osion, missä niitä verrataan toisiinsa. Sininen väri viittaa pysyviin koealoihin vuodelta 2023, vihreä väri pysyviin koealoihin vuodelta 2024, keltainen väri lisäkoealoihin vuodelta 2023 ja punainen väri lisäkoealoihin vuodelta 2024.

Pääryhmiä on mahdollista verrata pareittain seuraavilla kuudella tavalla: 2023 ja 2024 pysyvät koealat keskenään, 2023 pysyvät koealat ja 2023 lisäkoealat, 2023 pysyvät koealat ja 2024 lisäkoealat, 2024 pysyvät koealat ja 2023 lisäkoealat, 2024 pysyvät koealat ja 2024 lisäkoealat sekä 2023 ja 2024 lisäkoealat keskenään. Parivertailuista toteutettiin kolme: 2023 ja 2024 pysyvät koealat keskenään, 2023 pysyvät koealat ja 2023 lisäkoealat sekä kolmantena 2023 pysyvät koealat ja 2024 lisäkoealat. Muitten pääryhmien vertailun ei todettu tuottavan lisäarvoa tutkimuksen kannalta. 2023 pysyvät koealat toimivat siten vertailun kiintopisteenä kaikissa paitsi lisäkoealojen keskinäisessä vertailussa eikä lisäkoealojen vertaaminen 2024 pysyviin koealoihin tuottanut merkitsevää lisätietoa. Myös 2023 ja 2024 lisäkoealojen välinen vertailu karsiutui, sillä vanhan algoritmin maastossa valittujen lisäkoealojen ja uuden algoritmin kartan perusteella valittujen koealojen välillä ei ollut sellaista yhdistävää tekijää, minkä vertailu olisi ollut mielekästä. Jos vuonna 2024 olisi mitattu lisäkoealojen lisäksi maastossa valittavat toiset lisäkoealat samaan tapaan kuin 2023 lisäkoealat valittiin 2023 pysyvien koealojen läheisyydestä, olisi 2024 karttatiedon perusteella valittujen lisäkoealojen vertaaminen vuoden 2024 maastossa valittaviin lisäkoealoihin ollut mielekästä.

5.1 Koealatietojen tulokset

5.1.1 Vertailukelpoinen perustaso

Sovelluksen perusteella kerättävän tiedon vertailtavuuden vuoksi on olennaista selvittää sellaisen metsän kuolleisuuden ja riskitekijöitten perustaso, minne sovellus ei osoita ol-

lenkaan kohonnutta riskitasoa. Tällainen perustaso muodostaa vertailupohjan sille kuolleisuudelle, mitä sovelluksen havaitsemilta kohonneen riskin koealoilta on löydettävissä. Vertailukelpoisen perustason selvittämiseksi mitattiin 20 koealaa.

Taulukko 7. Kuolleisuuden ja riskitekijöitten perustaso terveessä kuusivaltaisessa vertailumetsässä

Terve metsä Puulaji	Kpl	Keski lpm (cm)	Elä- viä	Kuol- leita	Kuol- leita % os.	Kirj. pai- naja	Täh- tikir- jaaja	Kaa- tu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Mänty	7	30	7	0	0	0	0	0	0	0	0	0	0	0
Kuusi	127	28	125	2	1,6	0	0	1	1	0	2	4	0	0
Koivu	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Haapa	1	30	1	0	0	0	0	0	0	0	0	0	0	0
H.leppä	1	15	1	0	0	0	0	0	0	0	0	0	0	0
T.leppä	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Pihlaja	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Yhteensä	136	28	134	2	1,5	0	0	1	1	0	2	4	0	0

Terveessä vertailukelpoisessa metsässä oli koealojen perusteella keskimäärin 93 % kuuksia, mikä selittyy sillä, että koko tutkimus keskittyy kuusivaltaisiin koealoihin ja siten myös terveen metsän vertailukelpoiset koealat valikoitiin kuusivaltaisista metsistä. Kuusista 2 kappaletta eli 1,6 % olivat kuolleita ja riskitekijöitä löytyi 6 % kuusista. Riskitekijät olivat suurimmaksi osaksi koroja, mutta muutama pihkavuoto, yksi katkennut latva ja yksi myrskyn kaatama puu havaittiin myös.

5.1.2 Koealojen elinvoimaisuuden status

Koealojen elinvoimaisuutta verrattaessa erotettiin tulokset toisistaan pääryhmittäin ja niitä verrattiin toisiinsa pareittain. Jaottelu tehtiin kappaleessa 4.2.7 kuvatulla tavalla terveisiin, stressaantuneisiin ja vahingoittuneisiin koealoihin. Tulokset koottiin pääryhmittäin elinvoimaisuuden statusta esittävään taulukkoon.

Taulukko 8. Koealojen elinvoimaisuuden status pääryhmittäin kappaleittain mitattuna.


	Terve 0-2	Stressaantunut 3-5	Vahingoittunut 6+
Pysyvät koealat 2023	42	27	31
Pysyvät koealat 2024	35	28	36
Lisäkoealat 2023	14	11	76
Lisäkoealat 2024	43	19	38

Ensimmäinen tarkasteltava vertailupari oli pysyvät koealat vuosilta 2023 ja 2024. Tämä vertailupari muodosti alun perin työn olennaisimman tutkittavan ryhmän, sillä vuonna 2023 korkeimman riskin alueelle asetetut koealat olivat potentiaalisimpia osoittamaan muutosta terveestä vahingoittuneempaan suuntaan. Algoritmin muutos vuosien välissä aiheutti sen, että uuden algoritmin mukaan nämä koealat eivät osuneet enää korkeimman riskin alueelle siitä huolimatta, että vanha algoritmi määritteli nämä kohteet korkeimman riskin alueiksi. Siten tarkastelun merkitys laski, sillä tarkastelu olisi mielekkäämpää, jos laskenta osoittaisi kummallekin vuodelle korkeaa riskiä.

Kuitenkin verrattaessa pysyvien koealojen eri vuosia toisiinsa taulukon 9 indeksilukujen kautta, nähdään että pientä siirtymää vuosien välillä on tapahtunut. Terveiksi määriteltyjä koealoja oli vuonna 2024 enää 83 % siitä määrästä, mitä niitä oli vuonna 2023. Stressaantuneiden koealojen määrä kasvoi 104 %:iin ja vahingoittuneiden koealojen määrä kasvoi 116 %:iin. Siirtymää vahingoittuneempaan suuntaan on siten tapahtunut jonkin verran. Siirtymä on nähtävissä graafisesti kuviossa 6.

Taulukko 9. Pysyvien koealojen elinvoimaisuuden statuksen indeksiluku vuosilta 2023 ja 2024.

	Terve 0-2	Stressaantunut 3-5	Vahingoittunut 6+
Pysyvät koealat 2023	100	100	100
Pysyvät koealat 2024	83	104	116



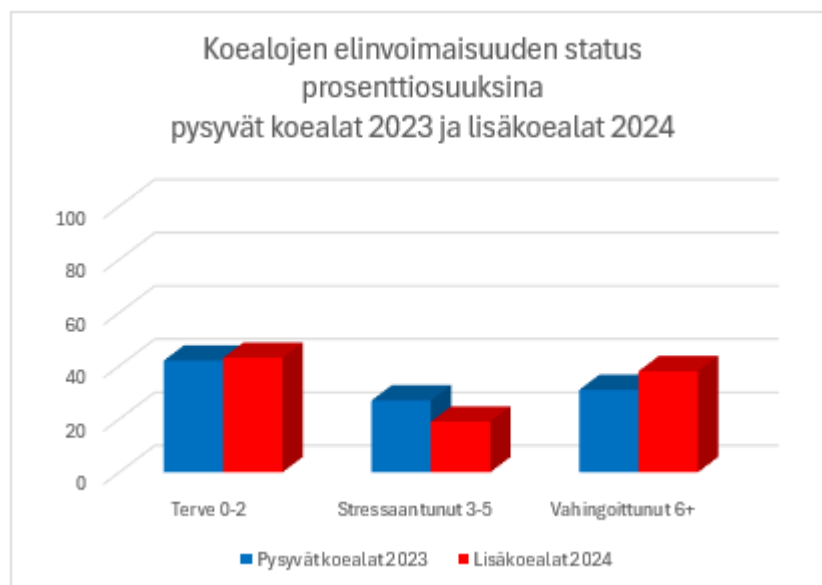
Kuvio 6. Elinvoimaisuuden status prosenttiosuuksina pysyvillä koealoilla vuosina 2023 ja 2024.

Ensimmäinen vertailupari on juuri se vertailupari, jossa sovelluksen tuhojen ennakoitokyky tulee näkymään, mutta ennakoitokyvyn selvittämiseksi algoritmin laskennan tulisi vakiintua siinä määrin, että laskenta ei muutu enää merkittävästi etenkään takautuvasti. Takautuvat muutokset vievät pohjaa vertailun muodostamiselta, sillä jos vertailupari ei uuden laskennan mukaan osu kummankaan vuoden osalta riskialueelle, ei vertailupari pääse vertaamaan sitä mitä sen alun perin oli tarkoitus mitata. Algoritmin voi olettaa muuttuvan kehityksensä alkuvaiheessa enemmän, mutta vakiintuvan melko pian.

Toinen tarkasteltava vertailupari on vuoden 2023 pysyvien koealojen vertaaminen vuoden 2024 lisäkoealoihin. Tämä tarkastelu näyttää uuden algoritmin painotuksia verrattuna vanhan algoritmin painotuksiin. Algoritmien välinen ero osoittaa sen, että uuden algoritmin painotuksilla ollaan saatu mitattua koealoilta 23 % enemmän vahingoittuneeseen kategoriaan osuvia tuloksia. Siirtymä on ollut enimmäkseen vahingoittuneesta kategoriasta terveitten sijaan.

Taulukko 10. 2023 pysyvien koealojen ja 2024 lisäkoealojen elinvoimaisuuden statuksen indeksiluku.

	Terve 0-2	Stressaantunut 3-5	Vahingoittunut 6+
Pysyvät koealat 2023	100	100	100
Lisäkoealat 2024	102	70	123



Kuvio 7. Elinvoimaisuuden status prosenttiosuuksina 2023 pysyvillä koealoilla ja 2024 lisäkoealoilla.

Kolmas vertailupari on 2023 pysyvät koealat ja 2023 lisäkoealat. Näitten vertaaminen näyttää sen, että vaikka sovelluksen perusteella valitut pysyvät koealat eivät ole välttämättä olleet juuri siinä kohtaa, missä metsässä todellisuudessa on suurin riski metsälle, on sovellus kuitenkin ohjannut hyvin lähelle merkittäviä tuhoalueita ja tuhoriskin alla olevia alueita. Indeksissä 2023 pysyvät koealat muodostavat perustason, johon verrattuna niiden läheltä on löytynyt hilaruutuja, joissa on ollut 2,45-kertainen määrä kuolleita puita sekä havaittuja altistavia riskitekijöitä yhteensä.

Taulukko 11. 2023 pysyvien koealojen ja 2023 lisäkoealojen elinvoimaisuuden statuksen indeksiluku.

	Terve 0-2	Stressaantunut 3-5	Vahingoittunut 6+
Pysyvät koealat 2023	100	100	100
Lisäkoealat 2023	33	41	245



Kuvio 8. Elinvoimaisuuden status prosenttiosuuksina 2023 pysyvillä koealoilla ja 2023 lisäkoealoilla.

5.1.3 Koealatietojen yhteenvedot pääryhmittäin

Koealatietojen helpomman käsiteltävyyden vuoksi pääryhmistä tehtiin yhteenvedot, missä on laskettu kaikki sen pääryhmän mukaiset koealat yhteen. Ensimmäisenä esitel-

lään 2023 ja 2024 pysyvien koealojen yhteenlasketut summat koealoilta, missä on summattu yhteen kappalemääräisinä kaikkien 74 koealan tiedot yhteen. Ylempi taulukko esittää 2023 tiedot, keskimääräinen 2024 tiedot ja alimmainen taulukko vuosien välisen muutoksen.

Taulukko 12. Pysyvien koealojen yhteenlasketut puumäärät, riskitekijät ja muutoksen suuruudet pysyviltä koealoilta vuosilta 2023 ja 2024.

Pysyvät koealat, absoluuttiset yhteenlasketut määrät													
2023 Kpl		Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu	Yhteensä riskiteki- jöitä
Puulaji													
Mänty	17	12	5	0	0	0	2	3	0	0	0	0	5
Kuusi	761	609	143	42	13	18	42	28	40	23	0	26	232
Koivu	40	34	6	0	0	1	2	0	0	0	0	1	4
Haapa	4	4	0	0	0	0	0	0	0	0	0	0	0
H.leppä	5	3	2	0	0	0	0	0	0	0	0	2	2
T.leppä	0	0	0	0	0	0	0	0	0	0	0	0	0
Pihlaja	1	1	0	0	0	0	0	0	0	0	0	0	0
Yhteensä	828	663	156	42	13	19	46	31	40	23	0	29	243
2024 Kpl		Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu	Yhteensä riskiteki- jöitä
Puulaji													
Mänty	17	12	5	0	0	0	2	3	0	0	0	0	5
Kuusi	761	594	158	49	15	20	52	31	43	27	5	30	272
Koivu	40	34	6	0	0	2	2	0	0	0	0	1	5
Haapa	4	4	0	0	0	0	0	0	0	0	0	0	0
H.leppä	5	3	2	0	0	0	0	0	0	0	0	2	2
T.leppä	0	0	0	0	0	0	0	0	0	0	0	0	0
Pihlaja	1	1	0	0	0	0	0	0	0	0	0	0	0
Yhteensä	828	648	171	49	15	22	56	34	43	27	5	33	284
Muutos		Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu	Yhteensä riskiteki- jöitä
Puulaji													
Mänty		0	0	0	0	0	0	0	0	0	0	0	0
Kuusi		-15	15	7	2	2	10	3	3	4	5	4	40
Koivu		0	0	0	0	1	0	0	0	0	0	0	1
Haapa		0	0	0	0	0	0	0	0	0	0	0	0
Harmaaleppä		0	0	0	0	0	0	0	0	0	0	0	0
Tervaleppä		0	0	0	0	0	0	0	0	0	0	0	0
Pihlaja		0	0	0	0	0	0	0	0	0	0	0	0
Yhteensä		-15	15	7	2	3	10	3	3	4	5	4	41

2023 ja 2024 pysyvien koealojen osalta laskettiin myös keskimääräisen koealan tiedot jakamalla yhteenlasketut summat koealojen määrällä (74). Näin saatiin taulukkoa 7 mukaileva taulukko 8, mikä osoittaa absoluuttisten summien sijaan luvut keskimäärin koealaa kohden ja keskimääräisen muutoksen vuosien välillä per koeala. Lisäkoealoilta laskettiin vastaavasti yhteenlasketut summat. 2023 ja 2024 lisäkoealoja on kumpiakin 37.

Taulukko 13. 2023 ja 2024 pysyvien koealojen keskiarvoiset puumäärät, riskitekijät ja muutoksen suuruudet.

Pysyvät koealat, keskiarvot per koeala												
2023	Kpl	Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Puulaji												
Mänty	0,2	0,2	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Kuusi	10,3	8,2	1,9	0,6	0,2	0,2	0,6	0,4	0,5	0,3	0,0	0,4
Koivu	0,5	0,5	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Haapa	0,1	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
H.leppä	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
T.leppä	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Pihlaja	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Yhteensä	11,2	9,0	2,1	0,6	0,2	0,3	0,6	0,4	0,5	0,3	0,0	0,4
2024	Kpl	Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Puulaji												
Mänty	0,2	0,2	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Kuusi	10,3	8,0	2,1	0,7	0,2	0,3	0,7	0,4	0,6	0,4	0,1	0,4
Koivu	0,5	0,5	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Haapa	0,1	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
H.leppä	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
T.leppä	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Pihlaja	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Yhteensä	11,2	8,8	2,3	0,7	0,2	0,3	0,8	0,5	0,6	0,4	0,1	0,4
Muutos		Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Puulaji												
Mänty		0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Kuusi		-0,2	0,2	0,1	0,0	0,0	0,1	0,0	0,0	0,1	0,1	0,1
Koivu		0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Haapa		0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Harmaaleppä		0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Tervaleppä		0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Pihlaja		0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Yhteensä		-0,2	0,2	0,1	0,0	0,0	0,1	0,0	0,0	0,1	0,1	0,1

Taulukko 14. 2023 ja 2024 lisäkoalojen yhteenlasketut puumäärät ja riskitekijät.

Valinnaiset koealat, absoluuttiset yhteenlasketut määrät													
2023	Kpl	Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu	Yhteensä riskiteki- jöitä
Puulaji													
Mänty	13	8	5	0	0	3	0	0	0	0	0	2	5
Kuusi	395	222	173	52	30	41	38	33	24	5	7	20	250
Koivu	15	14	1	0	0	1	0	0	0	0	0	0	1
Haapa	4	3	1	0	0	0	0	0	0	0	0	1	1
H.leppä	1	1	0	0	0	0	0	0	0	0	0	0	0
T.leppä	1	1	0	0	0	0	0	0	0	0	0	0	0
Pihlaja	2	2	0	0	0	0	0	0	0	0	0	0	0
Yhteensä	431	251	0	52	30	45	38	33	24	5	7	23	257
2024	Kpl	Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu	Yhteensä riskiteki- jöitä
Puulaji													
Mänty	68	48	20	0	0	3	4	2	2	0	2	14	27
Kuusi	248	187	61	22	11	17	4	3	18	4	1	11	91
Koivu	23	22	1	0	0	1	0	0	0	1	0	0	2
Haapa	3	2	1	0	0	1	0	0	0	0	0	0	1
H.leppä	3	3	0	0	0	0	0	0	0	0	0	0	0
T.leppä	0	0	0	0	0	0	0	0	0	0	0	0	0
Pihlaja	8	2	6	0	0	0	0	0	0	0	0	6	6
Yhteensä	366	273	92	22	11	22	8	5	20	5	3	31	127

Vaikka lisäkoealojen tiedot on mitattu eri koealoilta, voidaan niitten tiedoista silti laskea keskimääräisiä lukuja jotka ovat vertailukelpoisia muihin pääryhmiin nähden. On vain pidettävä mielessä, että 2023 lisäkoealat valittiin käyttäen eri kriteerejä kuin 2024 lisäkoealat, mikä selittää lisäkoealojen eri vuosien väliset erot. 2024 lisäkoealat ovat verranollisempia pysyviin koealoihin kuin 2023 lisäkoealoihin.

Taulukko 15. 2023 ja 2024 lisäkoealojen keskimääräiset puumäärät ja riskitekijät.

Valinnaiset koealat, keskiarvot per koeala												
2023	Kpl	Elä- viä	Kuol- leita	Kirj. pai- naja	Täh- tikir- jaaja	Kaa- tu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Puulaji												
Mänty	0,4	0,2	0,1	0,0	0,0	0,1	0,0	0,0	0,0	0,0	0,0	0,1
Kuusi	10,7	6,0	4,7	1,4	0,8	1,1	1,0	0,9	0,6	0,1	0,2	0,5
Koivu	0,4	0,4	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Haapa	0,1	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
H.leppä	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
T.leppä	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Pihlaja	0,1	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Yhteensä	11,6	6,8	4,9	1,4	0,8	1,2	1,0	0,9	0,6	0,1	0,2	0,6
	0,0											
2024	Kpl	Elä- viä	Kuol- leita	Kirj. pai- naja	Täh- tikir- jaaja	Kaa- tu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Puulaji												
Mänty	1,8	1,3	0,5	0,0	0,0	0,1	0,1	0,1	0,1	0,0	0,1	0,4
Kuusi	6,7	5,1	1,6	0,6	0,3	0,5	0,1	0,1	0,5	0,1	0,0	0,3
Koivu	0,6	0,6	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Haapa	0,1	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
H.leppä	0,1	0,1	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
T.leppä	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Pihlaja	0,2	0,1	0,2	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,2
Yhteensä	9,9	7,4	2,5	0,6	0,3	0,6	0,2	0,1	0,5	0,1	0,1	0,8

Tutkittavan sovelluksen tuottaman datan tarkkuuden selvittämiseksi olennaisimpia tietokenttiä ovat elävien ja kuolleiden puitten suhteelliset osuudet, sillä sitä kautta päästään käsiksi heikentyneitten puitten määrään. Seuraavaksi keskitytään vertaamaan eri pääryhmiä keskenään käyttäen kuolleitten puitten osuutta mittarina.

5.1.4 2023 ja 2024 pysyvät koealat

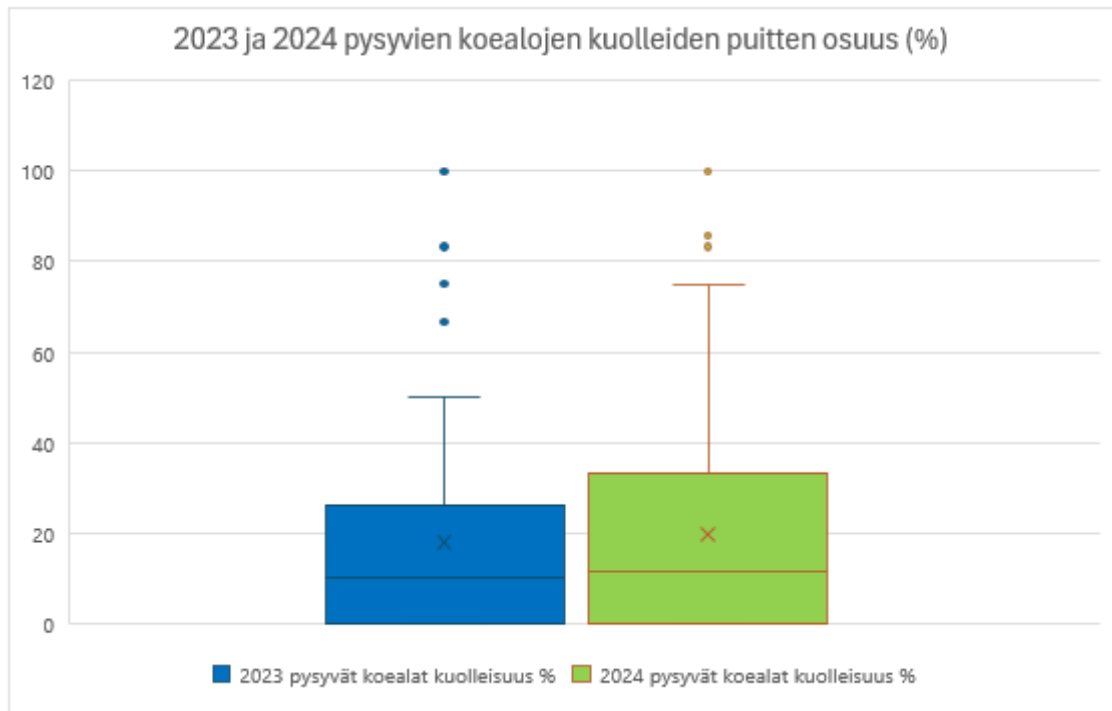
2023 ja 2024 pysyvien koealojen tietoja verrattiin toisiinsa käyttäen useampaa eri tapaa. Ensinnäkin käytettiin luvussa 4.2 esiteltyä indeksin muodostamista, missä 2023 pysyvät koealat muodostavat indeksin pohjan, johon 2024 pysyviä koealoja verrataan. 2023 pysyville koealoille annetaan joka sarakkeeseen arvo 100, joten jos 2024 pysyvien koealojen indeksiluku on yli 100, on sen arvo suurempi kuin 2023 pysyvien koealojen vastaava arvo

ja jos taas 2024 pysyvien koealojen indeksi on pienempi kuin 100, on se vastaavasti laskenut 2023 pysyvien koealojen tietoihin nähden. Indeksien värityksessä on jätetty värittömäksi solu jos indeksiluku on sama kuin 2023 pysyvillä koealoilla, värjätty punaisella jos indeksiluku on suurempi kuin 2023 pysyvillä koealoilla ja värjätty vihreällä jos indeksiluku on pienempi kuin 2023 pysyvillä koealoilla. Indeksien voitiin todeta näyttävän kaikissa muuttuneissa kategorioissa muutosta huonompaan. Elävien puitten osuus on vihreällä korostettu, koska lukema on 2024 pysyvillä koealoilla pienempi kuin vuonna 2023, mutta kehitystä ei puuston kannalta ole positiivinen.

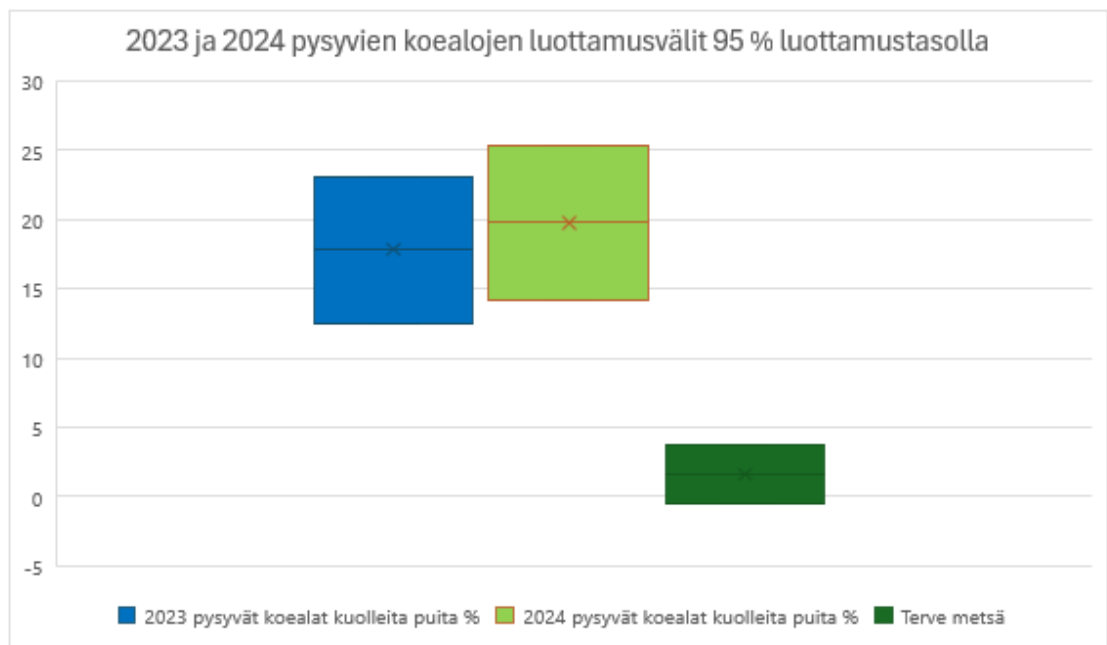
Taulukko 16. Indeksi 2023 ja 2024 pysyvien koealojen välillä, missä vuoden 2023 koealat saavat arvon 100.

Indeksi 2024 pysyville koealoille (2023 pysyvät koealat = 100)											
2023 Kpl	Eläviä	Kuolleita	Kirj. painaja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Puulaji											
Mänty	100	100	100				100	100			
Kuusi	100	98	110	117	115	111	124	111	108	117	115
Koivu	100	100	100			200	100				100
Haapa	100	100									
H.leppä	100	100	100								100
T.leppä											
Pihlaja	100	100									
Yhteensä	100	98	110	117	115	116	122	110	108	117	114

2023 ja 2024 pysyviä koealoja tarkasteltiin myös puitten kuolleisuuden osalta käyttäen ruutu- ja janakaaviota. Seuraavat kaksi kaaviota esittävät kuolleitten puitten osuudet prosenttiosuuksina kaikista koealojen puista sekä kuolleitten puitten prosentuaalinen osuus käyttäen 95 % luottamusväliä. Luottamusvälilaskenta osoittaa sen alueen, mille satunnaisesti havaintojoukosta valitun koealan kuolleisuusprosentti 95 % todennäköisyydellä asettuu.



Kuvio 9. 2023 ja 2024 pysyvien koealojen kuolleitten puitten prosentuaaliset osuudet ruutu- ja janakaaviolla.



Kuvio 10. 2023 ja 2024 pysyvien koealojen kuolleitten puitten prosentuaalinen osuus 95 % luottamusvälillä, missä kuvio näyttää luottamusvälin ylä- ja alarajan. Vertailussa mukana myös terveen metsän vertailutaso.

5.1.5 2023 pysyvät koealat ja 2024 lisäkoealat

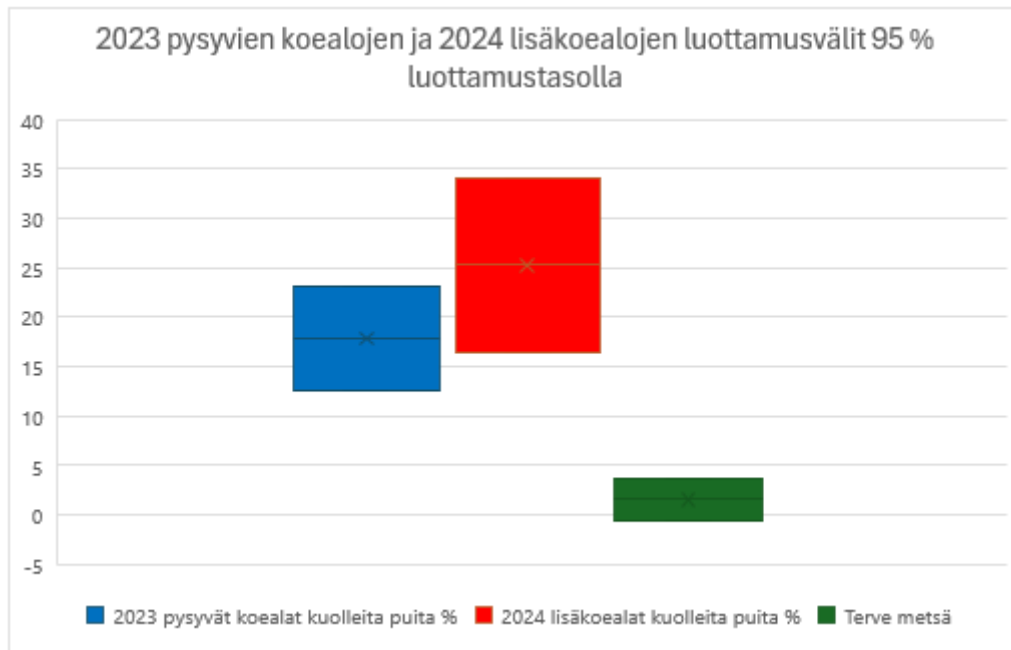
Seuraava pääryhmien välinen tarkastelu kohdistui 2023 pysyviin koealoihin ja 2024 lisäkoealoihin. Näitten kahden pääryhmän välinen tarkastelu on hyvin samankaltainen ja siten hyvin verrattavissa 2023 ja 2024 pysyvien koealojen väliseen vertailuun. Ainoa olennainen ero oli, että 2024 lisäkoealat ovat uuden algoritmin mukaisen laskennan tulos ja 2023 pysyvät koealat vanhan laskennan. 2023 pysyvien koealojen ja 2024 lisäkoealojen osalta laskettiin indeksiluvut, kuolleitten puitten suhteellinen osuus ja kuolleitten puitten suhteellisen osuuden luottamusväliä 95 % luottamusastetta käyttäen.

Taulukko 17. Indeksi 2023 pysyvien koealojen ja 2024 lisäkoealojen välillä, missä 2023 pysyvät koealat saavat arvon 100.

Indeksi 2024 lisäkoealoille (2023 pysyvät koealat = 100)											
2023 Kpl	Eläviä	Kuolleita	Kirj. pa:naja	Tähtikirjaaja	Kaatu- nut	Kat- ken- nut	Kil- pai- lu	Pih- kav.	Koro	Har- suun- tunut	Muu
Puulaji											
Mänty	153	133	200			0	0				
Kuusi	104	73	242	248	462	456	181	236	120	43	154
Koivu	75	82	33			200	0				0
Haapa	200	150									
H.leppä	40	67	0								0
T.leppä											
Pihlaja	400	400									
Yhteensä	104	76	231	248	462	474	165	213	120	43	159



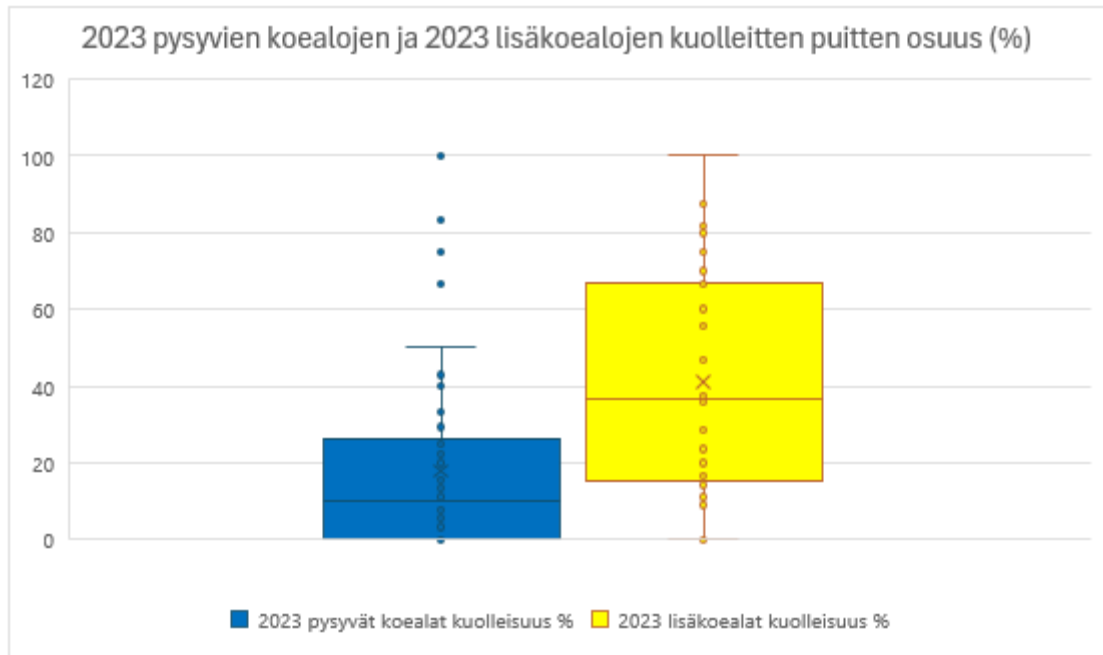
Kuvio 11. 2023 pysyvien koealojen ja 2024 lisäkoealojen kuolleitten puitten prosentuaaliset osuudet ruutu- ja janakaaviolla.



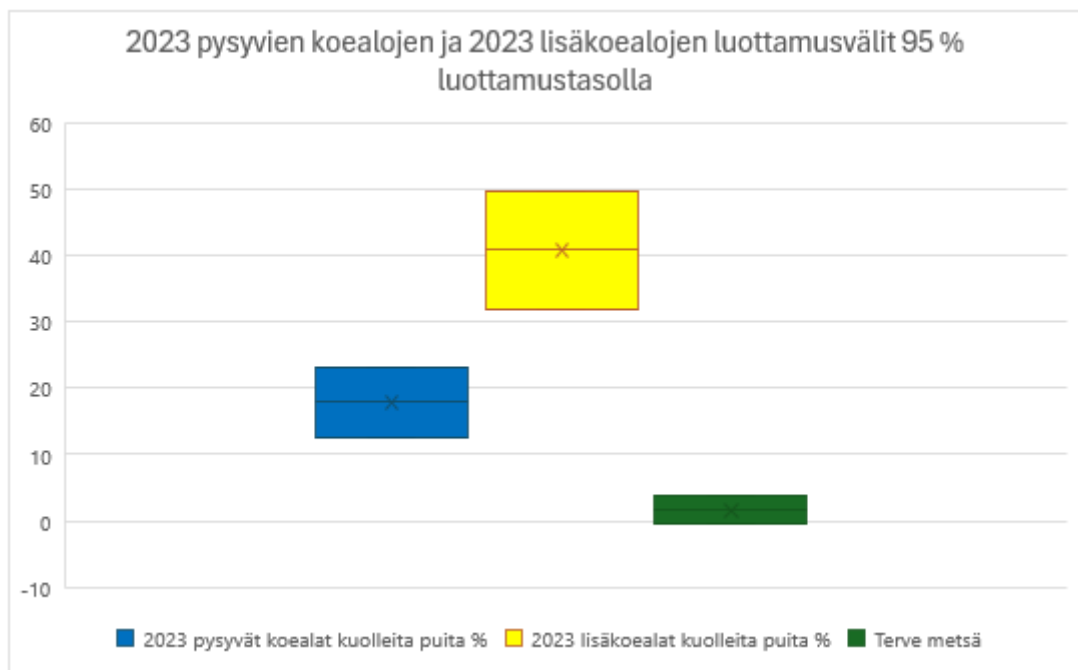
Kuvio 12. 2023 pysyvien koealojen ja 2024 lisäkoealojen kuolleitten puitten prosentuaalinen osuus 95 % luottamusvälillä, missä kuvio näyttää luottamusvälin ylä- ja alarajan. Vertailussa mukana myös terveen metsän vertailutaso.

5.1.6 2023 pysyvät koealat ja 2023 lisäkoealat

2023 pysyville koealoille ja 2023 lisäkoealoille tehtiin vastaavanlaiset kaaviot kuolleitten puitten prosenttiosuudesta ja kuolleiden puitten prosentuaalisen osuuden luottamusvälistä 95 % luottamusasteella. Kuitenkin indeksitarkastelua ei tehty näitten pääryhmien välillä, sillä 2023 lisäkoealat eroavat aineiston valikoitumistavallaan muista pääryhmistä siinä määrin, ettei indeksitarkastelu tuottaisi tarkasteluun sopivaa tietoa.



Kuvio 13. 2023 pysyvien koealojen ja 2023 lisäkoealojen kuolleitten puitten prosentuaaliset osuudet ruutu- ja janakaaviolla.



Kuvio 14. 2023 pysyvien koealojen ja 2023 lisäkoealojen kuolleitten puitten prosentuaalinen osuus 95 % luottamusvälillä, missä kuvio näyttää luottamusvälin ylä- ja alarajan. Vertailussa mukana myös terveen metsän vertailutaso.

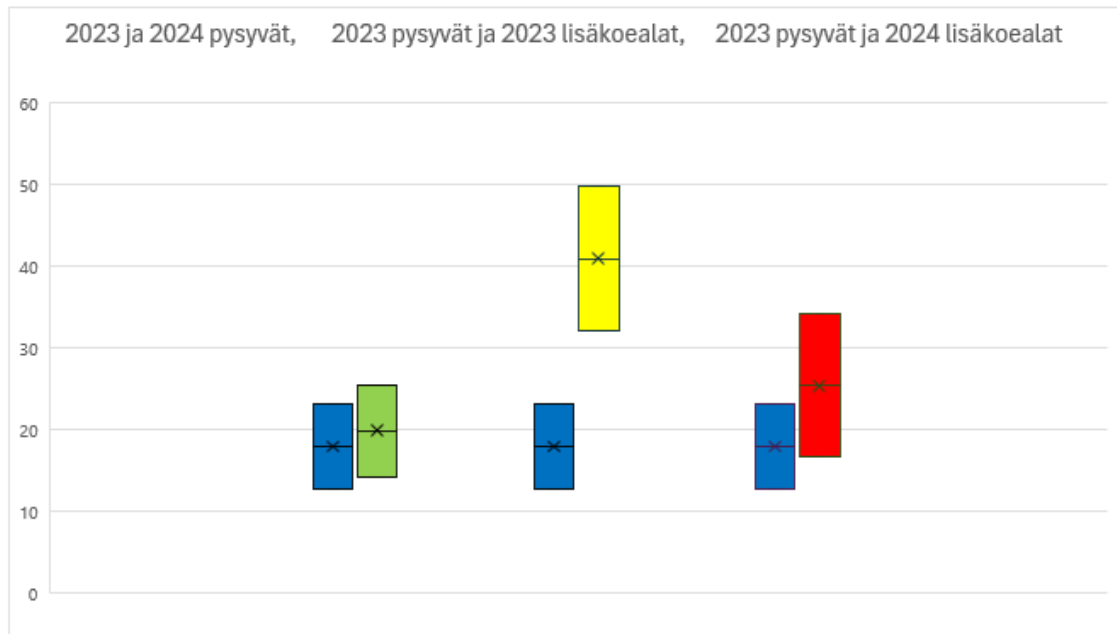
5.1.7 Pääryhmien kokoomayhteenvedot

Kaikista pääryhmistä tehtiin kokoomakaavio, josta voidaan tarkastella pääryhmien kuolleitten puitten keskiarvoja prosenttiosuuksina, niiden keskihajontaa sekä luottamusväliä 95 % luottamustasolla. Luottamusvälin ala- ja ylärajat laskettiin niin, että alaraja on kuolleitten puitten keskiarvo miinus luottamusväli ja yläraja on kuolleitten puitten keskiarvo plus luottamusväli. P-arvo on ollessa 0,05 tai pienempi voidaan todeta, että nollassa nollahypoteesi ”otokset eivät poikkea toisistaan” voidaan hylätä ja vastahypoteesi ”otokset poikkeavat merkitsevästi toisistaan” jää voimaan. P-arvo laskettiin vertaamalla muita ryhmiä vuoden 2023 pysyviin koealoihin ja sen perusteella vain 2023 lisäkoealat poikkesivat merkitsevästi muista pääryhmistä, vaikka muissakin on havaittavissa muutosta.

Taulukko 18. Kokoomataulukko, missä näkyy pääryhmien sisältämien koealojen määrä, keskimääräinen kuolleisuus, kuolleisuuden keskihajonta, luottamusväli ja p-arvo. Vertailussa mukana myös terveen metsän vertailutaso.

	N	Kuolleita puita keskimäär. (%)	Keskihajonta	Luott.väli 95 %	Luott.väli alaraja	Luott.väli yläraja	p-arvo (2-suunt.)
2023 pys. koealat kuolleita puita %	74	18	23,2	5,3	12,6	23,1	
2024 pys. koealat kuolleita puita %	74	20	24,6	5,6	14,2	25,4	0,612
2023 pys. koealat kuolleita puita %	74	18	23,2	5,3	12,6	23,1	
2023 lisäkoealat kuolleita puita %	37	41	27,6	8,9	32,0	49,7	<0,001
2023 pys. koealat kuolleita puita %	74	18	23,2	5,3	12,6	23,1	
2024 lisäkoealat kuolleita puita %	37	25	27,3	8,8	16,5	34,1	0,161
Terve vertailumetsä	20	1,6	4,8	2,1	-0,5	3,7	

Pääryhmien luottamusvälit kerättiin myös yhteen kokoomakaavioon, jotta pääryhmien väliset erot on helpompi nähdä graafisesti samanaikaisesti. Kaavio esittää luottamusvälin alarajan ja ylärajan kullekin päätyypille. 2023 pysyvät koealat ovat vertailun vuoksi esitetty perustasona aina sen pääryhmän vieressä, mihin sitä on aiemmin jo verrattu.



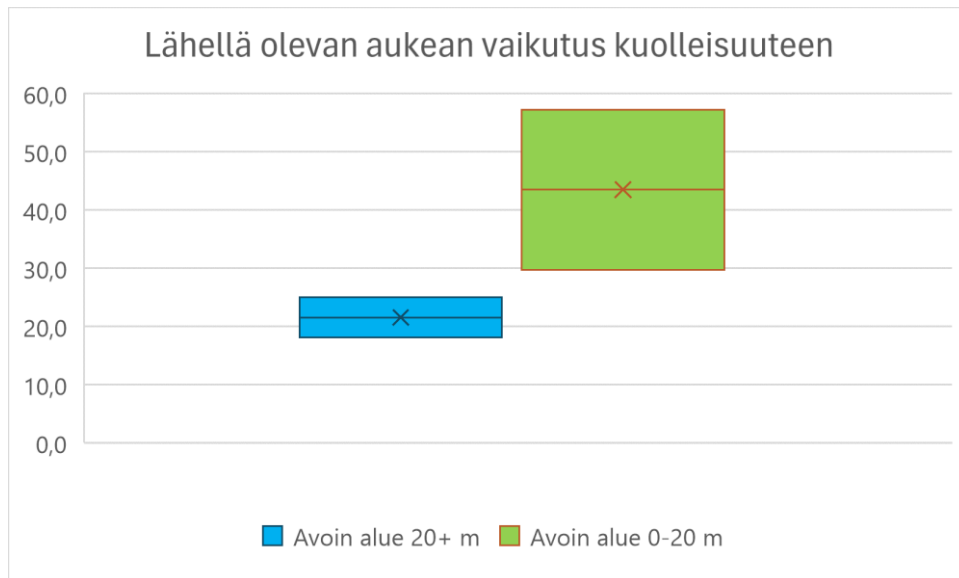
Kuvio 15. Pääryhmien luottamusvälit esitettynä yhdessä kaaviossa, missä kuvio näyttää luottamusvälin ylä- ja alarajan.

5.1.8 Lähellä olevan aukean alan vaikutus kuolleisuuteen

Kaikkien pääryhmien kaikkien koealojen maastossa tapahtuvan tiedonkeruun yhteydessä on tallennettu myös se tieto, onko koeala kahtakymmentä metriä lähempänä aukeaa alaa. Seuraavassa taulukossa 14 ja kuviossa 13 esitetään eriteltynä ne koealat, jotka ovat olleet enintään 20m päässä aukeasta alasta. Pääryhmällä ei ole vaikutusta tarkasteluun.

Taulukko 19. Keskimääräinen kuolleisuus koealoilla silloin, kun koealat luokitellaan pääryhmien sijaan sen mukaan, ovatko ne lähellä vai kauempana aukeasta alasta.

	N	Keski-arvo (%)	Keski-hajonta	Luott.väli 95 %	Luott.väli alaraja	Luott.väli yläraja	p-arvo (2-suunt.)
Avoim alue 20+ m	201	21,5	24,8	3,4	18,1	24,9	
Avoim alue 0-20 m	21	43,4	32,2	13,8	29,7	57,2	<0,001



Kuvio 16. Aukean läheisyyden vaikutus kuolleisuusprosenttiin, missä kuvio näyttää luottamusvälin ylä- ja alarajan.

Laskettaessa p-arvoa sille, vaikuttaako avoimen alueen läheisyys kuolleisuuteen, muodostetaan alkuun nollahypoteesiksi ”avoimella alueella ei ole vaikutusta kuolleisuuteen” ja vastahypoteesiksi tulee ”avoimella alueella on vaikutusta kuolleisuuteen”. P-arvoksi saatiin alle 0,001, eli tilastollinen merkitsevyys on huomattava. Siten nollahypoteesi hylätään ja vastahypoteesi jää voimaan. Toisin sanoen, avoimella alueella koealan läheisyydessä on huomattava merkitys kuolleisuuteen.

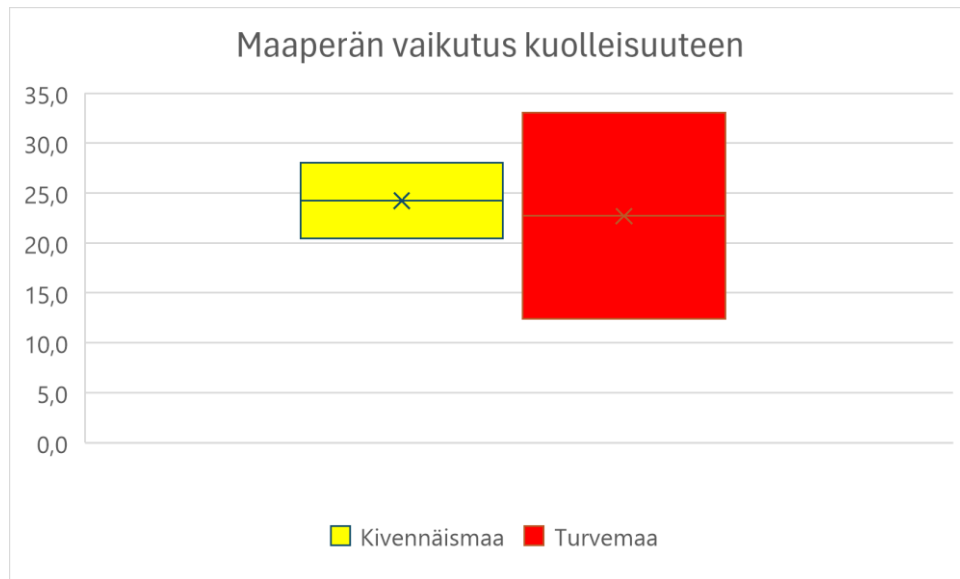
Kuitenkin avoimen alueen vaikutuksessa kuolleisuusprosenttiin on otettava huomioon se, että otoskoko niistä koealoista, jotka ovat 0-20m etäisyydellä avoimesta alasta, on melko pieni ($n=21$). Otoskoko otetaan huomioon keskihajonnan ja p-arvon laskennassa, mutta siitä huolimatta laskenta on altis poikkeaville havaintoyksiköille, jotka sijaitsevat sattumalta poikkeuksellisen lähellä normaalijakauman toista ääripäätä.

5.1.9 Maaperän vaikutus kuolleisuuteen

Kaikkien pääryhmien kaikkien koealojen maastossa tapahtuvan tiedonkeruun yhteydessä on tallennettu myös se tieto, onko koeala kivennäismaalla vai turvemaalla. Seuraavassa taulukossa 15 ja kuviossa 14 esitetään eriteltyinä ne koealat, jotka ovat olleet kivennäismaalla ja mitkä taas turvemaalla. Pääryhmällä ei ole vaikutusta tarkasteluun.

Taulukko 20. Keskimääräinen kuolleisuus silloin, kun koealat luokitellaan pääryhmien sijaan maaperän mukaan.

	N	Keski-arvo (%)	Keskihajonta	Luott.väli 95 %	Luott.väli alaraja	Luott.väli yläraja	p-arvo (2-suunt.)
Kivennäismaa	181	24,2	26,1	3,8	20,4	28,0	0,429
Turvemaa	41	20,6	27,0	8,3	12,4	33,0	



Kuvio 17. Maaperän vaikutus kuolleisuusprosenttiin, missä kuvio näyttää luottamusvälin ylä- ja alarajan.

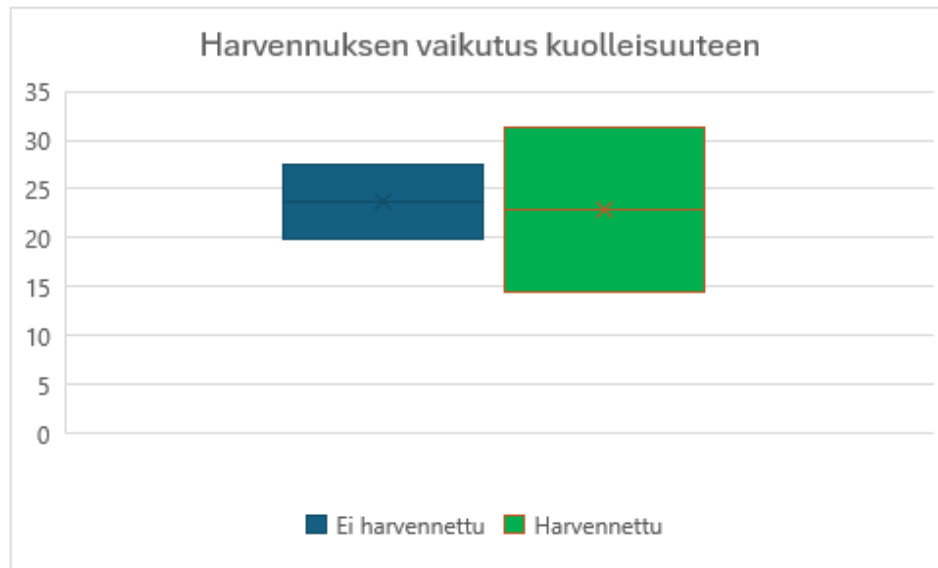
Laskettaessa p-arvoa sille, vaikuttaako maaperä kuolleisuuteen, muodostetaan alkuun nollahypoteesiksi ”maaperällä ei ole vaikutusta kuolleisuuteen” ja vastahypoteesiksi tulee ”maaperällä on vaikutusta kuolleisuuteen”. P-arvoksi saatiin 0,429 eli tilastollista merkittävyyttä ei ollut havaittavissa. Siten nollahypoteesi jää voimaan eli maaperällä ei ole tilastollisesti merkitystä kuolleisuuteen.

5.1.10 Harvennuksen vaikutus koealoihin

Kaikkien pääryhmien kaikkien koealojen maastossa tapahtuvan tiedonkeruun yhteydessä on tallennettu myös se tieto, onko koeala harvennettu vuoden 2018 jälkeen. Seuraavassa taulukossa 16 ja kuviossa 15 esitetään eriteltynä ne koealat, joitten alueelle on tehty metsänkätöilmoitus harvennuksesta 2018 tai sen jälkeen ja jossa maastossa on havaittavissa harvennuksen jälkiä esimerkiksi kannoista. Pääryhmällä ei ole vaikutusta tarkasteluun.

Taulukko 21. Keskimääräinen kuolleisuus silloin, kun koealat luokitellaan pääryhmien sijaan sen mukaan, onko alueella tehty harvennus 2018 jälkeen.

	N	Keski-arvo (%)	Keski-hajonta	Luott.väli 95 %	Luott.väli alaraja	Luott.väli yläraja	p-arvo (2-suunt.)
Ei harvenn.	180	24	25,9226846	3,7869696	20	28	
Harvennettu	42	23	28,0496502	8,4830279	14	31	0,825



Kuvio 18. Harvennuksen vaikutus kuolleisuuteen, missä kuvio näyttää luottamusvälin ylä- ja alarajan.

Laskettaessa p-arvoa sille, vaikuttaako harvennus kuolleisuuteen, muodostetaan alkuun nollahypoteesiksi ”harvennuksella ei ole vaikutusta kuolleisuuteen” ja vastahypoteesiksi tulee ”harvennuksella on vaikutusta kuolleisuuteen”. P-arvoksi saatiin 0,825 eli tilastollista merkitsevyyttä ei ollut havaittavissa. Siten nollahypoteesi jää voimaan eli harvennuksella ei ole tilastollisesti merkitystä kuolleisuuteen.

5.1.11 Kohteilta löydettyjen riskitekijöiden korrelaatioanalyysi

Kohteitten maastokartoituksen yhteydessä kartoitettiin puista eri riskitekijöitä, jotka voisivat liittyä puitten heikentymiseen ja kuolleisuuteen. Kartoituksen yhteydessä havaittiin, että suurin osa riskitekijöistä löytyi kuusista, mikä korreloi vahvasti sen kanssa, että kuusia löytyi koealojen puista muutenkin melko vastaava prosentuaalinen osuus.

Taulukko 22. Kuusen kappalemäärät ja prosentuaaliset osuudet koealojen puista ja kaisista riskitekijöistä.

	Kuusi määrä	Muitten määrä	Kuusen osuus %	Kuusi riskit	Muitten riskit	Kuusen osuus %	Riskitekij. per kuusi %
2023 pysyvät koealat	761	67	92	232	11	95	30
2024 pysyvät koealat	761	67	92	272	12	96	36
2023 lisäkoealat	395	36	92	250	7	97	63
2024 lisäkoealat	248	118	68	91	36	72	37
Terve vertailumetsä	127	9	93	8	0	100	6

Erilaisia riskitekijöitä oli kaikilla mitatuilla varsinaisilla koealoilla huomattavasti enemmän, kuin vertailukelpoisella terveessä metsässä, jonne sovellus ei osoittanut merkittävästi kohonnutta riskiä. Vuoden 2023 pysyvillä koealoilla oli viisinkertainen määrä riskitekijöitä per mitattu kuusi kuin terveessä metsässä ja 2023 lisäkoealoilla yli kymmenkertainen määrä.

Koska muitten puitten osuus kokonaismäärästä ja siten riskitekijöistä on niin pieni, ei niistä saa luotettavaa korrelaatioanalyysiä tehtyä. Kuusesta on kuitenkin riittävästi havaintoja siihen, että siitä voidaan tehdä luotettavasti korrelaatioanalyysi.

Taulukko 23. Pearsonin korrelaatiokertoimet kuusen riskitekijöille suhteessa kuolleisuuteen.

Pearsonin korrelaatiokerroin	Kirj. painaja	Tähtikirjaaja	Kaatu-	Katkenut	Kilpailu	Pihkav.	Koro	Har-suuntunut	Muu
Kuusi 2023 pysyvät koealat	0,8	0,2	0,2	0,2	0,3	-0,1	-0,2	0,0	0,5
Kuusi 2024 pysyvät koealat	0,7	0,3	0,3	0,2	0,2	-0,1	-0,2	0,2	0,5
Kuusi 2023 lisäkoealat	0,6	0,0	0,5	0,1	0,2	-0,4	-0,1	-0,2	0,3
Kuusi 2024 lisäkoealat	0,6	0,2	0,5	0,3	0,2	-0,1	-0,1	0,2	0,4

Pearsonin korrelaatioanalyysissä arvot, jotka ovat 0,7 ja yli, viittaavat voimakkaaseen korrelaatioon ja ne värjätettiin taulukossa 18 punaisella. Arvot, jotka ovat 0,3 ja 0,7 välillä, viittaavat kohtalaiseen korrelaatioon ja ne on värjätetty taulukossa keltaisella. Korrelaatio-
taulukosta oli havaittavissa, että kirjanpainaja, myrsky ja muu tuho nousevat kategorioina muitten yläpuolelle suhteessa kuolleitten puitten määrään.

5.2 Tulosten tarkastelu ja yhteenveto

2023 ja 2024 pysyvien koealojen, 2023 pysyvien koealojen ja 2023 lisäkoealojen sekä 2023 pysyvien koealojen ja 2024 lisäkoealojen välisessä tarkastelussa huomio kiinnittyi siihen, että vain 2023 pysyvien koealojen ja 2023 lisäkoealojen osalta p-arvo oli tilastollisesti merkitsevä. Muitten osalta nollahypoteesi jäi voimaan, eli pääryhmien välillä ei ollut tilastollisesti merkitsevää eroa suhteessa kuolleisuuteen. 2023 pysyvien koealojen ja 2023 lisäkoealojen välinen tilastollinen merkitsevyys selittyy pääasiassa sillä, että 2023 lisäkoealojen valintatapa poikkesi muitten pääryhmien valintatavasta. Siten voitiin nähdä, että jos ainoa havaittu tapa saada tilastollisesti merkitsevää eroa karttapohjaisesti valittuihin koealoihin oli valita koealat maastossa, niin se tarkoittaa sitä, että kartan vakavimman uhan alla olevat hilaruudut eivät välttämättä olleet maastossa kaikkein vakavimmin vaurioituneita hilaruutuja. Kaikilla varsinaisilla koealoilla oli kuitenkin huomattavasti suurempi kuolleisuus kuin terveellä vertailumetsällä, jossa kuolleisuus oli 1,6 % ja riskitekijöitä oli 6 %:lla kuusista.

Vertaamalla 2023 pysyviä koealoja vuoden 2024 lisäkoealoihin päästiin käsiksi siihen, oliko sovelluksen taustalla toimivan algoritmin osumatarkkuus parantunut vai huonontunut vuoden 2023 ja vuoden 2024 välillä. Vaikka p-arvo 0,161- ei alittanut tilastollisesti merkitsevän muutoksen rajaa 0,05, oli vuosien välillä silti selkeää muutosta nähtävissä. Kuolleisuusprosentti nousi 18 %:sta 25 %:iin, mikä indikoi sitä, että vuoden 2024 uuden algoritmin mukainen laskenta osui keskimäärin jonkin verran vakavammin vaurioituneisiin hilaruutuihin kuin vanhempi vuoden 2023 algoritmin mukainen laskenta. Siten todettiin, että algoritmi oli kehittynyt tarkempaan suuntaan.

Koealoihin vaikuttavista ulkoisista tekijöistä tarkasteltiin maaperän ja lähellä olevan aukean alueen vaikutusta kuolleisuuteen sekä sitä, vaikuttaako lähivuosina tehty harvennus koetuloksiin. Kaikkien kolmen oletettiin vaikuttavan kuolleisuuteen lisäävästi, mutta ainoastaan lähellä olevan aukean todettiin tilastollisesti olevan merkityksellinen. Maaperän oletettiin vaikuttavan niin, että turvemaa ei pystyisi ankkuroimaan puita yhtä hyvin pystyyn kuin mitä kivennäismaa pystyisi, mutta tästä ei saatu vahvistavaa näyttöä. Itse asiassa koetulokset näyttivät päinvastaista tulosta, eli kivennäismailla kuolleisuus oli korkeampaa. 2018 jälkeisen harvennuksenkaan ei todettu lisäävän kuolleisuutta. Harvennetut koealat saivat kuitenkin suuremman vaihteluvälin, mikä selittyy osaltaan sillä, että

koealoja oli vähemmän kuin harventamattomia koealoja. Otoskoko vaikuttaa vaihteluvälin suuruuteen.

Puitten riskitekijöitten suhteen kirjanpainaja korreloi vahvasti kuolleisuuden kanssa kun taas myrskyn kaatamat ja muut tuhot korreloivat keskivahvasti. Muu tuho -kategoriassa oli edustettuina tunnistettuja tuhoja, kuten esimerkiksi mesisieni, mutta sinne rekisteröityi myös sellaiset hyönteistuhot, joista ei vielä pystynyt varmistumaan tuhon aiheuttajasta. Siten oletettavaa on, että jos seurantaa alueelle jatkettaisiin, nämä muihin tuhoihin kategorisoidut tuhot jakautuisivat tunnistettuihin kategorioihin suurelta osin.

6 PÄÄTELMÄT

6.1 Päätelmiä

Eri pääryhmien välinen vertailu tuotti mielenkiintoista tietoa tutkittavan sovelluksen kehityksestä. Voidaan todeta, että vuosien välillä on nähtävissä kehitystä silloinkin, kun se ei ylittänyt tilastollisesti merkitsevän muutoksen rajaa. Kehitys jatkui kuitenkin saman suuntaisena tarkentuen entisestään, mikä on sovelluksen työelämäkäytön kannalta olennaisempaa kuin tilastollinen merkitsevyys. 2023 ja 2024 pysyvien koealojen välillä kuolleisuus pysyi melkein samana, vaikka pieni kuolleisuuden kasvu on nähtävissä. Tämä kehitys selittynee parhaiten normaalilla häiriödynamiikalla, missä bioottiset ja abioottiset tuhot aiheuttavat sinne tänne kuolleita puita. Näin lyhyen aikavälin tutkimuksessa ei ole mahdollista korvaavien puiden ehtiä taimesta sen kokoisiksi, että ne olisivat rekisteröityneet mittauksissa.

Kiinnostavimpiin vertailuihin kuului 2023 pysyvien koealojen ja 2024 lisäkoealojen välinen vertailu, sillä siinä käytännön tasolla verrattiin vanhaa ja uutta algoritmia toisiinsa. Kummassakin tapauksessa koealat valittiin sovelluksen tuottaman häiriökartan perusteella, jolloin ennakkotieto maastossa ei päässyt vaikuttamaan asiaan. Koska algoritmi ehti muuttua merkittävästi 2023 pysyvien koealojen mittausten jälkeen ennen 2024 lisäkoealojen mittauksia, kuvasi tämä vertailu varsin hyvin algoritmien välisiä tarkkuuseroja. Tutkimalla karttakuvia oli havaittavissa erittäin selkeä ero siinä, kuinka suurelle hilajoukolle karttasovellus näytti tuhon. Vuoden 2023 algoritmi näytti vakavasti vaurioituneita hilaruutuja huomattavan paljon enemmän kuin vuoden 2024 algoritmi. Toisin sanoen sovelluksen kehittäjät olivat selkeästi säätäneet laskentaa varovaisemmaksi, jotta vääriä positiivisia tuloksia ei syntyisi niin paljoa. 2023 pysyvien koealojen ja 2024 lisäkoealojen välinen kuolleisuuden arviointi ei ylittänyt tilastollisesti merkitsevän rajaa, sillä p-arvo jäi 0,161:een. Kuitenkin ero 18 % ja 25 % välillä voitiin tulkita selkeäksi kasvuksi tarkkuudessa siitä huolimatta, että p-arvo ei sitä rekisteröinyt. Toisin sanoen, algoritmin muuttuessa varovaisemmaksi, on positiivisten eli tuhoa ilmentävien hilaruutujen todennäköisyys sisältää kuolleita puita korkeampi kuin vuoden 2023 algoritmin kanssa.

Kääntöpuolena väärin positiivisten tulkintojen välttämiseksi on kuitenkin se, että väärin negatiivisten tulkintojen määrä käytännössä väkisin kasvaa. Tämä tarkoittaa sitä,

että uuden algoritmin tulkitessa varovaisemmin hilaruudun vakavasti vaurioituneeksi kasvaa todennäköisyys sille, että lievemmin vaurioituneet eivät rekisteröidy ollenkaan kartalla. Tällaiseen tulkintaan ei ole olemassa oikeaa ja väärää asetusta, vaan se on vain säädettävä sille tasolle mikä hyödyttää tiedon käyttäjää eniten. Ainoastaan siirtymällä yksin puin tulkintaan voitaisiin kyseisestä ongelmasta päästä todella eroon, mutta vaihtokauppana saataisiin ongelmaksi erittäin raskas laskenta ja suuremmat vaatimukset lähtötiedoille. Ennen kuin Sentinel-2:n korvaa uusi tarkempi satelliitti, jonka tiedot säilyvät avoimena, ei muutokselle ole edes teoreettista mahdollisuutta.

Koalaa lähellä olevan aukean alan vaikutus mitattuihin tuloksiin yllätti voimakkuudellaan, sillä keskiarvo oli yli kaksinkertainen siihen nähden mitä kauempana avoimesta sijaitsevien keskiarvo oli. Tämän kokoinen muutos saikin niin pienen p-arvon, että se jouduttiin ilmaisemaan $p < 0,001$ mikä on yleinen tapa kirjata 0,001 pienempiä p-arvoja. Olettavaa oli löytää selkeää korrelaatiota, mutta löydetty korrelaatio oli odotettua vahvempaa, tosin otoskoko oli pieni sillä luokalla, jotka olivat 0-20 m etäisyydellä avoimista alueista (n=21). Pieni otoskoko lisää epävarmuutta, mikä näkyy myös hajontaluvuissa.

Hongcheng ym. 2003 tutkivat eri puulajien tuulenkestävyyttä avohakkuualojen läheisyydessä ja havaitsivat, että tuulituhot lisääntyvät uusien avohakkuualojen reunoissa ja etenkin kuusella. Kuusi pintajuurisena puuna kärsii erityisen herkästi siitä, että avohakkuun myötä sellaiset puut, jotka ovat tottuneet kasvamaan metsän keskellä, ovatkin yhtäkkiä reunapuuta avohakkuualan vieressä. Tuulen nopeudet, mitä nämä puut joutuvat kokemaan reunalla, ovat selkeästi suurempia kuin mitä ne olisivat olleet ilman avohakkuualan vaikutusta.

Pulgarin Diaz ym. 2024 tutkivat myös yhtenä osa-alueena tutkimustaan sitä, miten lähellä oleva avohakkuuala vaikuttaa kirjanpainajatuhojen leviämiseen. He havaitsivat avohakkuualojen korreloivan hyvin vahvasti uusien kirjanpainajaesiintymien kanssa, sillä avohakkuu muodostaa reuna-alueelle suotuisat olosuhteet kirjanpainajalle. He totesivat Hongchengin ym. 2023 tavoin, että tuulituhot lisääntyvät reuna-alueella, mutta toivat myös esille sen, että auringon valo luo reuna-alueelle myös paahteisemman, kuivuudelle alttiimman vyöhykkeen. Näin kirjanpainajakanta pääsee lisääntymään reunavaikutusalueella ennen kuin populaatio lähtee leviämään syvemmälle metsään. (Pulgarin Diaz ym. 2024, 14.)

Ruotsissa on tehty vastaavaa tutkimusta kirjanpainajakannan leviämisestä ja avohakkuu-
alan on todettu lisäävän Ruotsissa kirjanpainajatuhoja 200-500 m etäisyydellä ja jopa si-
täkin kauemmas. Kuitenkin erotuksena Suomen malliin on se, että Ruotsissa laki ei vel-
voita keräämään tietyn määrärajan ylittävää osaa tuulenskaadoista kuten Suomessa lakiin
kirjoitettu vaatimus on. Siten reunavaikutuksen vioittamat puut toimivat etenevän tuhon
ensimmäisenä vaiheena. (Pulgarin Diaz ym. 2024, 14.)

Harventamisen lisäksi tutkittiin maaperän vaikutusta kuolleisuuteen ja siinä ei havaittu
tilastollisesti merkitseviä tuloksia odotettuun suuntaan. Itse asiassa turvemaitten kuollei-
suuden keskiarvo oli hieman pienempi kuin kivennäismaitten. Ennako-odotukset olivat
sen kannalla, että turvemaiilla erityisesti kaatuneita puita olisi kivennäismaita enemmän.
Turvemaan osalta hajonta oli kyllä suurempaa, mutta toisaalta otoskoko oli selkeästi pie-
nempi joten osa hajonnasta selittyy suoraan pienemmällä otoskoolla.

Harvennusten suhteen odotukset olivat jakautuneet ja omalla tavallaan kahtiajakoisuus
jäi datan tulkinnankin jälkeen voimaan, sillä mitään merkittävää eroa harvennetuilla ja
harventamattomilla koealoilla ei havaittu. Harventaminen yhtäältä lisää riskiä mm. lumi-
tuhoille ja muille tuhoille, mutta toisaalta harvennettaessa poistetaan metsästä nimen-
omaan vahingoittuneita puita, jolloin vaikutukset näyttäisivät lyhyellä aikavälillä kumoa-
van toisensa. Lyhyt aikaväli nähdään tässä 2018-2024 väliseksi ajaksi, sillä harvenne-
tuissa aloissa oli näkyvissä metsänkäyttöilmoituksia vain vuodesta 2018 eteenpäin.

Riskitekijöistä tehty korrelaatioanalyysi osoitti voimakkaan korrelaation kirjanpainajaha-
vainnon, myrskyssä kaatuneitten puitten ja muihin tuhoihin kategorisoitujen puitten
osalta. Todennäköisesti muuksi kategorisoitu tuho monesti oli todellisuudessa kirjanpai-
najajan aiheuttama puun kuivuminen, mutta jos ei kuorta saanut raotettua niin, että syömä-
kuvioista saataisiin varmuus, ei tuhoa myöskään voinut arvailun perusteella kategorisoida.
Myös pihkavuoto oli monesti hyvin suurella todennäköisyydellä alkava tai kesken jäänyt
kaarnakuoriaisten hyökkäys, mutta pelkän pihkavuodon perusteella ei lähdetty tulkitse-
maan mahdollista pihkavuodon aiheuttajaa.

Muitten riskirekijöiden osalta ei koettu vastaavanlaista virhekategorioiden vaaraa, vaikka pienimuotoisesti esimerkiksi kuusentähtikirjaajan tuhoksi voisi teoreettisesti joutua myös kuusi, joka muuten on elävä, mutta jolla on kuivuuden tappama latva. Kuitenkin todennäköisyys virhetulkinnoille muissa kategorioissa koettiin niin pieneksi, ettei sen asian tarkempaan tutkimiseen nähty aiheutta puuttua.

Jos tätä tutkimusta verrataan muihin kuusen tuhoja tutkineisiin tutkimuksiin, kuten esimerkiksi Abdullahin ym. 2018 tekemään tutkimukseen, jossa 67 % kaarnakuoriaisten hyökkäyksen kohteeksi kaukokartoituksella tunnistetuista koealoista todettiin olevan oikeasti hyökkäyksen kohteina ilmakuvioiden perusteella, tämän tutkimuksen lukemat vaikuttavat huomattavasti pienemmiltä. On kuitenkin huomattava, että Abdullahin ym. 2018 tutkimusasetelmassa he laskivat ensin ne koealat, joissa tuhon oletettiin olevan merkittävä ja siitä aineistosta valikoitiin tutkittavaksi vain sellaiset 30 m x 30 m hilaruudut, joitten ympärillä joka suunnassa oli myös hilaruutu, joka kaukokartoituksen perusteella oli hyökkäyksen kohteena. Abdullahin ym. 2018 koeasetelma olisi jättänyt tutkimatta merkittävän osan tämän tutkimuksen aineistosta varsinkin uudemman algoritmin mukaan laskettuna. Siten tämän tutkimuksen koeasetelmalta olisi epärealistista odottaa vastaavia 67 % osu-matarkkuuksia.

Tutkimuskysymykseen liittyen voidaan todeta, että sovelluksen tuottama tieto ohjaa sovelluksen käyttäjää riskialueille hyvin, mutta että alueilla on ajoittain suurta vaihtelua sen suhteen, onko riski sellainen, mistä puu voi toipua. Etenkin 2023 lisäkoealat osoittavat, että jo vuoden 2023 osalta laskenta ohjasi maastossa sellaisiin paikkoihin, minkä läheisyydessä oli tilastollisesti merkitsevästi enemmän kuolleita puita kuin 2023 pysyvillä koealoilla, joka sekään ei edusta tervettä normaalia metsää vaan vuonna 2023 riskialueeksi leimaantunutta kohdetta.

Koska sovelluksen tuottama karttataso voidaan pitää maastokartan päälle projisoituna, on sitä äärimmäisen helppo käyttää maastokäynnillä. Siten sovelluksen tuottama tieto on maastokäynnin aikana käytävien alueiden valinnan suhteen olennaista sen varmistamiseksi, onko kartalla näkyvä riski realisoitunut metsässä vai ei. Sen lisäksi vuosien välillä oli havaittavissa algoritmin tarkentumista, joten käyttökelpoisuus on tutkimusaikana parantunut.

Sen sijaan hyvin vähän oli havaittavissa sitä, että sovellus olisi havainnut vuonna 2023 sellaisen tuhon, mikä realisoitui vasta vuonna 2024 näkyväksi. Vain kohteella 24 koealan 1 osalta kuolleisuus vuosien välillä oli silmiinpistävän suurta. Vuonna 2023 eläviä puita oli 6 ja kuolleita 1 kun taas vuonna 2024 asetelma oli kääntynyt pääläelleen, eläviä oli 1 ja kuolleita 6. Riskitekijöistä 5 jäi tunnistamatta, mikä voi hyvinkin viitata kirjanpaina- tuhon alkuvaiheisiin. Kuitenkin se, että yhdellä koealalla päästiin tämänkaltaiseen päätelmään ei ole tilastollisesti mitenkään merkitsevä, kun koealoja oli yhteensä 74 joilta tätä päästiin vertailemaan (2023 ja 2024 pysyvät koealat).

Tarkasteluun siitä, näkeekö sovellus alkavia tuhoja ennalta, vaikutti oletettavasti hyvin paljon se, että lähes kaikki vuoden 2023 pysyvien koealojen ja lisäkoalojen osalta uuden algoritmin mukainen laskenta ei olisi havainnut kohonnutta riskitasoa. Jos algoritmin muutoksen jälkeen merkittävästi suurempi osa koealoista olisi osunut myös uuden algoritmin vakavan riskin alueiksi, olisi tarkastelu ollut merkittävämpää sen kannalta, että pystyykö sovellus havaitsemaan tuhoja ennalta. Vuoden 2023 syksyllä mitatuista 120 koealasta vain 9 olivat vuoden 2024 laskennan mukaisesti edes lievän riskin alueella. Merkittävien tulosten saavuttamiseksi olisi syytä olla vähintään sadan havainnon joukko sellaisia koealoja, jotka ovat molempina vuosina (tai kaikkina vuosina pidemmissä tutkimuksissa) vähintään lievän riskin alueilla mutta mielellään korkean riskin alueilla. (Vilkkä 2007, 27, 57.)

Käytännössä tämä tarkoittaa sitä, että ennen kuin algoritmin laskenta vakiintuu siinä määrin, että suunnilleen samat hilaruudut näkyvät vertailtavissa vuosissa korkean riskin alueina, ei tätä pystytä tutkimaan kunnolla. Kuitenkin on oletettavaa, että lähivuosina laskenta vakiintuu merkittävästi ja se mahdollistaa tämän asian tarkastelun esimerkiksi jatkotutkimusmahdollisuutena tälle tutkimukselle.

Huomion arvoista kuitenkin tuhojen ennustamiskyvyn suhteen on se, että terveestä metsästä mitattu perustaso kuusen eri riskitekijöitten määrästä oli huomattavasti pienempi kuin missään varsinaisista koealoista. Sovelluksen tuottaman riskikartan perusteella mitattujen koealojen riskitekijämäärät olivat viisinkertaisesta yli kymmenkertaiseen, mikä indikoi vahvasti sen suuntaan, että sovellus on todellakin havainnut poikkeavia nestevirtauksia näissä puissa.

6.2 Vaikutukset Metsä Groupin kannalta

Metsä Groupin kannalta on olennaista olla ensimmäisten joukossa tuottamassa asiakkaidensa kannalta räätälöityä tietoa ja siihen tutkittava sovellus pyrkiikin. Ei ole asiakkaan kannalta välttämättä olennaista käyttääkö asiakas sovellusta itse vai hyötyykö hän siitä välillisesti sitä kautta, että Metsä Groupin metsäasiantuntija hyödyntää sovelluksen tuottamaa tietoa metsäkäyntien aikana.

Tutkimusta mutkisti vuosien välillä tapahtunut algoritmin päivitys, mutta jatkon kannalta algoritmin kehittäminen on erittäin olennaista sen käyttökelpoisuuden kehittämisen suhteen. Toisin sanoen, algoritmi mitä päivitetään, saavuttaa todennäköisemmin hyvän tason kuin algoritmi, mitä ei päivitetä. Päivityksen osalta tutkimuksessa havaittiinkin muutosta tarkkuudessa ja tämä on tärkeä viesti myös ohjelmiston kehittäjille siitä, että kehityksen suunta on ollut oikea. Voidaankin nähdä, että mahdollisesti suurin hyöty Metsä Groupille tästä tutkimuksesta onkin se tieto, että algoritmin eteen tehty kehitystyö on johtanut parempaan tarkkuuteen. Tämä tieto tuli mahdolliseksi vain siitä syystä, että koeasetelmaan tuli koeasetelman ulkopuolinen muutos, mutta onnekas yhteensattuma saatiin onneksi kunnolla vertailtua siksi, että vuodelta 2023 tallennettiin vanhan algoritmin mukaiset laskekartat huolellisesti jokaiselta koealalta.

Metsäasiantuntijoiden kanssa käytyjen tutkimusaiheeseen suoranaisesti liittymättömien keskusteluitten perusteella sovelluksen koettu hyödyllisyys on vaihdellut melko paljon, mutta tarkkuuden parantuessa voidaan olettaa, että metsäasiantuntijoiden mielipiteet kääntyvät aina vain positiivisemmiksi. Suurin osa metsäasiantuntijoista kokee tällä hetkellä niin, että sovellus tuottaa arvokasta tietoa, mutta että siihen ei voi missään nimessä sokeasti luottaa. Tutkimustulokset vahvistavat melko hyvin tämän kaltaisen mielipiteen, sillä koealojen välillä oli ajoittain huomattavaa eroa. Vastaan tuli täysin tuhoutuneita koealoja mutta myös sellaisia, missä ei näkynyt merkkiäkään tuhosta. Näin ollen sovelluksen suurin hyöty on ehdottomasti siinä, kun sen tuottamaa tietoa käsitellään kuin riskianalyysinä. Kohonneen riskin alueilla ei välttämättä ole tuhoa, mutta maastokäynnillä maastoaskeleet voidaan hyvin perustellusti suunnata riskikartan hälyttävimpien hilaruutujen kautta, jotta saadaan varmuus siitä, onko alueella todellinen pysyvä tuho, hetkellinen häiriö vai väärä hälytys.

Riskikartoituksen kannalta sovellus on erittäin helppokäyttöinen, sillä se voi olla aktiivisena maastokartan päälle tuotuna kerroksena niin, että maastokartta säilyy hyvin luettavana siitä huolimatta, että tuhoriskin kohteet näytetään samanaikaisesti. Sovelluksen osoittamalla korkean riskin alueilla oli kaikissa mittauksissa huomattavasti enemmän kuolleita puita kuin vertailtavassa terveessä metsässä. Virhetulkintojen mahdollisuus on aina läsnä kaukokartoitukseen perustuvassa tulkinnassa, joten ilman maastoaskeleita ei sovelluksen tuottaman tiedon perusteella ole syytä vielä hätiköityihin johtopäätöksiin.

Kuitenkin tutkittavalle sovellukselle on selkeästi tarvetta nyky maailmassa, kun yleisesti ottaen tiedostetaan ilmastonmuutoksen tuomat riskit etenkin kaarnakuoriaisten leviämisen kannalta. Näin ollen mitä nopeammin saadaan tuhoa hillitsevät toimenpiteet aloitettua, sitä tehokkaammin kaarnakuoriaisten leviämistä saadaan hillittyä.

6.3 Tutkimuksen luotettavuus ja eettisyys

Tämän tutkimuksen luotettavuuden tarkastelu kohdentui siinä käytetyn materiaalin lähteisiin, maastossa kerätyn tiedon hankintatapaan, käytettyihin analysointimalleihin, tulkintaan, eettisiin näkökulmiin sekä tutkimuksen relevanttiuteen.

Kvantitatiivinen tutkimustapa on sellainen tutkimustapa, missä tietoa esitetään numeraalisesti. Kvantitatiivisessa tutkimuksessa on tärkeää pysyä tiedon kannalta objektiivisena, eli toisin sanoen pyrkiä minimoimaan tiedon käyttäjän vaikutus tiedon laatuun. Tämä onnistuu silloin, kun itse tutkimusprosessi on puolueeton ja silloin, kun kyseisen tutkimuksen tulokset esitetään puolueettomasti. (Vilka 2007, 14-16.)

Tämän työn kannalta työn puolueettomana pysymisen kannalta on olennaista, että tehty tutkimus ei liittynyt työtehtäviini Metsä Groupilla eikä Metsä Group yrittänyt millään tavalla vaikuttaa esitettyihin tuloksiin tai johtopäätöksiin. Tiedon objektiivisuuden kannalta tietoa esiteltäessä kerrotaan tiedon lähde ja käytetyt analysointimenetelmät. Siten tutkimuksen toistettavuus on säilynyt hyvällä tasolla. Kuitenkin on otettava huomioon, että tutkimusta tehneen omat mielipiteet ja näkemykset aina vaikuttavat jonkin verran

tutkimuksen suuntaan ja tarkasteltaviin määreisiin, vaikka itse numeraalinen osuus olisi-kin täysin objektiivinen.

Aineiston hankinnan suhteen tämä tutkimus tehtiin systemaattisen havainnoinnin menetelmin. Siinä ennalta vakioidulla tavalla tallennetaan tietoa tutkittavasta kohteesta ja kirjataan ne ylös. Tietoa kerättiin koealoilta, eli otannan menetelmin. Siten otantaan vaikuttaa aina esimerkiksi käytetty otoskoko, jota taas voi rajoittaa resurssien rajallisuus. Kun tarkastelu pysyy kokonaistasolla, on noin sadan otoksen määrä riittävä. Kuitenkin mitä suurempi otoskoko, sitä paremmin tieto voidaan siirtää kuvaamaan perusjoukkoa. (Vilka 2007, 27, 51-58.)

Tämän tutkimuksen systemaattisen havainnoinnin menetelmiä oli maastokartoituksen havainnot, jotka ennakkoon strukturoidulla tavalla kerättiin kaikilta koealoilta ennalta määrättyllä tavalla yhtenevästi. Omin aistein havainnointi on kuitenkin aina jonkin verran altis mittaustavasta johtuville mittausvirheille. Mittaukset kuitenkin tehtiin suunnilleen samankaltaisissa sääolosuhteissa, joten tieto on varsin samankaltaisella tavalla kerätty eri vuosien välillä. Käytetyt analysointimallit valikoituivat aina sen mukaan, mikä malli tuotti kyseiselle aineistolle mahdollisimman todennettavaa tietoa. Esimerkiksi analysointimalleja, jotka tuottavat p-arvon tutkittavalle määreelle, käytettiin mieluummin, kuin sellaisia, jotka tuottavat vain korrelaatioanalyseja.

Tutkimuksen aineistona käytetyn ja systemaattisen havainnoinnin menetelmin kerätyn tiedon analysointiin ollaan tarvittu myös runsaasti muita lähteitä ja tutkimuksia rakentamaan sellaista viitekehystä, missä tutkimus asettuu osaksi suurempaa kokonaisuutta. Muitten lähteiden käytössä on kuitenkin pystyttävä säilyttämään lähdekriittisyys. Olen- naista lähdekritiikin kannalta on, että tutkija on pohtinut käyttämänsä lähteen luotetta- vuutta ja soveltuvuutta ennen lähteen käyttöä. Varsinkin internetistä haetun aineiston kanssa on syytä varmistua tiedon luotettavuudesta. Toisaalta kirjojen kanssa tieto voi olla päivittymätöntä, joten lähteestä riippuen on erilaisia riskejä. (Vilka 2007, 32-34.)

Tässä tutkimuksessa käytettiin mahdollisimman paljon tieteellisen tutkimuksen tasoista lähdemateriaalia. Lisäksi käytettiin runsaasti oppikirjoja ja oppaita, jotka on julkaissut luotettava lähde. Muutamassa poikkeavassa tilanteessa käytettiin arkisempia verkkoläh- teitä kuten Wikipediaa, sillä vaikka niitten osalta tieto on yleensä hyvällä tasolla, on sen

varmistaminen monesti vaikeaa. Siten edellisen kaltaisia lähteitä käytettiin mahdollisimman vähän ja sellaisissa tilanteissa, kun soveltuvampaa tieteellistä artikkelia ei ollut aiheesta saatavilla. Tekoälyyn perustuvia sovelluksia ei käytetty missään tutkimuksen vaiheessa tekstin tuottamiseen tai muokkaamiseen, eikä mikään tutkimuksen osa perustu tekoälyn tuottamaan tekstiin.

Määrällistä tutkimusta tehdessä voi myös tulla vastaan tiedon anonymisoinnin tarve eli se, että tietoa ei voi johtaa niihin henkilöihin tai paikkoihin mistä tieto on haettu (Vilka 2007, 95.). Tämän tutkimuksen osalta on päädytty anonymisoimaan koealojen sijaintiksi, ettei yksittäisten metsänomistajien omaisuudesta tulisi esitettyä omaisuuden arvoa alentavaa tietoa. Tämän lisäksi maastossa koealojen yhteyteen jätettiin yhteystiedot tutkimuksen tekijälle ja selite koejärjestelystä. Kuitenkin yhden kohteen suhteen metsänomistaja pyysi purkamaan koealajärjestelyt hänen mailtaan ja kaksi kohdetta menivät hakkuuseen ennen 2024 mittauksia.

Tutkimusta tehdessä on pyritty välttämään määrällisten tutkimusten suurimpia kompastuskiviä. Näistä ensimmäinen on tutkimusongelman hämärtyminen tutkimusta tehdessä, mitä on pyritty estämään tarkastelemalla sitä, vastaako tutkimustulokset tutkimuskysymykseen. Toinen kompastuskivi on se, että tutkija ei tunne riittävästi tutkimuskohdettaan. Tähän on vastattu perehtymällä eri tutkimusmenetelmiin ennakkoon ja muuttamalla aineiston keräystapaa siinä vaiheessa, kun tutkimusta tehdessä huomattiin aineistoon tulleen ohjelmistollinen suuri päivitys, joka muokkasi koeasetelmaa tutkijasta riippumatta. Kolmas kompastuskivi on se, että tietoa ei ole ylipäättään saatu tarpeeksi. Tämän kaltaisen tutkimuksen osalta on kuitenkin epärealistista resurssien puitteissa kasvattaa koealajärjestelyitä suhteettomiin mittakaavoihin, joten tarkan harkinnan perusteella päädyttiin nykyiseen järjestelyyn. Viimeinen kompastuskivi on yksinkertaisesti se, ettei tutkija ole riittävän huolellinen. Tätä kohtaa on pyritty pitämään jatkuvasti huomion keskipisteessä, sillä suurten data-aineistojen kanssa on helppoa tuottaa myös vahingossa virheitä aineistoon. Sen tähden aineistoa on tarkasteltu useampaan kertaan niin, että mahdollisia virheitä ollaan saatu karsittua aineistosta. (Vilka 2007, 100-101)

Tutkimuksen reliabiliteettiä eli ei-sattumanvaraisuutta tarkastellessa tutkimuksen odotetaan olevan toistettavissa merkittävästi osiltaan samankaltaisin tuloksin. Tämän tutkimuksen kannalta koettiin, että mittauksissa ja analysoinneissa pyrittiin mahdollisimman

hyvään toistettavuuteen ja omalta osaltaan 2023 ja 2024 pysyvien koealojen hyvinkin toisiaan vastaavat tulokset tukevat ajatusta siitä, että tulokset ovat hyvin toistettavissa. Myös validius on olennaista tutkimuksessa, eli toisin sanoen se, että tutkimus todellakin tutkii sitä mitä sen on tarkoituskin tutkia. Tämän tutkimuksen tarkoitus oli tehdä päätelmiä tutkittavasta sovelluksesta ja sen tarkkuudesta, joten tutkimusasetelmalla on pyritty saavuttamaan tarkkuutta mittaavaa tietoa. Vain riittävän tarkasti toimiva sovellus voi todella olla hyödyllinen. Yhdessä reliabiliteettius ja validius muodostavat tutkimuksen kokonaisluotettavuuden, josta oikeastaan vasta uusintamittauksella voitaisiin varmistua. (Vilka 2007, 149-152.)

Lopulta on tarkasteltava vielä yhtä osa-aluetta eli relevanttiutta. Tutkimuksen tilaajan näkemys on ollut työn aloituksesta sen päättymiseen asti sellainen, että tutkimukselle on nykymaailmassa tarvetta. Ilmastonmuutoksen myötä lisääntyneet tuhot tarvitsevat vastapainokseen lisääntyntä tietoisuutta siitä, missä oikeasti on alkavia tuhopesäkkeitä niin, että niihin voidaan kohdentaa asianmukaisia toimenpiteitä. Siten tutkimus on relevantti niin tilaajan kuin myös tilaajan asiakkaiden kannalta.

6.4 Tutkimuksen jatkokehitysmahdollisuudet

Tutkimusta voidaan myöhemmin jatkaa mm. tekemällä metsäasiantuntijahaastatteluita ja selvittämällä sitä kautta, kuinka sovelluksen käyttäminen on koettu heidän parissaan. Tutkittavia kysymyksiä voisi olla esimerkiksi se, että onko metsäasiantuntijoiden suhtautuminen sovelluksen käyttämiseen positiivista vai negatiivista sekä se, että onko tämän tutkimuksen ja sovelluksen koetun hyödyllisyyden välillä ristiriitaa.

Toinen vaihtoehto jatkotutkimukselle olisi kääntää koeasetelma tietyllä tapaa pääläelleen, jolloin voitaisiin etsiä maastosta pahoin vahingoittuneita alueita ja tarkastella, että vastaako sovelluksen karttanäkymä maastohavaintoa. Tämän tutkimuksen lähtökohta taas on ollut kartan antaman tiedon vertaaminen maastohavaintoihin, jolloin nämä kaksi tiedonkeruutapaa voisivat tukea toisiaan hyvin. Periaatteessa 2023 lisäkoealojen keräystapa oli jossain määrin tämän kaltainen, mutta ei aivan niin pitkälle viety, sillä 2023 lisäkoealat kerättiin 2023 pysyvien koealojen läheisyydestä eikä niistä riippumatta.

LÄHTEET

Abdullah, H. 2019. Remote sensing of European spruce (*Ips typographus*, L) bark beetle green attack. University of Twente. Väitöskirja. Viitattu 22.10.2024. https://www.researchgate.net/publication/334285852_Remote_sensing_of_European_spruce_Ips_tytopographus_L_bark_beetle_green_attack

Abdullah, H., Skidmore, A., Darvishzadeh, R. & Heurich M. 2018. Sentinel-2 accurately maps green-attack stage of European spruce bark beetle (*Ips typographus*, L.) compared with Landsat-8. *Remote sensing in ecology and conservation* 2019-03, vol. 5(1), s. 87-106.

Accuracy Metrics. 2014. Humboldt State University. Verkkosivu. Viitattu 6.7.2024. https://gsp.humboldt.edu/olm/Courses/GSP_216/lessons/accuracy/metrics.html

Ahmed, S., Hilmers, T., Uhl, E., Jacobs, M. Bohnhorst, L., Kolisnyk, B., del Río, M. & Pretzsch, H. 2024. Neighborhood competition modulates the link between crown structure and tree ring variability in monospecific and mixed forest stands. *Forest Ecology and Management* 2024 vol 560, artikkeli 121839. Viitattu 20.6.2024. <https://doi.org/10.1016/j.foreco.2024.121839>

Boxplot. 2024. DATAtab: Online Statistics Calculator. Verkkosivu. Viitattu 19.10.2024. <https://datatab.net/tutorial/box-plot>

Gregow, H., Peltola, H., Laapas, M. Saku, S. & Venäläinen, A. 2011. Combined occurrence of wind, snow loading and soil frost with implications for risks to forestry in Finland under the current and changing climatic conditions. *Silva Fennica* vol. 45, nro. 1, artikkeli 30. Viitattu 20.6.2024. <https://doi.org/10.14214/sf.30>

Hedgren, P. 2003. The bark beetle *Pityogenes chalcographus* (L.) (Scolytidae) in living trees: reproductive success, tree mortality and interaction with *Ips typographus*. *Journal of applied entomology* 2004-04 vol 128, s. 161-166.

Hila-aineisto. 2023. Metsäkeskus. Verkkosivu. Viitattu 6.7.2024. <https://www.metsakeskus.fi/sites/default/files/document/tietotuotekuvaus-hila-aineisto.pdf>

Holopainen, M. 2019. Metsien kaukokartoitus – digitalisaatiota, täsmämetsätaloutta ja 4D-geoinfotatiikkaa. Metsätieteen aikakauskirja 2019 artikkeli 10214. <https://doi.org/10.14214/ma.10214>

Holopainen, M. & Pulkkinen, P. 2013. Tilastolliset menetelmät. 5.-8. painos. Helsinki: Sanoma Pro Oy.

Holopainen, M., Tokola, T., Vastaranta, M., Heikkilä, J., Huitu, H., Laamanen, R. & Alho, P. 2015. Geoinfotatiikka luonnonvarojen hallinnassa. Helsingin yliopiston metsätieteiden laitoksen julkaisu 7: 1–152. <http://hdl.handle.net/10138/166765>

Hongcheng, Z., Peltola, H., Talkkari, A., Venäläinen, A., Strandman, H., Kellomäki, S. & Wang, K. 2003. Forest Ecology and Management 2004-12, vol. 203 (1), s. 77-88.

Hyvönen, P. 2002. Kuvioittaisten puustotunnusten ja toimenpide-ehdotusten estimointi k-lähimmän naapurin menetelmällä Landsat TM -satelliittikuvan, vanhan inventointitiedon ja kuviotason tukiaineiston avulla. Metsätieteen aikakauskirja 2002(3), s. 363-379. <https://doi.org/10.14214/ma.6177>

Introducing Sentinel-2. n.d. European Space Agency (ESA). Verkkosivu. Viitattu 3.7.2024. https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2/Introducing_Sentinel-2

Jamali, S., Olsson, P., Ghorbanian, A. & Müller, M. 2023. Examining the potential for early detection of spruce bark beetle attacks using multi-temporal Sentinel-2 and harvester data. ISPRS Journal of Photogrammetry and Remote Sensing 205 (2023) s. 352-366. <https://doi.org/10.1016/j.isprsjprs.2023.10.013>

Karjalainen, L. 2010. Tilastotieteen perusteet. Keuruu: Otavan Kirjapaino Oy.

Kirjanpainaja kuusikossa: ennakointi, hallinta ja torjunta. n.d. Metsäkeskus. Verkkosivu. Viitattu: 12.5.2024. <https://www.metsakeskus.fi/sites/default/files/document/kirjanpainajatuhon-torjuntaopas.pdf>

Kohler, M., Sohn, J., Nägele, G. & Bauhus, J. 2010. Can drought tolerance of Norway spruce (*Picea abies* (L.) Karst.) be increased through thinning?. *European journal of forest research* 2010-11 vol. 129 (6), s. 1109-1118.

Kulha, N. & Honkaniemi, J. 2022. Metsätuhoja vai luontaisia häiriöitä – miten käsitellä häiriödynamiikkaa suomen kielellä? *Metsätieteen aikakauskirja* 2022, artikkeli 10723. Viitattu 20.6.2024. <https://doi.org/10.14214/ma.10723>

Kuusentyvilaho. n.d. Luonnonvarakeskus. Verkkosivu. Viitattu 20.6.2024. <https://www.luke.fi/fi/luonnonvaratieto/tiedetta-ja-tietoa/metsatuhot/metsatuhonaiheuttajat/taudit/kuusentyvilaho>

Kuusi. 2024. LuontoPortti. Verkkosivu. Viitattu 6.7.2024. <https://luontoportti.com/t/920/kuusi>

Laki metsätuhojen torjunnasta. 20.12.2013/1087. Verkkosivu. Viitattu 19.6.2024. <https://www.finlex.fi/fi/laki/alkup/2013/20131087>

Luonnonvaratieto. n.d. Luonnonvarakeskus. Verkkosivu. Viitattu 3.7.2024. <https://luonnonvaratieto.luke.fi/kartat?panel=metsatuhot>

Luotamo, M. 2023. *Advances in Region-Based Multisource Machine Learning for Remote Sensing*. Tietojenkäsittelytieteiden osasto. Helsingin yliopisto. Helsingin yliopiston avoin julkaisuarkisto. Väitöskirja. Viitattu 27.6.2024. <https://helda.helsinki.fi/bitstreams/5a7c7f43-89f8-43bd-8cda-4b5a1000babe/download>

Maanmittauslaitos. n.d. Tuotannon tilannekartta. Verkkosivu. Viitattu 26.6.2024. <https://tilannekartta.maanmittauslaitos.fi/laserkeilaus>

Martínez-García, E., Nilsson, M., Laudon, H., Lundmark, T., Fransson, J., Wallerman, J. & Peichl, M. 2024. Drought response of the boreal forest carbon sink is driven by understorey–tree composition. *Nature geoscience* 2024-03, vol. 17 (3), s. 197-204.

Metsien kestävä hoito ja käyttö. n.d.. Metsänhoidon suositukset. Verkkosivu. Viitattu 26.3.2024. <https://metsanhoidonsuosituksset.fi/fi/metsien-kestava-hoito-ja-kaytto>

Metsä Group. 2022. Metsä Group ja CollectiveCrunch kehittävät tekoälysovelluksen myrsky- ja hyönteistuhojen tunnistamiseen. Verkkosivu. Viitattu 26.3.2024. <https://www.metsagroup.com/fi/puunhankinta/uutiset-ja-julkaisut/tiedotteet/2022/metsa-group-ja-collectivecrunch-kehittavat-tekoalysovelluksen-myrsky--ja-hyonteistuhojen-tunnistamiseen/>

Metsä Group. n.d. Metsä Groupin tekoälysovellus hyönteistuhojen tunnistamiseen. Verkkosivulle upotettu video. Viitattu 7.7.2024. <https://www.metsagroup.com/fi/puunhankinta/kestava-kehitys/data-ja-teknologia/metsa-groupin-ja-collectivecrunchin-hyonteistuhotekoalysovellus/>

Metsäkeskus 2022. Hyönteistuhot alkavat näkyä metsissä – karttapalvelusta apua havainnointiin. Verkkosivu. Viitattu 26.3.2024. <https://www.metsakeskus.fi/fi/ajankohittaista/hyonteistuhot-alkavat-nyt-nakya-metsissa-karttapahyonteistuhotlvelusta-apua-havainnointiin-1>

Metsäkeskus. 2024. Kansallinen kaukokartoitus ja metsien digitaalinen kaksonen (MetsäKaksonen). Verkkosivu. Viitattu 26.6.2024. <https://www.metsakeskus.fi/fi/hankkeet/metsakaksonen>

Metsävaratiedon laatuseloste. 2023. Metsäkeskus. Verkkosivu. Viitattu 25.6.2024. <https://www.metsakeskus.fi/sites/default/files/document/metsavaratiedon-laatuseloste.pdf>

Migaz-Mazur, R., Kycko, M., Zwijacz-Kozica, T. & Zagajewski, B. 2021. Assessment of Sentinel-2 Images, Support Vector Machines and Change Detection Algorithms for

Bark Beetle Outbreaks Mapping in the Tatra Mountains. *Remote sensing* 2021:13, artikkeli 3314. https://www.researchgate.net/publication/354048155_Assessment_of_Sentinel-2_Images_Support_Vector_Machines_and_Change_Detection_Algorithms_for_Bark_Beetle_Outbreaks_Mapping_in_the_Tatra_Mountains

Mäyrä, J., Keski-Saari, S., Kivinen, S., Tanhuanpää, T., Hurskainen, P., Kullberg, P., Poikolainen, L., Viinikka, A., Tuominen, S., Kumpula, T. & Vihervaara, P. Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks. *Remote Sensing of Environment* 256 (2021), artikkeli 112322. <https://doi.org/10.1016/j.rse.2021.112322>

Netherer, S., Ehn, M., Blackwell, E. & Kirisits, T. 2016. Defence reactions of mature Norway spruce (*Picea abies*) before and after inoculation of the blue-stain fungus *Endonodiophora polonica* in a drought stress experiment. *Central European forestry journal* 2016-12, vol.62(4), s. 169-177.

Nevalainen, S. & Piri, T. 2020 Metsätuhoriskit tasa- ja eri-ikäismetsätaloudessa. *Metsätieteen aikakauskirja* 2020 artikkeli 10310. Viitattu 20.6.2024. <https://doi.org/10.14214/ma.10310>

Ohlinger, J. 2021. Red Edge detects vegetative stress earlier in plant growth cycle. *Verkko sivu*. Viitattu 5.7.2024. <https://up42.com/blog/red-edge-detects-vegetative-stress-earlier-in-plant-growth-cycle#:~:text=On%20the%20electromagnetic%20spectrum%2C%20the,Red%20and%20Near%20Infrared%20bands>.

Pukkala, T. 2018. Effect of species composition on ecosystem services in European boreal forest. *Journal of forestry research vuosikerta 2018-03*, vol.29(2), s. 261-272.

Pulgarin Diaz, J., Melin, M., Lyytikäinen-Saarenmaa, P., Peltola, H. & Tikkanen, O.-P. 2024. Relationship between stand and landscape attributes and *Ips typographus* salvage loggings in Finland. *Silva Fennica* vol. 58, no. 3, artikkeli 23069. <https://doi.org/10.14214/sf.23069>

Raitila, J., Ahola, J., Virkkunen, M., Sipola, T., Riihimäki, H. & Tenhunen, J. 2021. Digitaaliset metsänarviointimenetelmät puuhuollon tehostajina. Tutkimusraportti. Viitattu 27.6.2024. <https://cris.vtt.fi/en/publications/digitaaliset-mets%C3%A4narviointimenetelm%C3%A4t-puuhuollon-tehostajina>

Shalev-Shwartz, S. & Ben-David, S. 2014. Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press.

Shataee, S., Kalbi, S., Fallah, A. & Pelz, D. 2012. Forest attribute imputation using machine-learning methods and ASTER data: comparison of k-NN, SVR and random forest regression algorithms. *International journal of remote sensing* 2012-10, vol.33 (19), s.6254-6280.

Segarra, J., Buchaillet, M., Araus, J. & Kefauver, S. 2020. Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications. *Agronomy (Basel)* 2020-05, vol.10 (5), s.641. 18 sivua.

Solberg, s., Aamlid, D., Tveito, O. & Lystad, S. 2015. Increased needlefall and defoliation in Norway spruce induced by warm and dry weather. *Boreal Environment Research* 2015-06, vol. 20(3) s. 335-349.

Sähkömagneettinen säteily. n.d. Wikipedia. Verkkosivu. Viitattu 3.7.2024. https://fi.wikipedia.org/wiki/S%C3%A4hk%C3%B6magneettinen_s%C3%A4teily

Terminen kasvukausi. n.d. Ilmatieteenlaitos. Verkkosivu. Viitattu: 12.5.2024. <https://www.ilmatieteenlaitos.fi/terminen-kasvukausi>

Tjoelker, M., Boratyński & Bugala, W. (toim.) 2007. *Biology and Ecology of Norway Spruce*. E-kirja. Dordrecht: Springer. <https://link-springer-com.lib-proxy.tuni.fi/book/10.1007/978-1-4020-4841-8>

Tuominen, H., Neittaanmäki, P., Niinimäki, E., Pölönen, I., Rautiainen, I., Äyrämö, S., Ruohonen, T., Nyrhinen, R., Ojalainen, A., Vähäkainu, P. & Äyrämö, S-M. 2019. Teko-älyn perusteita ja sovelluksia. Jyväskylän yliopisto, JYX-julkaisuarkisto. <http://urn.fi/URN:ISBN:978-951-39-7796-2>

Valtakunnan metsien inventointi (VMI) – kuvaus. n.d. Luonnonvarakeskus. Verkkosivu. Viitattu 3.7.2024. <https://www.luke.fi/fi/seurannat/valtakunnan-metsien-inventointi-vmi/valtakunnan-metsien-inventointi-vmi-kuvaus>

Vastaranta, M., Honkavaara, E., Saarinen, N., Holopainen, M. & Hyypä, J. 2015. Tuuli- ja lumituhojen kartoitus ja mallinnus useampiaikaisten kaukokartoituspintamallien avulla. Metsätieteen aikakauskirja 2015, numero 1, artikkeli 6299. Viitattu 20.6.2024. <https://doi.org/10.14214/ma.6299>

Venäläinen, A., Lehtonen, I., Laapas, M., Ruosteenoja, K., Tikkanen, O.-P., Viiri, H., Ikonen, V.-P. & Peltola, H. 2020. Ilmastonmuutos lisää metsätuhojen riskejä Suomessa. Metsätieteen aikakauskirja vuosikerta 2020 artikkeli 10454. Viitattu 20.6.2024. <https://doi.org/10.14214/ma.10454>

Viiri, H. 2020. Parantaako vai heikentääkö metsänhoito metsien kestävyyttä metsätuhoja vastaan? Metsätieteen aikakauskirja vuosikerta 2020, artikkeli 10505. Viitattu 20.6.2024. <https://doi.org/10.14214/ma.10505>

Vilka, H. 2007. Tutki ja mittaa: Määrällisen tutkimuksen perusteet. Helsinki: Tammi.

Vuoden 2023 sääyhteenveto. n.d. Ilmatieteenlaitos. Verkkosivu. Viitattu 17.6.2024. <https://www.ilmatieteenlaitos.fi/vuosi-2023>

Wadke, N., Kandasamy, D., Vogel, H., Lah, L., Wingfield, B., Paetz, C., Wright, L., Gershenzon, J. & Hammerbacher A. 2016. The Bark-Beetle-Associated Fungus, *Endoconidiophora polonica*, Utilizes the Phenolic Defense Compounds of Its Host as a Carbon Source. *Plant Physiology* 2016, vol 171(2), s. 914-931. Viitattu 20.6.2024. <https://doi.org/10.1104/pp.15.01916>

Ylioja, T. & Sutela, S. (toim.). 2024. Metsätuhot vuonna 2023. Luonnonvara- ja biotalouden tutkimus 34/2024. Luonnonvarakeskus. Helsinki. 101 s.

Zeltiņš, P., Katrevičs, J., Gailis, A., Maaten, T., Jansons, J. & Jansons, Ā. 2016. Stem cracks of Norway spruce (*Picea abies* (L.) Karst.) provenances in Western Latvia. *Met-sanduslikud Uurimused* 65, 57–63. Viitattu 20.6.2024. <https://doi.org/10.1515/fsmu-2016-0012>