



UNIVERSITY OF
EASTERN FINLAND

Luonnontieteiden ja metsätieteiden tiedekunta
Faculty of Science and Forestry

METSÄTEIDEN KULJETUSKELPOISUUTEEN VAIKUTTAVAT TIEN SEKÄ
YMPÄRISTÖN OMINAISUUDET

Ville Karjalainen

METSÄTIETEEN PRO GRADU,
METSÄ-, ENERGIA- JA PUUTEKNOLOGIA

JOENSUU 2019

TIIVISTELMÄ

Suuri osa Suomen nykyisestä metsäautotieverkosta rakennettiin 1960 – 1990 luvuilla ja niiden suunniteltu rakenteellinen käyttöikä oli tuolloin arvioitu 20 – 30 vuodeksi. Suuri osa näistä teistä alkavat siis olemaan peruskunnostamisen tarpeessa. Metsäteollisuuden hakkuutavoitteiden kasvaessa ja puutavaran kuljetusautojen kokonaisuudessa nousemalla nykyisten metsäautoteiden kunto ei ole tarpeellisella tasolla palvelemaan näitä tarpeita. Ympäri vuotisen puutarpeen kasvu asettaa osalle kunnostettavista metsäautoteistä vaatimuksen kestää kuljetuksia myös kelirikkojen aikaan.

Metsäautoteiden kuntoinventointia varten on luotu selkeät laatuluokat tekijöille, jotka yleisesti vaikuttavat teiden kuntoon sekä liikennöitävyyteen. Nämä inventointi menetelmät ovat kuitenkin kalliita ja hitaita toteuttaa niin laaja-alaisesti kuin olisi tarpeellista. Metsäautoteiden kunnan inventoinnin helpottamiseksi tarvittaisiin siis menetelmiä, joilla näitä tekijöitä pystyttäisiin tarkkailemaan ja kartoittamaan ilman työläisiä maastomittauksia. Metsäautoteiden kuntotiedolla pystyttäisiin kohdentaa kunnostustoimenpiteitä tie osuuksille, joilla kunnostukselle on tarvetta ja hyväkuntoisesta tiestä saatava hyöty olisi kannattavaa suhteessa kunnostustoimenpiteiden kustannuksiin.

Tutkimuksen tavoitteena oli tutkia, kuinka luotettavasti metsäautotien kuljetuskelpoisuutta pystytään ennustamaan tien omista sekä tien ympäristön tekijöistä. Tutkimusta varten kerättiin laaja maastoreferenssiaineisto syksyllä 2018 Sonkajärven ja Kurun tutkimusalueilta. Aineistoon mitattiin sekä metsäautoteiden että tien ympäristön ominaisuuksia, joilla arveltiin olevan vaikutusta metsäautoteiden kuntoon. Teille suoritettiin myös arvio niiden kuljetuskelpoisuusluokasta (kelirikko, kesä, kuiva kesä, talvi). Tutkimuksessa selvitettiin kuinka hyvin mitattujen ominaisuuksien avulla, pystytään ennustamaan teiden kuljetuskelpoisuutta.

Tutkimuksessa analysoitiin ensin mitattujen ominaisuuksien merkittävyyksiä suhteessa toisiinsa sekä kuljetuskelpoisuuteen. Analyysien tuloksista selvisi, että osalla aiemmin merkittäväksi oletetuista ominaisuuksista ei ollutkaan suurta vaikutusta kuljetuskelpoisuuteen. Analyysien tulokset osoittivat tien pintalaadun ja tien leveyden olevan merkittävimmät ominaisuudet kuljetuskelpoisuudessa.

Kuljetuskelpoisuutta tarkasteltiin kahdella erilaisella regressiomallilla, joissa käytettiin muuttujina aiempien analyysien perusteella valikoituneita teiden ominaisuuksia. Luodut mallit onnistuivat lopullisessa testivaiheessa ennustamaan kuljetuskelpoisuuden oikein 70,6% ja 68,2% tarkkuudella. Suurimmat ongelmat molemmilla malleilla oli ennustaa oikein luokkaa ”kuiva kesä”, mikä pudotti mallien ennustamistarkkuutta merkittävästi.

Luoduilla malleilla pystytään ennustamaan tien kuljetuskelpoisuutta melko luotettavasti, mutta parantamisen varaa on etenkin luokan ”kuiva kesä” ennustamisessa. Kuljetuskelpoisuuden tarkasteluun voitaisiin ottaa avuksi mukaan paikkatietoaineistoja, joista etenkin laserkilausaineisto on osoittautunut aiemmissä tutkimuksissa hyvinkin käytännölliseksi työkaluksi tien kunnan tarkkailussa.

ABSTRACT

Major part of Finland's current forest road network was built between 1960s and 1990s, and their technical lifetime was then estimated at 20 – 30 years. So many of these roads are shortly in the need of overhaul. As the logging targets of the forest industry keep growing and the total weight of timber trucks increase, the condition of existing forest road network is not sufficient to meet these needs. The growing demand of timber for round-the-year requires for at least part of the forest roads to be overhauled to withstand timber transportation even during spring and autumn thaw.

Clear quality classes have already been created for the factors that generally affect the condition forest roads and transportability. However, these inventory methods are expensive and slow to implement as extensively as needed. In order to facilitate the inventory of forest roads, there would be a need for methods to observe and map these road condition affecting factors without arduous field measurements. With the help of forest road condition information, we would be able to target overhauling on sections of roads where it is needed. It would also be important to determine that the benefits of a high-quality road would be profitable relative to the cost of the overhaul.

The aim of the study was to examine how reliably the transportability of a forest road can be predicted from the factors of the road itself and the factors of the environment surrounding the road. In the autumn of 2018, extensive field reference data were collected from the research areas in Sonkajärvi and Kuru. Selection of factors which were thought to have an impact on the condition of the forest road were measured from the forest road and the road surrounding environment. The roads were also assessed for their transportability class (spring thaw, summer, dry summer, winter). The study investigated how well these measured factors can be used to predict road transportability during different seasons.

The study first analyzes the significance of the measured properties in relation to each other and the transportability classes. The results of the analyzes showed that some of the features previously considered significant did not actually have a significant impact on the transportability. The results of the analyzes indicated that the road surface quality and the road width were the most significant properties when it comes transportability.

Transportability was examined with two different regression models which were using the significant variables selected from previous analyzes. In the final test phase, the models succeeded in predicting the transportability with 70.6% and 68.2% accuracy. The most considerable problem with both models was that they had low success predicting the "dry summer" class correctly, which significantly reduced the potential accuracy of both models.

The models created are able to predict transportability quite reliably, but there is still room for improvement, especially with the "dry summer" class. Spatial data sets, which especially in the past have been proven to be a very useful tool for monitoring the condition of the road, could be included in the further examinations of forest road transportability.

SISÄLLYS

TIIVISTELMÄ	2
ABSTRACT	3
1 JOHDANTO	5
2.1 Maastomittaukset	17
2.3 Muuttujien arvojen normalisointi ja indeksien laskenta	22
2.4 Tutkimukseen valittu aineisto	24
3 MENETELMÄT	26
4.1 Ennustavien selittäjien analyysi	30
4.2 Regressiomallit	34
4.3 Mallien testaus	40
5 TULOSTEN TARKASTELU	43
6. JOHTOPÄÄTÖKSET	47
KIRJALLISUUS	49
LIITTEET	52

1 JOHDANTO

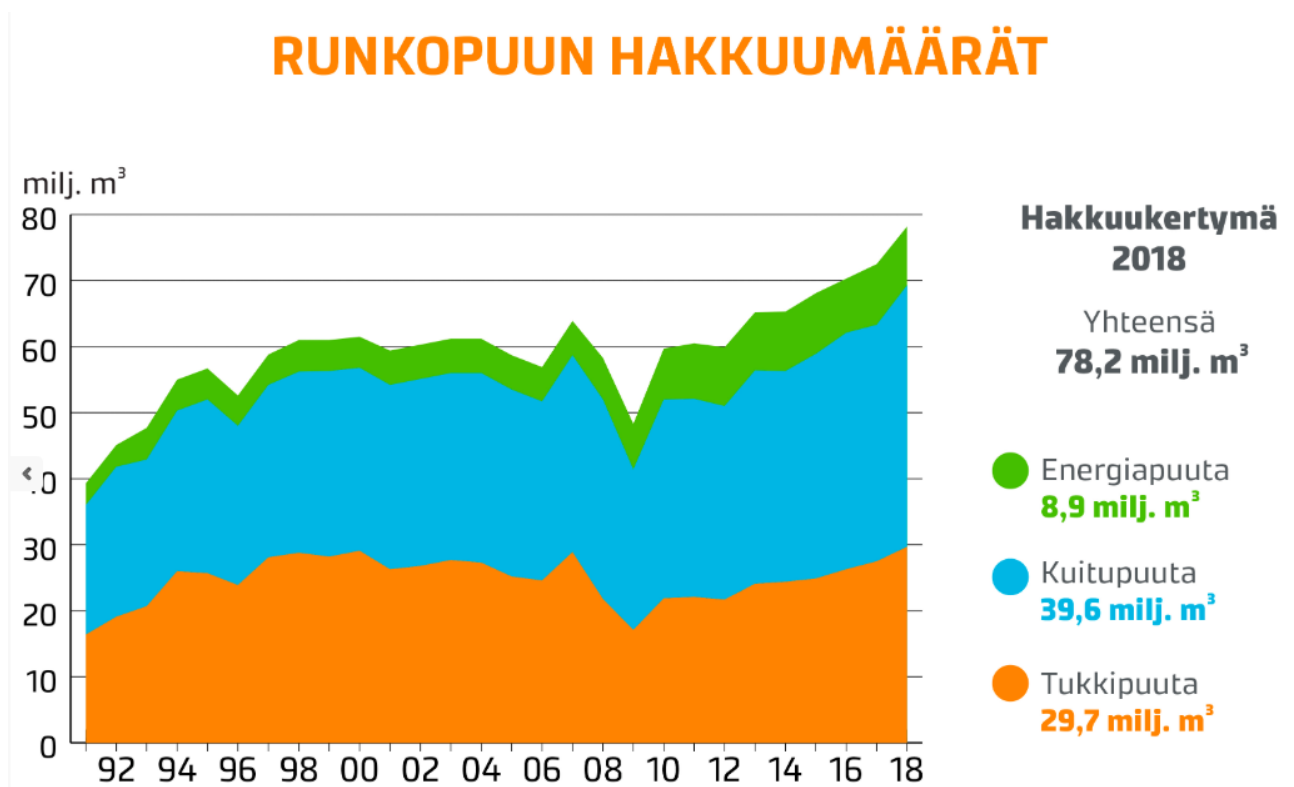
Suomen jatkuvasti kasvava metsätalous ja puuta käyttävä teollisuus on riippuvainen hyväkuntoisesta metsätieverkostosta. Metsäteiden rakentamisen huippuaikaa kesti 1960 -luvun loppupuolelta 1990 -luvun puoliväliin ja silloin rakennettujen teiden suunniteltu käyttöikä oli 20 – 30 vuotta. Metsäteollisuuden kasvava puuntarve ja tästä syntyvät hakkuutavoitteet, lisäävät puutavarankuljetusta. Puutavarankuljetuksessa käytettävän raskaan liikenteen kaluston kokonaisuusmassojen korotus 76 tonniin vuonna 2013 loi entisestään lisää painetta jo ajoittain käyttöikänsä lopussa oleville metsäautoteille. Kuljetusten määrän lisääntyessä ja kuljetuskaluston massan kasvaessa nykyisen metsäautotieverkoston ylläpitäminen käyttökelpoisena on ensisijaisen tärkeää. Kunnostustoimenpiteille on ollut jatkuvaa tarvetta jo aiemminkin, mutta kunnostuksen tarve vain kasvaa lähitulevaisuudessa.

Venäläisen ym. mukaan (2017) kausivaihtelu aiheuttaa kotimaisen puun toimitusketjussa arviolta 70 miljoonan euron lisäkustannukset vuosittain. Kustannuksista 59 % kohdistuu puun korjuuseen, 19 % kaukokuljetuksiin ja yksityisteiden kunnossapitoon, sekä 22 % puun ylimääräiseen varastointiin. Kausivaihtelua aiheuttavat tiestön kelirikko sekä muut kantavuusrajoitteet, leimikoiden korjuukelpoisuuden rajoitteet ja tehtaiden kysynnän vaihtelut. Painorajoitettujen tieosuuksien määrä vaihtelee vuosittain ja painorajoitukset painottuvat voimakkaasti kevään kelirikon ajalle huhti-, touko- sekä kesäkuulle. Kelirikon takia keskimääräinen kuljetusmatka saavutettavissa oleviin tienvarsivarastoihin voi kasvaa, jolloin puuta joudutaan mahdollisesti kuljettamaan tehtaiden normaalien hankinta-alueiden ulkopuolelta. Teiden kantavuusongelmat haittaavat myös korjuukoneiden siirtoja leimikolta toiselle ja nostavat siten myös korjuun kustannuksia.

Metsätiellä tarkoitetaan yksityistielain (2018/560 §3) mukaan tietä, joka on tarkoitettu pääasiassa metsätalouden edellyttämiä kuljetuksia varten. Metsätie tarkoittaa siten ajoneuvoilla, kuten puutavara-autoilla, ajokelpoista tietä (Korpilahti 2008). Metsäautotiet palvelevat kuitenkin suurilta osin muitakin käyttäjiä kuin pelkästään metsätalouden puutavara-autoja, esimerkiksi metsien virkistyskäyttäjät hyötyvät hyväkuntoisesta ja kattavasta metsäautotieverkostosta. Suomessa koko tieverkon yhteispituus on noin 454 000 kilometriä ja tästä yksityis- ja metsäautoteiden osuus on noin 350 000 kilometriä (Liikennevirasto 2017). Näistä yksityisteistä noin puolet on metsäteitä (Greis ym. 2015). Metsätalouden tarpeita palvelevia metsäteitä on rakennettu maahamme yhteensä noin 157

000 km. Tästä määrästä noin 98 000 km sijaitsee yksityismetsissä, 24 000 km metsäyhtiöiden omilla mailla ja 35 000 km Metsähallituksen mailla (Greis ym. 2015).

Luonnonvarakeskuksen (Luke) mukaan (Luke 2019) metsistämme hakattiin vuonna 2018 metsäteollisuuden käyttöön kotimaista ainespuuta (tukki- tai kuitupuun mitat täyttävää raakapuuta) 69,3 miljoonaa kuutiota ja energiapuuksi 8,9 miljoonaa kuutiometriä runkopuuta, eli yhteensä 78,2 miljoonaa kuutiota. Hakkuiden määrä ylitti Luke:n hakkuukertymätilaston mukaan edellisen vuoden hakkuut liki kuudella miljoonalla kuutiometrillä. Luke:n syksyllä 2018 tekemän arvion mukaan metsiemme puuntuotannollisesti suurin kestävä hakkuumahdollisuus on nyt menossa olevalla 10-vuotiskaudella 2015 – 2024 koko maassa 84 miljoonaa kuutiometriä runkopuuta vuodessa. Kuvasta 1 nähdään selkeästi, kuinka metsäteollisuuden kasvu on nostanut, sen käyttöön tarvittavan runkopuun hakkuukertymää.



Kuva 1. Runkopuun hakkuukertymät vuosien 1991 – 2018 välillä. (Luke 2019. Runkopuuta kaatui 2018 enemmän kuin koskaan, 13.6.2019)

Suomen metsäteollisuus on kasvanut runsaasti vuodesta 2014 eteenpäin ja alalle ollaan jatkuvasti tekemässä uusia investointeja, jotka kasvattaisivat nykyistä puuntarvetta ja täten

hakkuumääriä. Tällöin häiriötön ja ympärivuotinen puutavaran kuljetus leimikoilta tehtaille sekä sahoille on äärimmäisen tärkeää, jotta tehokasta toimintaa ja kasvua voidaan pitää yllä. Tarve ympärivuotiselle ja häiriöttömälle puunhankinnalle varsinkin kelirikon aikaan on suuri haaste, sillä nykyisessä metsätieverkostossa on suhteellisen vähän ympärivuoden raskaan liikenteen kalustolle kelpaavia teitä. Varsinkin metsäautotieverkoston pistojen kunto on suurilta osin heikko, vaikka niiden kunto onkin kriittinen tekijä toimivalle puunhuollolle ja leimikoiden saavutettavuudelle.

Metsäteiden rakentamiseen alettiin myöntää metsänparannusvaroja (nykyinen Kemera) vuodesta 1948 alkaen (Viitala & Uotila 1999). Teiden rakentaminen lisääntyi merkittävästi kuitenkin vasta 1960-luvun loppupuolella ja varsinainen huippukausi oli 1980 -luvun alkupuolella, jolloin metsänparannusvaroin rahoitettuja metsäteitä tehtiin vuosittain noin 3 000 kilometriä (Viitala & Uotila 1999). Metsäteiden rakentamisen aikakausi kesti aina 1990 -luvun puoleen väliin (Korpilahti 2008). Tuolloin rakennettujen teiden suunniteltu rakenteellinen käyttöikä oli 20 – 30 vuotta, joten suuri osa metsäautoteistä on lähellä teknisen elinkaarensa loppua. Monissa tapauksissa nämä tiet edustavat pullonkauloja kuljetusverkossa (Kaakkurivaara 2018). Liikenneviraston ohjeita 1 mukaan (2014) pääosa vanhoista metsäautoteistä on ns. rakentamattomia teitä, joissa ei ole asianmukaisesti rakennettuja routimattomia rakennekerroksia. Näillä teillä on vain kaksi pääkerrosta: pohjaosa, joka on muodostettu oja kaivaessa saadulla maa-aineksella, ja pintaosa, joka on ohut pintamurskekerros. Metsäautotieverkosto vaatii siis lähitulvaisuudessa mittavia perusparannuksia ja näiden teiden on vastattava käytettävien kuorma-autojen kasvaneen kokonaisuuden asettamia kantavuuden vaatimuksia (Kaakkurivaara 2018). Alueellisen metsäohjelman (AMO) asettama metsäautoteiden vuotuinen perusparantamisen määrän tavoite on noin 4000 kilometriä ja uusien metsäautoteiden rakentamisen tavoite noin 550 kilometriä. (Leinonen 2019) Vuosittain Suomessa kuitenkin perusparannetaan ja rakennetaan metsäautoteitä valtion tuella vain 1000 – 1500 kilometriä. (Leinonen 2019)

Yleisesti ottaen puutavaran kuljetus puutavara-autoilla on joustava kuljetusmenetelmä tapauksissa, joissa kuljetusten lähtöpaikka muuttuu jatkuvasti ja lisäarvo on alhainen. Siksi puun kuljetus puutavara-autoilla on Suomen metsäteollisuuden raaka-aineen tärkein kuljetusmenetelmä (Malinen ym. 2014). Tästä syystä Suomen metsäteollisuus tarvitsee mahdollisimman hyvää kuntoisen metsätieverkoston. Ympärivuotisen ja häiriöttömän raaka-

aineiden toimituksen tavoitteen saavuttamiseksi olisi tarpeellista suorittaa laajoja metsäteiden perusparannuksia tai lisätä tietämystä metsäteiden kunnosta, jotta parannustoimenpiteitä voitaisiin kohdistaa selkeisiin ongelmakohtiin. Metsätien perusparantamisella tarkoitetaan toimenpiteitä, joilla vanha tie korjataan tulevan puutavaran kuljetuksen vaatimusten mukaiseksi (Korpilahti 2001). Perusparannuksen syitä ovat useimmiten rakenteelliset puutteet, kuljetustarpeiden kasvaminen tai riittävien kunnossapitotöiden laiminlyönti ja niistä johtuva tien rappeutuminen (Korpilahti 2001).

Metsäautotiet ovat tärkeimpiä rakenteita metsätaloudessa, sillä ne määrittävät, onko tietyn metsän hoitaminen kannattavaa vai ei (Gumus S. 2009). Kaikkia teitä ei kuitenkaan ole taloudellisesti järkevää lähteä perusparantamaan tai kunnostamaan. Viitalan ym. mukaan (2004) metsätalouden näkökulmasta perusparannusinvestointien kannattavuus riippuu suuresti tien vaikutusalueella toteutuvista hakkuumääristä, niiden ajoittumisesta ja kaluston liikuttelun vähentymisestä sekä helpottumisesta suhteessa siihen, kuinka paljon perusparannus maksaisi kyseiselle tielle. Hakkuiden määrä ja ajoittuminen on oleellinen tieto, pohdittaessa tien perusparannuksen tai kunnostuksen tarvetta. Tällöin voidaan määrittää, onko tie kannattavaa kunnostaa kelirikon aikaan liikennöitäväksi vai riittääkö, että tiellä tapahtuvat kuljetukset ajoittuvat kesäkaudelle. Viitala ym. Mukaan (2004) olisi siis hyödyllistä kartoittaa sellaiset puuntuotantoalueet, joilla metsäteiden perusparantaminen kelirikkokelpoisiksi olisi tuottoisaa. Tärkeää on myös pystyä kohdentamaan resursseja vanhojen yksityisteiden perusparannukseen siten, että teiden ensisijaisten maksajien — metsänomistajien — ja muidenkin käyttäjien hyöty maksimoituisi.

Tien merkittävyyteen löytyy arviointimenetelmä (Korpilahti 2008), jossa teille annetaan pisteytys perustuen: ensiksi tien tieverkollisesta asemasta, eli onko tie esimerkiksi kahden maantien välinen tie, jolla on paljon läpikulkuliikennettä. Toiseksi arvio suoritetaan vaikutusalueen luonteesta, eli onko tie metsä- tai energiatalouden aktiivisessa käytössä ja onko tien toiminta-alueella taloudellista potentiaalia tai onko tien vaikutusalueella muuta merkittävää toimintaa, kuten elinkeinotoimintaa, pysyviä asutuksia tai maa-ainesten ottopaikkoja. Kolmanneksi tarkastellaan yleisesti, onko tiellä, kuinka runsaasti liikennöintiä, johon sisältyy tiedot sekä henkilö- että tavaraliikenteestä. Tällä arvioinnilla pystyttäisiin asettamaan tiet tärkeysjärjestykseen perusparannuksia ajatellen.

Teiden kunnossapitokustannukset koostuvat yleisesti lanauksesta, sorastuksesta sekä aurauksesta. Ajan mittaan nämä kustannukset nousevat tien yleiskunnon heikentymisen seurauksena. Kunnossapitokustannukset vaihtelevat paljon yksittäisten teiden välillä ja niiden suuruuteen vaikuttaa etenkin raskaan liikenteen määrä ja ajankohta. (Viitala & Uotila 1999)

Ilmastonmuutoksen aiheuttamilla sääilmiöillä oletetaan olevan merkittävä vaikutus metsäautoteiden kantavuuteen sekä liikennöitävyyteen ja tämä vaikutus tulee näkymään eri osissa Suomea eri tavoilla. Matalat lämpötilat, myrskyt, voimakkaat tuulet ja sadannan kasvu tulevat todennäköisesti aiheuttamaan häiriöitä kuljetuksissa, vaurioittamaan teitä ja vaikeuttamaan teiden ylläpitoa (Malinen ym. 2014). Lisääntyvä sadanta aiheuttaa vedenpinnan ja pohjavedenpinnan nousua. Tierakenteiden vaurioriski kasvaa ja elinkaari lyhenee pohjaveden nousun aiheuttaman kantavuuden alenemisen myötä (Saarelainen & Makkonen 2007). Ilmaston ääri-ilmiöiden voimistuminen ja toistuvuuden lisääntyminen lisää tierakenteiden ja laitteiden kunnossapito- ja korjaustarvetta (Saarelainen 2006a & 2006b)

Syys- ja kevätsateiden lisääntyessä tien pinnan sekä rungon kuivatuksen on toimittava hyvin, jotta etenkin pintakantavuus ei kärsi kosteuden liiasta kasvusta. Lisääntyvistä sateista, aiheutuva vesistöjen sekä vesiuomien tulviminen voi ylittää teiden kuivatusrakenteiden mitoitusastan, jolloin tulvien aiheuttamat vahingot yleistyvät ja kasvavat (Saarelainen & Makkonen 2007).

Saarelaisen ja Makkosen mukaan (2007) teiden aurauksen tarve talvisin todennäköisesti vähenee etelässä, mutta Keski- ja Pohjois-Suomessa lumisateiden odotetaan lisääntyvän ja aiheuttavan vaikeuksia teiden liikennöintikelpoisena pitämisessä etenkin yksityisteillä. Lisäksi liukkauden torjunnan tarve kasvaa Pohjois-Suomessa, kun talvet leudontuvat. Talvikunnossapito ei ole lain velvoittamaa, jos tien tai tieosan käyttö ei ole yhdellekään tieosakkaalle välttämätöntä talvikaudella (Yksityistielaki, 2018/560 § 24). Malisen ym. (2014) tutkimuksessa tiedusteltiin yhteensä 86:lta puunkuljetuksen yrittäjältä heidän näkemystään puunkuljetuksen tulevaisuuden haasteista ja yhdeksi suurimmaksi ongelmaksi nousi nimenomaan teiden talvikunnossapito.

Ilmaston lämpenemisellä voi myös olla positiivisia vaikutuksia puunkuljetuksessa. Saarelaisen ja Makkosen mukaan (2007) leudompina talvina ansiosta metsäautotiestölle tulee aiheutumaan vähemmän routimisesta johtuvia vaurioita, sillä ilmaston lämpeneminen

pienentää roudan syvyyttä, jolloin myös kelirikkoajan pituus lyhenee. Routa ja kelirikko ovat kuitenkin ongelmia myös tulevaisuudessa, ja niiden huomioonottaminen tienpidossa on edelleen tarpeellista ja etenkin pienteiden painorajoitustarve tuskin tulee muuttumaan, vaikka kelirikko lyheneekin. Routakauden lyheneminen aiheuttaa myös talven ajan suoritettavien kuljetusten aikaikkunan lyhenemistä.

Metsäautoteiden kunnan määrittämistä aiemmin on tutkittu käyttäen erilaisia kaukokartoitusmenetelmiä, etenkin tiheäpulssisella lentolaserkeilausaineistolla on todettu olevan potentiaalia tien laadun ja keskilinan määrittämisessä. Tien kunnan havainnoinnista tiedetään, että tien kosteuteen vaikuttavilla ominaisuuksilla on suuri vaikutus kuljetuskelpoisuudessa. Tien rungon läheisyyteen sekä tien pinnalle jäävä vesi aiheuttaa tien pehmenemistä, joka vaikuttaa suuresti tien liikennöitävyyteen. Kyseisiä tekijöitä ovat muun muassa tien pinnan kaltevuus, reunapalteet sekä sivu- ja laskuojat. Näiden ongelmakohtien selvittäminen kaukokartoitusaineistolla olisi ensisijaisen tärkeää tien kokonaiskunnan arvioinnissa.

Tarkkinen (2015) pyrki opinnäytetyössään määrittämään tien ja tätä ympäröivän maaston ominaisuuksia hyödyntäen korkeusmallia, joka on muodostettu laserkeilausaineiston pohjalta. Tarkasteltavina ominaisuuksina olivat tienpinta, tienpinnan ja ympäröivän maaston korkeusero sekä kuivavara. Tutkimuksesta saadut korrelaatiot tien pinnan ja ympäröivän maaston korkeuserojen sekä tien kantavuuden välille eivät olleet luotettavia. Tärkeä huomio työssä oli, että tien kantavuus heikkeni mitä syvemmäksi ojien syvyydet muuttuivat, jolloin oletuksena maaperä on ollut ”huonompaa” ja ojat on tästä syystä rakennettu syvemmiksi. Korkeuseromallista oli myös mahdollista havaita ajoittain tien laitoihin muodostuneita palteita, joilla on merkittävä vaikutus tien pinnan kuivumiseen. Tutkimuksessa käytettyä menetelmää voisi tuottaa toisenlaisia tuloksia, kun mukaan saataisiin muitakin tietolähteitä, kuin pelkkä korkeusmalli.

Kiss ym. toteuttamassa tutkimuksessa (2015) pyrittiin arvioimaan metsäteiden rakenteellista kuntoa, kausivaihtelun aiheuttamia vaurioita, tien kuivatusta, siltoja, pinnan kulumista, näkymäaluetta, vesakoitumista ja tasaisuutta hyödyntäen tiheäpulssista lentolaserkeilausaineistoa. Vaihtelevan resoluution digitaalisten korkeusmallien kanssa käytettiin topografista sijainti-indeksiä, standardisoitua korkeusindeksiä ja hydrologiatyökaluja, tavoitteena testata, mitkä aiemmin mainituista tien kunnan

kategorioista voitaisiin johtaa aineistosta luotettavasti. Tutkimuksen tuloksissa käy ilmi, että tien pinnan kuluneisuudella ja tasaisuudella on merkittävin vaikutus tien pinnan laatuun. Tien pinta pystyttiin määrittämään kaikilla resoluutioilla vähintään 66 %:sti oikein ja ojat 60 %:sti. Tulokset varmistivat, että lentolaserkeilausaineistoa voitaisiin käyttää laadukkaan tiedon hankkimiseen metsäautoteistä.

Craven ja Wing (2014) tutkimuksessa saatiin vastaavasti selville, että tiheäpulssisella lentolaserkeilausaineistolla pystytään ennustamaan onnistuneesti metsäteiden keskilinjoja ja laatua. Tiheäpulssisella lentolaserkeilausaineistolla todettiin pystyttävän määrittämään myös tieverkon kaarteiden jyrkkyyksiä ja nostamaan esille kaarteita, jotka ovat liian jyrkkiä puoliperävaunurekoille. Ferraz ym. 2016 pääsivät myös vastaaviin tuloksiin kaarteiden jyrkkyyksien estimoinnista, mutta he käyttivät harvapulssista lentolaserkeilausaineistoa.

Nisulan (2019) maisterintutkielmassa arvioitiin harvapulssisen lentolaserkeilausaineiston ja avoimen paikkatietoaineiston käytettävyyksiä metsäteiden kunnon määrittämisessä. Tutkimuksen tulokset osoittavat, että harvapulssisesta lentolaserkeilausaineistosta mitattavat piirteet, kuten pisteiden korkeusjakaumaa kuvaavat persentiilit, pisteiden korkeutta kuvaavat keskiluvut sekä korkeusmallista irrotetut rinteiden jyrkkyyttä kuvaavat piirteet, osoittautuivat tärkeimmiksi ennustettaessa metsäteiden kuntoa. Tutkimuksessa onnistuttiin ennustamaan tien kuntoluokka 69,8% tarkkuudella, mikä vastaa hyvin Kiss ym. (2015) tutkimuksessa saatuja tuloksia.

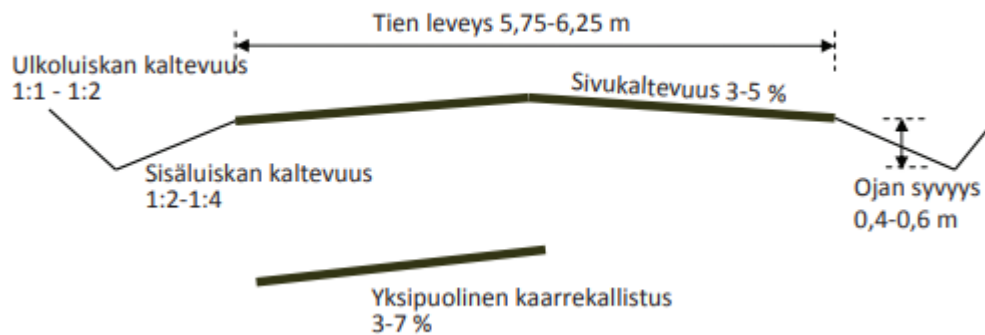
Hruza ym. (2018) tutkivat neljää eri kaukokartoitusmenetelmää tienpinnan kunnon tarkastelussa: lentolaserkeilaus (ALS), liikkuva laserkeilaus (MLS), maastolaserkeilaus (TLS) ja lähifotogrammetria (CRP). Liikkuvaa laserkeilausta (MLS) käytetään laajalti kaupunkialueilla, erityisesti päällystettyjen teiden keilaamiseen ja arviointiin. Liikkuva laserkeilain on mahdollista kiinnittää esimerkiksi autoon tai miehittämättömään ilma-alukseen. Toinen menetelmä, jota Hruza ym. (2018) tutkimuksessaan tarkastelivat, oli maastolaserkeilaus (TLS). Heidän mukaansa maastolaserkeilausta voidaan tehokkaasti käyttää tien pinnan tarkastelussa ennen korjaustoimenpiteitä, tien vahinkojen havainnoinnissa (urautumien ja kuopat) tai tarvittavan materiaalin määrän pinnan korjausten toteuttamiseen. TLS-menetelmä on yksi nopeinten kehittyvistä menetelmistä 3D-tiedon keruussa. Tutkimuksen tulokset maastolaserkeilauksesta (RMSE 0,0243m) ja lähifotogrammetriasta (RMSE 0,0110) olivat tien pinnan kunnon tarkastelussa todella lupaavat, saavuttaen huomattavasti paremman

tarkastelun tarkkuudet kuin yleisesti käytetty lentolaserkeilausaineisto (RMSE 0,1392) tai liikkuva laserkeilaus (RMSE 0,3167m).

Zhang (2008) tutkimuksessa tarkasteltiin miehittämättömän helikopterin käyttöä tien pintakunnon datan keräämiseen. Tavoitteena oli myös kehittää tehokas menetelmä kerättyjen kuvien käsittelemiseen ja pinnan ominaisuuksien tarkastelemiseen. Tutkimuksessa kuvien keräämiseen käytettiin helikopteriin kiinnitettyä järjestelmäkameraa. Kuvista saatiin tuotettua arvio tieolosuhteista käyttämällä kuvankäsittelyyn ja analysointiin kehitettyjä algoritmeja. Kuvien avulla tien pinnasta onnistuttiin luomaan 3D-malli. Menetelmää on testattu useilla päällystämättömillä sorateilla. Tutkimuksen tulokset osoittivat menetelmän onnistuvan kuvaamaan tienpinnan laatua hyvin. Luotujen mallien ja tien pinnalle suoritettujen tarkkojen mittausten välille jää vain yhden senttimetrin ero, mikä kertoo kehitettyjen mallien suuresta potentiaalista tien pintalaadun mallinnuksessa.

Metsäautoteiden kuntoinventointia voidaan toteuttaa maastossa tarkastelemalla tien kuntoa kuvastavia ominaisuuksia sekä tekijöitä tien pinnalta ja sen ympäristöstä. Kuntoinventointi olisi tärkeää etenkin yksityisteillä, sillä näistä on olemassa hyvin suppeasti kuntotietoja, mikä hankaloittaa esimerkiksi puutavaran kuljetusten suunnittelua.

Kuivatuksen toimivuudella on erittäin suuri merkitys metsätien kuntoon ja hyvällä kuivatuksella voidaan merkittävästi pinta- ja runkokelirikon muodostumista. Metsätien liikennöitävyys pysyy hyvänä, kunhan pinta- sekä runkorakenteet pysyvät kuivana ja sade- tai sulamisvesi ei jää seisomaan tien pinnalle tai ojiin lähelle tien runkoa (Korpilahti 2008). Tien kuivauksen toimivuutta ajatellen merkittävimmät tekijät ovat: reunapalteet, tien sivukaltevuus, vesakoituminen, rummut ja sivu- sekä laskuojien syvyys ja kunto (Korpilahti 2008). Näiden tekijöiden ollessa kunnossa voidaan taata vedelle esteetön kulku tienpinnalta sivuojiin ja edelleen laskuojiin pois tien rungon läheisyydestä.



Kuva 2. Soratien poikkileikkaus (Liikenneviraston ohjeita 1/2014)

Liikenne viraston ohjeiden 1 mukaan (2014) tien sivukaltevuuden tulisi olla riittävän jyrkkä tien molemmin puolin 3-5% (kuva 2). Liian pieni sivukaltevuus estää veden poisvirtaamisen tien pinnalta ja aiheuttaa veden sekä liikenteen yhteisvaikutuksesta kuoppaisuutta ja uria. Liian pieni sivukaltevuus myös lisää syksyn ja alkutalven vesisateiden aikana ja keväällä lumien sulaessa pintakelirikkoa. Kaarteissa liian suuri sivukaltevuus voi pahimmillaan aiheuttaa raskaiden ajoneuvojen suistumis- sekä kaatumisvaaran, etenkin liukkaaseen vuodeen aikaan ja jos tien reunakantavuudessa on puutteita.

Reunapalteet ovat ajoradalta siirtyneestä pintamateriaalista tien reunalle muodostuneita pientareita, jotka estävät veden poistumista sivuojiin, vaikka tien sivukaltevuudet olisivat riittävät. Niiden muodostumiseen vaikuttaa myös tien reunojen heinittyminen sekä vesakoituminen. (Liikenneviraston ohjeita 1/2014)

Tiheä vesakko heikentää merkittävästi tien kuivatuksen toimintaa sekä sivuojien veden siirtokykyä ja kaventaa myös ajoradan leveyttä. Vesakkoa voi esiintyä metsäteillä sivuojoissa sekä ajoradan ja sivuojan välisellä alueella. (Korpilahti 2008) Rungas ojien vesakoituminen sitoo kosteutta maaperään lähelle tien runkoa ja haittaa veden kulkeutumista sivuojoissa, lisäksi suurikokoinen vesakko varjostaa tien pintaa hidastaen sen kuivumista.

Tien pinnan epätasaisuudet, kuten urat, kuopat ja pintaan nousseet kivet aiheuttavat ajomukavuuden heikkenemistä sekä hidastavat tien pinnan kuivamista. Tien kulutuskerros vaikuttaa myös tien pintakantavuuteen ja kuljetuskelpoisuuteen. Korpilahden mukaan (2008) kulutuskerroksen paksuus tulisi olla vähintään 5 senttimetriä ja siinä käytettävän materiaalin on oltava kalliomurskettä, murskesoraa, luonnonsoraa tai moreenimurskettä.

Vuosina 2011 – 2014 on tutkittu teiden kuljetuskelpoisuuden mahdollista parantamista lisäämällä pintamurskeen sidosaineksi tuhkaa. Lisättäessä tuhkaa, tien pinnalle muodostuu kova kuorimainen rakenne, joka kestää kulutusta huomattavasti paremmin kuin pelkkä puhdas murske. Tutkimuksen tulokset osoittavat, että tuhalla perusparannetut tiet paranevat kantavuudeltaan vuosien edetessä, toisin kuin tuhkattomat tiet. (Tuhkan käyttö tienrakennuksen materiaalina... 2014)

Sivu- ja laskuojat ovat merkittäviä tekijöitä tien kuivatuksessa ja etenkin kelirikkojen aikaan. Sivuoajat estävät veden lammikoitumista tien reunoille, mahdollistavat veden poistumisen tierakenteesta ja johtavat ne edelleen laskuojiin (Väyläviraston ohjeita 6/2019). Huono kuntoisilla, tukkeutuneilla tai liian matalilla sivuojilla on negatiivinen vaikutus tien kuivatukseen ja täten tien kantavuuteen (Liikenneviraston ohjeita 1/2014). Tierummut kuljettavat sade- ja sulamisvesiä tien ali laskuojiin. Tierummut sijoitetaan yleensä tien alimpaan kohtaan, johon sivuojista laskeva vesi kasaantuu. Tukkeutunut tai romahtanut tierumpu estää veden kulkeutumisen tien ali laskuojiin, mikä aiheuttaa veden seisattumisen tien rungon läheisyyteen ja aiheuttaa tien kantavuuden alenemista kyseisissä kohdissa (Liikenne viraston ohjeita 5/2013).

Maaperän kantavuus vaikuttaa huomattavasti tien rakentamis- sekä hoitokustannuksiin ja tierungon mitoitus on riippuvainen pohjanmaan kantavuudesta. Mitä hienojakoisemmalle pohjamaalle tie rakennetaan, sitä vahvempi ja leveämpi täytyy rungon olla, jotta tielle saadaan haluttu kantavuus. Pohjamaan kantavuus riippuu voimakkaasti maalajin raekoosta ja yleisesti voidaan todeta suuremman raekoon omaavan maa-aineksen sitovan itseensä vähemmän vettä kuin hienojakoinen maa-aines. (Korpilahti 2001)

Korpilahden ohjeistuksessa (2008) on määritetty tekijät, jotka vaikuttavat metsäautoteiden kuntoon ja kuinka näitä tekijöitä voidaan mitata kuntoinventointien yhteydessä. Menetelmät ovat kuitenkin liian hitaita ja työläitä suorittaa suuremmille alueille. Asiantuntemus olisi suuressa roolissa kuntoinventointien suorittamisen laatua ja nopeutta ajatellen, mutta ongelmana on tällaisten asiantuntijoiden puute. Tiedon keruun joukkoistaminen olisi yksi vaihtoehto kerätä laajempaa tiestödataa eri puolilta Suomea.

Joukkoistetun tiedonkeruun onnistuminen vaatisi että, inventoinneille luodaan tarkat ohjenuorat, mutta samaan aikaan mittausten suorittaminen ei saisi olla kuitenkaan liian

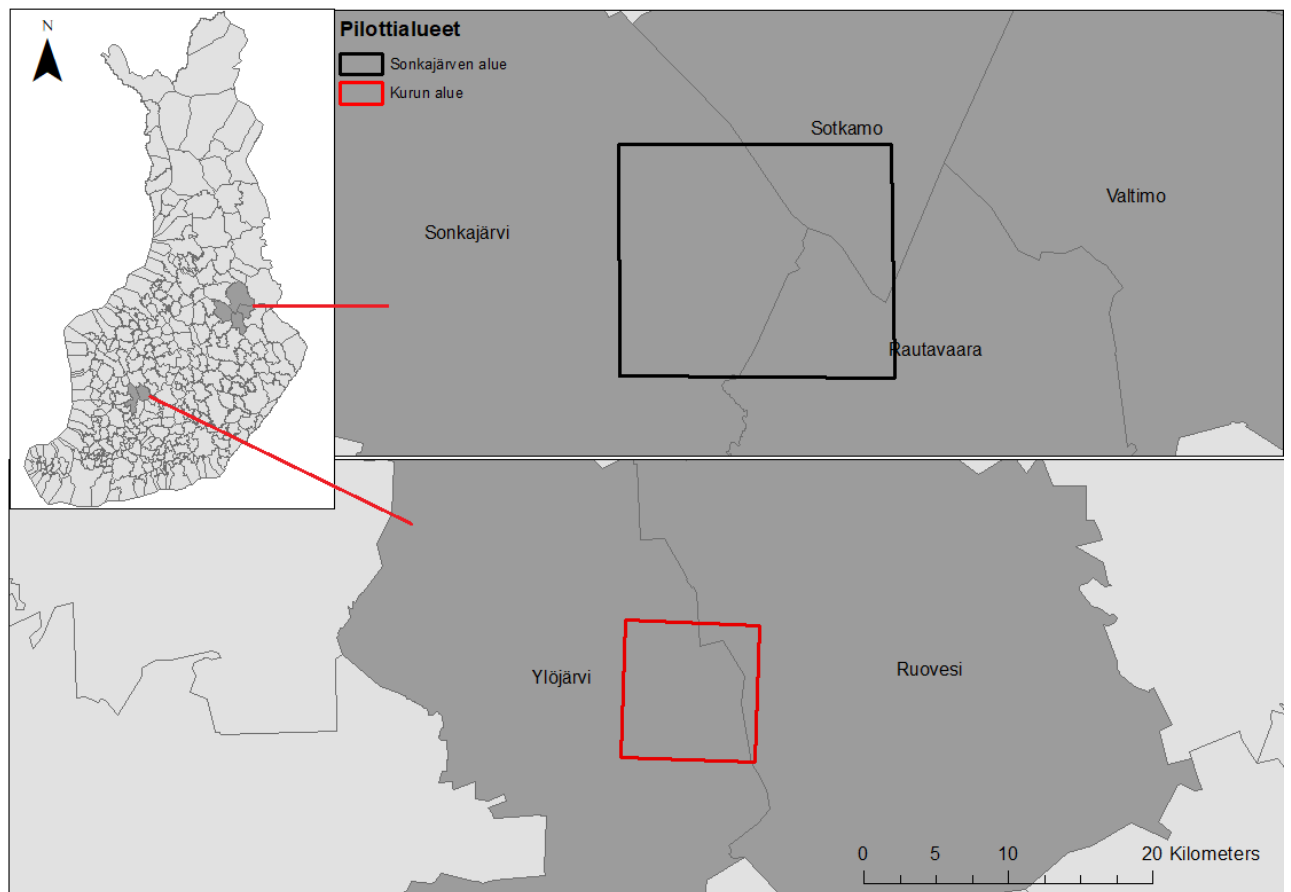
työlästä. Teiden täydellinen inventointi ei olisi välttämätöntä vaan kuljetukseen vaikuttavien ongelmakohtien tunnistaminen ja näiden paikantaminen olisi tärkeää. Inventoitaville tekijöille tulisi määrittää tarkat laatuluokat ja ohjeistukset sekä perusteet, kuinka nämä tekijät voitaisiin luokitella oikeisiin laatuluokkiin. Hyvä ohjeistus olisi tärkeä, jotta useammatkin eri arvioijat saisivat määritettyä saman laatuluokat tietyn kohteen ominaisuuksille, eikä arvioijan oma mielipide saisi liikaa valtaa päätöksessä. Tällöin kuntoinventointi olisi mahdollista myös vapauttaa yksityisteiden omistajien työkaluksi, jolloin tien kunto voitaisiin lisätä esimerkiksi osaksi metsäsuunnitelmaa Metsään.fi-palveluun. Metsänomistajien näkökulmasta teiden kuntoinventointi olisi hyödyllistä, sillä tien kunnolla on parhaillaan vaikutusta puukaupassa saatavaan puun hintaan, jos leimikko on hyvän tien varressa. Tämä taas voisi johtaa huonolla tuurilla liian ”hyvään” arviointiin metsänomistajan puolelta paremman puun hinnan toivossa.

Yhtenä työkaluna toimisi myös Metsäkeskuksen ja RoadsML:n valmistama Metsään Tie - mobiilisovellus. Sovelluksella voi ilmoittaa yksittäisiä havaintoja esimerkiksi metsätien liukkaudesta, kelirikosta, kuopista ja kivistä, tulvahaitoista tai aurauksen tarpeesta (Suomen metsäkeskus 2019a). Metsään Tie- sovelluksella saataisiin parhaillaan kerättyä reaaliaikaista tiestön kuntotietoa ja puunkorjuun sekä kuljetuksen reagointikykyä saataisiin parannettua. Muita vastaavia sovelluksia olisivat esimerkiksi Arbonaut Oy:n ProMS mobiilisovellus, jolla pystytään tarkastelemaan avoimia paikkatietoaineistoja ja raportoida sekä seurata erilaisia kunnossapitotöitä. Viominer mobiilisovelluksella voidaan kerätä tiestöstä gps-sijainnin mukaan tallentuvaa videoaineistoa. Viominer sovelluksella kerätty reaaliaikainen videoaineisto olisi puunkuljetuksen ja -korjuun suunnittelun apuna äärimmäisen hyödyllistä etenkin kelirikon aikaan.

Tutkimuksen tavoitteena oli selvittää kerätyn maastoaineiston pohjalta, mitkä tien ja ympäristön ominaisuudet ovat mahdollisesti merkittäviä tekijöitä tien kuljetuskelpoisuuden kannalta. Kerätyistä tien ominaisuuksista pyritään myös muodostamaan kaksi erilaista regressiomallia, joilla voitaisiin tarkastella, kuinka hyvin malleihin valikoituneilla ominaisuuksilla onnistutaan ennustamaan kuljetuskelpoisuusluokat tietyille koealojen otannalle.

2 AINEISTO

Tutkimuksessa käytetty aineisto on peräisin kahdelta alueelta Länsi-Suomesta ja Itä-Suomesta. Ensimmäinen alue sijaitsee Pirkanmaan kuntien Ruoveden, Ylöjärven sekä Kurun alueella ja toinen Pohjois-Savon kuntien Sonkajärven, Sotkamon sekä Rautavaaran alueella (Kuva 3). Jatkossa alueista käytetään nimitystä Kuru sekä Sonkajärvi. Hankkeessa oli mukana yhteensä neljä aluetta, aiemmin mainittujen lisäksi Kouvolan sekä Pyhäjärven kunnissa Tutkimuksessa käytettävän maastoaineiston keruu kohdistettiin kuitenkin ainoastaan Kurun sekä Sonkajärven alueen teille. Sonkajärven alueella mitatut tiet kuuluivat pääsääntöisesti joko Metsähallitukselle tai Metsä Groupille, mukana oli myös yksi Tornator:n omistama tie. Kurun alueella mitatut tiet kuuluivat joko Metsähallitukselle tai Metsä Groupille.



Kuva3. Kurun ja Sonkajärven tutkimusalueet

Tutkimuksessa käytetyt alueet valittiin siten, että ne poikkeavat toisistaan huomattavasti vallitsevien maalajiensa suhteen. Kurun alueella maalajit painottuvat vahvasti kalliomaahan sekä hiekkamoreeniin ja Sonkajärven alueella mitatut tiet sijoittuvat voimakkaasti turvemaille. Molemmilla alueilla sijaitsevat tiet olivat mittaushetkellä aktiivisessa yksityishenkilöiden sekä

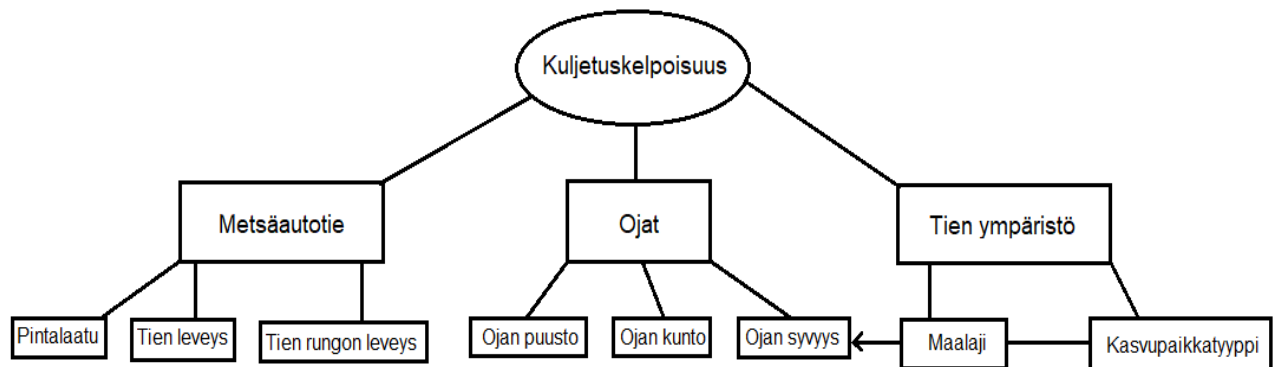
metsätalouden käytössä. Mittaukset suoritettiin vuoden 2018 syyskuun ja marraskuun välisenä aikana, tällöin sattui olemaan poikkeuksellisen kuiva ja lämmin syksy, jota edelsi todella lämmin ja vähä sateinen kesä. Teiden kuljetuskelpoisuus heikkenee suhteessa sateiden ja kertyvän kosteuden runsauteen, joten tässä tutkimuksessa näillä poikkeuksellisilla olosuhteilla voi olla huomattavakin vaikutus tuloksiin ja niiden yleistettävyyteen keskimääräisten olosuhteiden vallitessa.

2.1 Maastomittaukset

Tutkimuksessa käytettävä maastoaineisto kerättiin 18.09.2019 – 16.10.2019 välisenä aikana Ruoveden, Kurun, Sonkajärven, Valtimon ja Rautavaaran kuntien alueella. Alueilta mitattiin tuolloin yhteensä 26 tietä ja koealoja kertyi yhteensä 765, joista 474 mitattiin Kurussa ja 261 Sonkajärvellä. Tutkimuksessa käytettiin kuitenkin vain 314 mitattua koealaa, jotka sijoittuivat sekä Sonkajärven että Kurun tutkimusalueille. Tutkimuksessa käytettävät koealat valikoitiin vertailemalla koealoilla mitattuja tien tunnuksia, tavoitteena saada käytettävien koealojen välille riittävästi vaihtelua, täten minimoiden ominaisuuksiltaan hyvin samankaltaisten koealojen määrä. Tässä vaiheessa pois jätettyä osuutta koealoista käytettäisiin kuitenkin myöhemmin valmiin kuljetuskelpoisuusmallin testauksessa. Kerättyä maastoaineistoa käytettiin myös referenssiaineistona Arbonaut Oy:n kehittämän kuljetuskelpoisuusmallin jatkokehityksessä.

Maastossa kerätty aineisto koostui yhteensä yhdeksästä mitatusta ja arvioidusta tien sekä ympäristön ominaisuudesta. Osa näistä ominaisuuksista sai juoksevia arvoja ja osa taas luokiteltiin ominaisuuden hyvyden perusteella laadullisiin luokkiin.

- Kuljetuskelpoisuus
- Ajokaistan leveys
- Tien rungon leveys
- Pintalaatu
- Maalaji (vasen ja oikea)
- Kasvupaikkatyyppi (vasen ja oikea)
- Ojan syvyys (vasen ja oikea)
- Ojan kunto (vasen ja oikea)
- Ojan puusto (vasen ja oikea)



Kuva 4. Vuokaavio mitatuista ominaisuuksista ja niiden suhteista toisiinsa

Ennen maastomittausten aloittamista mitattavat tiet valikoitiin tutkimusalueilta, tavoitteena löytää teitä, jotka olisivat ominaisuuksiltaan ja liikennöintikelpoisuudeltaan vaihtelevia. Vaihtelevuutta saatiinkin mitattujen teiden välille, mutta useimmat mitatuista teistä olivat kuitenkin kunnoltaan hyviä, mihin vaikutti todennäköisesti kuluneen kesän ja syksyn vähäsateisuus.


Valituilta teiltä mitattavien koalojen vähimmäismääräksi sovittiin 20 koalaa, paitsi tien päättyessä ennen vähimmäismäärän saavuttamista. Mikäli 20 mitatun koalan aikana tien ominaisuuksissa ei tapahtunut merkittävää vaihtelua, mittaus kyseiseltä tieltä lopetettiin ja siirryttiin seuraavaan kohteeseen. Mitattavien koalojen määrälle yhdeltä tieltä ei asetettu ylärajaa, kunhan vain nähtiin tien ominaisuuksien vaihtelevan tarpeeksi, että mittauksia olisi järkevää jatkaa. Suurin määrä mitattuja koaloja yhdeltä tieltä oli 77.

Koalojen jono sijoitettiin siihen osuuteen tietä, jossa tien ominaisuuksissa todennäköisimmin esiintyi tutkimuksen kannalta mielenkiintoista ominaisuuksien vaihtelua. Koalajonojen sijoittamisen pohjatietona käytettiin maaperäkarttaa sekä maastossa tehtyjä tien kunnan havaintoja. Koalojen väliksi oli sovittu 24 metriä, joka vastasi Arbonaut Oy:n aiemmin analysoimien tiesegmenttien pituutta, tällöin yksi mitattu koala sijoittuisi aina yhdelle analysoidulle tiesegmentille.

Mittausten aikana jokaisen mitatun koalan tarkka sijainti määritettiin ja tallennettiin käyttäen Trimble:n tarkkuus-GPS:ää, jonka tarkkuus on yleensä alle 0,5 m. Koalojen sijaintitiedon tarkkuuden parantamiseksi GPS:ään kiinnitettiin lisäantenni. Teiden tunnukset mitattiin koalan keskipisteeksi asetetun GPS:n ympäriltä. Jokaiselle mitatulle koalalle annettiin koalakohtainen tunnus, joka on muotoa "1.11", jossa ensimmäinen luku viittaa

mitattuun tiehen ja pisteen jälkeinen luku viittaa kyseisellä tiellä mitattuun koealaan. Mittausten jälkeen GPS:n taltioimat koordinaatit siirrettiin tietokoneelle ja jälkikorjattiin Pathfinder Office-ohjelmistolla. Datan jälkikäsittely parantaa koealojen keskimääräistä paikannustarkkuutta. Jälkikorjatut koealojen sijainnit muunnettiin tämän jälkeen pistemuotiseksi shapefile-tiedostoiksi, jotta koealoja voitaisiin helposti tarkastella eri paikkatietojärjestelmissä.

Ajokaistan leveys määritettiin 50 senttimetrin luokissa ja mittaus suoritettiin mittakepillä johon 50 senttimetrin segmentit oli merkattu. Mittaus tapahtui mittaamalla tien pinnalla olevan murskekerroksen leveys laidasta laitaan, kuten kuvassa 5 on havainnollistettu. Jos mittausvaiheessa ajokaistan leveys jäi kahden 50 senttimetrin segmentin väliin pyöristettiin mittaustulos alaspäin edelliseen 50 senttimetrin luokkaan. Jos pintamursketta ei ollut kunnolla havaittavissa mittaus suoritettiin ajourien ulkoreunasta ulkoreunaan.



Kuva 5. Tieltä mitattuja tunnuksia. 1: Tien rungon leveys, 2: Ajokaistan leveys, 3: Ojan syvyys (mitattiin molemmilta puolilta)

Tien rungon leveys määritettiin myös 50 senttimetrin luokissa ja mittaus suoritettiin samalla mittakepillä kuten ajokaistankin leveyden mittaus. Tien rungon leveyden nähtiin alkavan ja päättyvän siihen pisteeseen, josta tie alkoi laskemaan ojaan (Kuva 5). Jos mittausvaiheessa tien rungon leveys jäi kahden 50 senttimetrin segmentin väliin pyöristettiin mittaustulos tulos alaspäin, kuten ajokaistankin leveyttä mitatessa.

Ojien syvyys määritettiin viiden senttimetrin tarkkuudella ja mittaus suoritettiin rullamitalla. Syvyys mitattiin tien molemmilta puolilta ja samalta linjalta koealan keskipisteestä katsoen.

Ojan syvyyden aloituspiste oli ojan pohja ja syvyyden päättymispiste oli tien pinnan tasalla. Jos mittausvaiheessa ojan syvyys jäi kahden viiden senttimetrin segmentin välille, pyöristettiin mittauksena alaspäin. Ojan puuttuessa tai tien penkan laskiessa suoraan maastoon merkittiin ojan syvyydeksi nolla. Rumpujen sijainti määritettiin tarkastelemalla, onko rumpua näkyvässä 12 metrin säteellä mitattavan koealan keskipisteestä. Rummun sattuessa koealalle merkittiin se raksilla maastolomakkeeseen.

Ojien kunto arvioitiin tien molemmilta puolilta ja arviointi tapahtui mitattavan koealan sekä seuraavan koealan väliseltä matkalta. Ojan kunnon luokittelussa käytettiin kolmea luokkaa: hyvä, tyydyttävä ja huono. Käytettyjä luokittelun kriteereitä olivat ominaisuudet, jotka vaikuttavat ojan kykyyn siirtää vettä, eli: ojan puusto, ojan umpeen kasvaneisuus ja muut tukokset sekä ojan kaltevuus pituussuunnassa. Apuna ojien kunnon luokittelussa käytettiin Korpilahti 2008 ohjeistusta.

Ojan puusto mitattiin ottamalla ojan pohjalta pyörähdyskoeala käyttäen 2,5 metrin sädettä. Puuston mittaus suoritettiin suorassa linjassa koealan keskikohtaan nähden sekä tien vasemmalta että oikealta puolelta. Pyörähdyskoealan puustosta mitattiin puiden keskiarvoinen pituus ja lukumäärä. Puiden lukumäärään laskettiin kaikki pyörähdyskoealan sisälle jäävät puut ja puiden keskiarvoinen pituus määritettiin valitsemalla silmämääräisesti keskiarvoa edustava puu ja mittaamalla tämän pituus mittanauhalla. Pyörähdyskoealan sisään jääneen puuston lukumäärälle laskettiin kerroin 'A', jolla yksittäisten koealojen puuston määrä voidaan muuttaa hehtaarikohtaiseksi. Kerroin 'A' on 2,5 metrin säteellä 509,296. (kaava 1)

$$A = 10000/(\pi \cdot 2,5^2)$$

(1)

Mitattavaa koealaa ympäröivän maaston maalaji määritettiin sekä tien vasemmalta että oikealta puolelta. Määrittäminen tapahtui kaivamalla kivennäismaanäyte kenttälapiolla joko ojan ulkopenkasta tai tien välittömästä läheisyydestä viereisen metsän puolelta. Maalajin määrittämiseen oli kuusi luokkaa: savimaa, hienoainesmoreeni, hiekkamoreeni, hiekka/sora, kalliomaa ja turve. Maalajin määrittämisen apuna käytettiin metsämaan muokkausoppaassa käytettyjä menetelmiä (Luoranen ym. 2007) Maalajin määrittäminen jokaiselta koealalta oli hidasta, joten se suoritettiin jokaisen koealajonon ensimmäiseltä koealalta ja siitä eteenpäin

joka viidenneltä koealalta tai ympäröivän maaston ominaisuuksien muuttuessa. Apuna maalajin määrittämisessä käytettiin maaperäkarttaa, jonka todettiin olevan hyvin luotettava apuväline. Kasvupaikkatyyppi määritettiin myös tien molemmin puolin. Kasvupaikkatyyppien määrittäminen tapahtui tarkastelemalla metsän puustoa sekä kenttäkerroksen kasvillisuutta. Apuna käytettiin ”Metsätyypit – opas kasvupaikkojen luokitukseen” kirjaa (Hotanen ym. 2013). Turvemaita ei luokiteltu tarkemmin eri turvemaatyyppeihin.

Kuljetuskelpoisuuden määrittäminen tapahtui mitattavan koealan ja seuraavan koealan väliseltä tiesegmentiltä. Kuljetuskelpoisuuden luokkina käytetään neljää Metsätehon määrittämää kuljetuksen ajankohdan luokkaa: talvi, kesä, kuiva kesä ja kelirikko. Tämän tunnuksen määrittämiselle ei ollut eksakteja raja-arvoja, joiden mukaan luokittelu olisi tapahtunut. Kuljetuskelpoisuuden määrittäminen tapahtui maastossa tarkastelemalla tien yleiskuntoa (pinnan tasaisuus ja pintamurskeen laatu), ympäristöä (maalaji ja ympäristön pinnanmuodot), ojien kuntoa (veden poistuminen tien rungon läheisyydestä) ja sen hetkistä sään vaikutusta tiehen. Kuljetuskelpoisuuden luokan lisäksi merkittiin, oliko tie mittaushetkellä kuljetuskelpoinen vai ei.

Tien pintalaadun määrittäminen tapahtui mitattavan koealan ja seuraavan koealan väliseltä tien segmentiltä. Käytettyjä pintalaadun luokkia oli kolme: hyvä, tyydyttävä ja huono. Luokittelun kriteereitä oli neljä: tien profiili, tien pinnan tasaisuus sekä uraisuus ja kulutuskerros. Profiililla tarkoitetaan tien kuperuutta tai koveruutta, eli toimiiko tien profiili veden poistajana vai kertyykö vettä ajoradalle. Pinnan tasaisuus kertoo, onko tiessä painumia, uria ja reunapalteita, jotka vaikuttavat tien kuivamiseen tai veden kertymiseen ajoradalle sekä tien pinnalle. Kulutuskerroksella tarkoitetaan pintamurskekerroksen paksuutta ja laatua. Apuna kriteerien tulkinnassa ja pintalaadun luokittelussa käytettiin Metsätehon määrittämiä luokkia (Korpilahti 2008). Pintalaadun määrittäminen on hyvin subjektiivista arviointia ja sopivan luokan määrittäminen yksiselitteisesti ei ole helppoa

Maastossa mitattujen teiden tunnusten lisäksi tutkimuksen käytössä oli kaksi erilaista kaukokartoitusaineistoa. Yhtenä aineistona oli Arbonaut Oy:n luoma maaston muotoihin perustuva kosteusindeksin kertova rasteritaso. Jokaiselle koealalle laskettiin tältä rasteritasolta ArcMap ohjelmistossa keskiarvoinen kosteusindeksi 0,5 hehtaarin alalta. Tällä kosteusindeksin arvolla saatiin käsitys, kuinka suuren kosteuden paineen ympäröivän maaston pinnanmuodot aiheuttavat tielle.

Toinen potentiaalinen kaukokartoitusaineisto oli auringonsäteilyindeksi, millä on vaikutusta tien pinnan kuivumisen nopeuteen. Säteilyindeksiä oli tarkoitus käyttää koealoilla, joiden veressä oli suoritettu avohakkuu ja tie oli paljastunut auringon kuivattamisen vaikutukselle. Tätä aineistoa ei kuitenkaan hyödynnetty tässä tutkimuksessa, koska koealojen mittausajankohtana oli jo valmiiksi poikkeuksellisen kuivaa. Tämän kuljetuskelpoisuusluokittelua potentiaalisesti parantavan tason käytön seurauksena luotavien mallien tuottamat tulokset olisivat mahdollisesti olleet liian ”hyviä” suhteessa todellisuuteen, kerta mittaushetkellä teiden tila oli jo poikkeuksellisen hyvä vähäisten sateiden vuoksi.

2.3 Muuttujien arvojen normalisointi ja indeksien laskenta

Aineiston muuttujien arvot olivat joko jatkuvia numeerisia arvoja tai laadullisia luokka-arvoja. Arvojen normalisointi helpotti analysointia ja oli eräiden muuttujien kohdalla välttämätöntä, sillä näiden muuttujien arvoille ei ollut selkeitä rajoja. Ojista laskettiin jokaiselle koealalle ojaindeksi-arvot, sillä ojista mitattuja ominaisuuksia (laatu & syvyys) oli järkevämpää käsitellä yhdistettynä muuttujana, joka ilmaisee ojien kokonaislaadun.

Kosteusluokkien normalisointi kosteusindekseiksi tapahtui taulukon 1 mukaan. Kosteusindeksejä määrittäessä kosteusluokan ylärajaksi asetettiin arvo nolla, sillä sen tulkittiin olevan jo kuiva, jolloin nolasta suuremmat arvot eivät enää vaikuttaneet kuivuuteen kasvavasti. Kosteusluokan arvossa -500 oli jo havaittavissa ympäröivän maaston kosteuden lisääntymistä. Kosteusluokka-arvojen alarajana pidettiin -2000, sillä tätä alhaisemmillä kosteusluokan arvoilla ei ollut enää havaittavissa merkittävää ympäristön kosteuden lisääntymistä. On huomattava, että edellä mainitut raja-arvot soveltuvat vain Suomen oloihin.

Taulukko 1. Kosteusluokkien arvojen mukaan määritetty kosteusindeksi

Kosteusluokka	kosteusindeksi
0 =<	0
-1; -300	0,1
-301; -500	0,3
-500; -700	0,4
-701; -900	0,5
-901; -1100	0,6
-1101; -1400	0,7
-1401; -1700	0,8
-1701; -1999	0,9
-2000 >=	1

Ojatietoja mitattiin useita, mutta kaikki kuitenkin liittyivät ojan kokonaislaatuun ja kykyyn siirtää veden aiheuttama kosteuden paine pois tienrunгон läheisyydestä. Ojaindeksin laskentaa varten ojan kuntoluokista muodostettiin laatukertoimet taulukon 2 mukaan. Samalla ojien syvyydetkin normalisoitiin syvyysluokkiin taulukon 3 mukaan, jotta pystyttiin laskemaan tien molempien puolien ojien yhteinen ojariski-indeksi. Verrattuna vaihtoehtoihin ojan ominaisuuksien tarkasteluihin, laskemalla ojariski-indeksi jokaiselle koelalle saavutettiin paras korrelaatio muiden tien ominaisuuksien kanssa. Yhteisen ojariski-indeksin laskenta tapahtui kertomalla määritetyt laatukertoimet ja syvyysluokat keskenään ja ottamalla näistä keskiarvo (kaava 2).

Taulukko 2. Ojien kunnan mukaan määritetty kerroin

Ojakunto	Kerroin
Hyvä	0,2
Tyydyttävä	0,5
Huono	0,8

Taulukko 3. Ojien syvyyden mukaan määritetty oja luokka

Ojan syvyys (cm)	Ojaluokka
0 - 10	1
11 - 25	0,9
26 - 50	0,7
51 - 75	0,5
76 - 100	0,3
100 <	0,2

$$B = \frac{(X_v * Z_v + X_o * Z_o)}{2} \quad (2)$$

jossa:

B = ojariski-indeksi

X_v = vasemman ojan syvyys

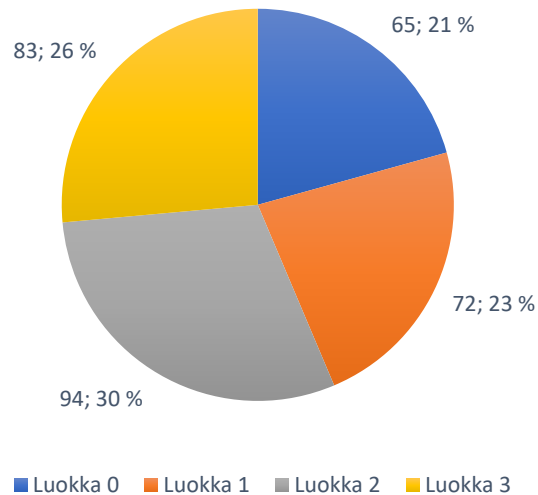
X_o = oikean ojan syvyys

Z_v = vasemman ojan kuntokerroin

Z_o = oikean ojan kuntokerroin

2.4 Tutkimukseen valittu aineisto

Tutkimuksen mallinnusvaiheeseen valikoitiin 765 koealasta yhteensä 314, joita käytettiin mitattujen tunnusten analysointiin sekä lopullisen kuljetuskelpoisuusmallin muodostamiseen. Loppuja koealoja käytettiin mukana lopullisen mallin testauksessa. Tutkimukseen valittujen koealojen valikointi tapahtui manuaalisesti, katsomatta koealojen sijainteja. Valikoinnissa pyrittiin valitsemaan tasainen määrä koealoja kaikista kuljetuskelpoisuusluokista, jolloin koealat jakautuivat kuljetuskelpoisuuden suhteen kuvan 6 mukaisesti. Valikoinnin tavoitteena oli tiivistää käytettävää aineistoa ja poistaa useasti toistuvat tunnuksien arvot. Tällöin käytetyssä aineistossa kaikkien tunnusten arvojen ääripäät sekä keskiarvot saatiin katettua tasaisesti, jolloin yhdessäkään tapauksessa suuri keskiarvoisten tunnusten määrä ei häivyttänyt ääripäiden merkitystä. Kuljetus kelpoisuudet muutettiin numeerisiksi tunnuksiksi, joissa luokka 0 = talvi, luokka 1 = kuiva kesä, luokka 2 = kesä, luokka 3 = kelirikko.



Kuva 6. Analysointiin ja mallinnukseen valitun aineiston kuljetuskelpoisuusluokkien jakautuminen sekä määrällisesti että prosentuaalisesti. Luokat ilmaisevat suositeltua kuljetuksen ajankohtaa kyseisellä tiellä: luokka 0 = talvi, luokka 1 = kuiva kesä, luokka 2 = kesä, luokka 3 = kelirikko.

Koealoilta kerätty aineisto koostui yhteensä 16 mitatusta sekä määritetystä tunnuksesta. Osa mitatuista tunnuksista karsittiin heti aluksi pois, sillä niiden ei nähty tuovan merkittävää lisäarvoa muiden vastaavien tunnusten ohella tai pois jätettyjen muuttujien mittausten tulokset olivat liian vajaita käytettäväksi. Käytettäviä tien tunnuksia vähensi myös aiemmin mainittujen ojariski-indeksien lasku, jossa yhdistettiin useammat erikseen mitatut ojan tunnuksia yhdeksi.

Pois jätettyjä muuttujia olivat ojien puusto, tien rungon leveys, rumpujen sijainti, sekä kasvupaikkatyyppi. Etenkin tien rungon leveys olisi ollut tärkeä lisä käytettävään aineistoon, mutta rungon leveys tuli mukaan mitattaviin tunnuksiin vasta puolella välissä maastomittauksia, joten tien rungon leveyden dataa ei olisi ollut käytössä kaikille analysoinnissa ja mallissa käytettäville koealoille. Analysoinnissa hyödynnetyt menetelmät ja mallin muodostaminen vaativat, että kaikista käytettävistä koealoista oli saatavilla kaikki samat tiedot, jolloin tien rungon leveyden tietojen puuttuminen osalta koealoista olisi tehnyt analysoinnista haastavaa.

Ojien puuston mittaus tuli myös myöhässä mitattavaksi tunnukseksi, mutta tämä ollut yhtä merkittävä puute kuin rungon leveyden tietojen puuttuminen, sillä ojan puuston määrä heijastui jo valmiiksi ojariski-indeksin arvoissa. Rumpujen sijainti jätettiin myös pois aineistosta sen epävarmuuden takia, sillä rumpujen sijainteja määrittäessä, jos rumpua ei

löytynyt tai veden ei huomattu virtaavan tien ali, ei rumpua tällöin merkattu olevan, vaikka rumpu saattoi olla olemassa, mutta oli vain tukossa tai piilossa ojan penkan runsaassa kasvillisuudessa.

Viimeinen pois jätetyistä tunnuksista oli kasvupaikkatyyppi, koska sen nähtiin olevan voimakkaasti sidonnainen alueen kosteuteen sekä maalajiin. Metsätyyppiopissa kasvupaikkatekijät jaetaan kahteen ryhmään, primaarisiin ja sekundaarisiin. Primaarisilla tekijöillä tarkoitetaan kasvupaikan pysyviä ja tilapäisistä muutoksista riippumattomia ominaisuuksia. Niitä voivat olla erityisesti maaperän laatuun liittyvät tekijät, kuten kivennäismaan vedenpidätys- ja vedenjohtokyky sekä kationinvaihtokyky. (Hotanen ym. 2013 s19).

Jäljelle jääneet tunnuksset, joita lähdettiin analysoimaan mallissa käytettävyyden näkökulmasta, olivat: tien ajokaistan leveys, tien pintalaatu, maaperä (oikea ja vasen), ojariski-indeksi, kosteusindeksi ja ei kuljetuskelpoinen koeala (arvoilla 0 ja 1). Ennen tunnusten analysointeja suurimmat odotukset merkittävyyden näkökulmasta asettuivat tien leveyteen ja kosteusindeksiin.

3 MENETELMÄT

Valikoitua aineistoa tarkasteltiin ensin yksinkertaisten korrelaatioiden sekä merkittävyyksien kautta ja tästä siirryttiin tarkastelemaan yksittäisten muuttujien suhteita toisiin käytettävissä oleviin muuttujiin. Korrelaatio taulukko luotiin käyttäen IBM SPSS Statistics-ohjelmaa, joka myös merkkää automaattisesti merkittävät muuttujien keskeiset korrelaatiot. SPSS käyttää Pearsonin korrelaatiota, joka mittaa kahden muuttujan välisen lineaarisen suhteen voimakkuutta ja suuntaa.

Selvitettyä kaikkien muuttujien väliset korrelaatiot, tarkasteltiin yksittäisten muuttujien välisiä suhteita muodostaen laatikko-janakuvaajia (eng. boxplot, box-and-whisker plot). Kuvaajia käytetään menetelmänä dataryhmien graafiseen kuvaamiseen hyödyntäen niiden kvartiileja. Laatikoiden ulkopuolella olevat viivat osoittavat datan arvojen vaihtelevuutta ylemmän ja alemman kvartiiliin ulkopuolella. Pisteet kuvastavat kvartiilien ylä- ja alarajoista voimakkaasti

poikkeavia arvoja (liitteet 1, 2 & 3). Laatikko-janakuvaajia tehtiin merkittävän korrelaation saavuttaneista muuttujapareista, tavoitteena löytää selkeää suuntaa arvojen välillä, esimerkiksi kuinka kosteusindeksin arvot jakautuvat eri kuljetuskelpoisuusluokille tai kuinka mitattujen ojien syvyys jakautuu eri maalajeille.

Käytettävien muuttujien korrelaatiot testattiin vielä ristiin käyttäen VIF-testiä (eng. variance Inflation Factor). VIF-testissä mitä suurempi saatu arvo on sitä vähemmän luotettavia regressiosta saadut tulokset ovat, jolloin korkean VIF-arvon saanut muuttuja/selittäjä voi olla syytä poistaa tai korvata regressiomallissa. Suorittamalla VIF-testi muuttujille saadaan selville mahdollisesti merkittävät tunnusten väliset korrelaatiot, jolloin näihin pystytään tarvittaessa reagoimaan ja täten varmistetaan, että lopullisissa tuloksissa ei ilmene merkittävää multikolinearisuutta.

Ensimmäisenä menetelmänä kuljetuskelpoisuusmallien muodostamisessa käytettiin yksinkertaista lineaarista regressiomallia. Linearisessa regressiomallinnuksessa käytettiin askeltavaa menetelmää (eng. Stepwise selection), joka automaattisesti määrittää mallin kannalta tärkeät selittäjät. Kaikille kuljetuskelpoisuusluokille muodostettiin yhteinen lineaarinen regressiomalli, jonka tuloksena saatiin juoksevia arvoja, jotka vaihtelivat luokkien ääripäiden arvojen välillä (0 → 3). Luokkaennusteiden varmuutta voitiin tarkastella helposti saatujen arvojen avulla, suhteessa siihen, kuinka tarkasti luokkaan asettuvan arvon ennuste sai. Esimerkiksi arvo 1,1 kertoo kyseisen koealan suuresta todennäköisyydestä kuulua kuljetuskelpoisuus luokkaan yksi, mutta arvossa 2,5 on selkeää epävarmuutta, kuuluuko kyseinen koeala kuljetuskelpoisuusluokkaan kaksi vai kolme. Saaduille arvoille voidaan asettaa ehtoja, milloin kahden luokan välinen arvo pyöristyy alempaan tai ylempään kuljetuskelpoisuusluokkaan. Näin voidaan vaikuttaa siihen, että mallin väärä ennuste antaa tulokseksi todennäköisemmin huonomman kuljetuskelpoisuusluokan, eikä ylioptimistista tulosta. Lineaariset regressiot yleisesti noudattavat muotoa, joka on esitetty kaavassa 3.

$$Y = b_1 + b_2x_1 + b_3x_2 + b_4x_3 + \dots + \varepsilon_i \quad (3)$$

Jossa:

Y= haluttu tunnus

b_i = vakiokerroin

x_i = selittäjä

ε_i = mahdollinen virhetermi

Toinen kuljetuskelpoisuutta ennustava malli muodostettiin ordinaaliregressiolla, jota yleisesti käytetään ennustamaan tasoistaan riippuvaisten muuttujien käyttäytymistä riippumattomien selittäjien avulla. Tavoitemuuttujan oletetaan olevan peräkkäinen sekä jokaisen tason täytyy olla toisistaan riippuva (huonompi tai parempi). Muuttuja voi olla joko numeerinen tai merkkijono. Ennustamisessa käytettävät riippumattomat selittäjät voivat olla jatkuvia tai kategorisia, joita molempia esiintyi tämän tutkimuksen aineistossa. Ordinaaliregressiomallinnuksessa käytetään kaikkia samoja selittäjiä kuin lineaarisessa regressiomallinnuksessa, mutta osalle selittäjistä suoritettiin uudelleen arvojen normalisointi mallin käytettävyyden ja tulkitsemisen helpottamiseksi. Ordinaaliregressio sopii hyvin kerätyn aineiston tulkintaan tavoitemuuttujan parempiin ja huonompiin kuljetuskelpoisuusluokkiin järjestyksen takia. Ordinaaliregressio tuottaa yhden regressiomallin kuten lineaarinenkin regressio, mutta tästä saatu tulos on Y-arvo (kaava 3), joka ei ole suoraan verrattavissa alkuperäisiin luokkiin. Tätä koealakohtaista Y-arvoa vertaamalla ordinaaliregression myös antamiin luokkaparin Z-arvoihin, voidaan jokaiselle luokkaparille laskea todennäköisyys (kaavat 4 - 6) ja johtaa tästä edelleen luokkakohtainen todennäköisyys (kaavat 7 - 10).

$$P_{0 \text{ tai } 1} = \frac{1}{1+e^{-(Z_1-Y)}} \quad (4)$$

$$P_{1 \text{ tai } 2} = \frac{1}{1+e^{-(Z_2-Y)}} \quad (5)$$

$$P_{2 \text{ tai } 3} = \frac{1}{1+e^{-(Z_3-Y)}} \quad (6)$$

Joista saadaan johdettua luokkien 0, 1, 2 ja 3 todennäköisyydet:

$$P_0 = P_{0 \text{ tai } 1} \quad (7)$$

$$P_1 = P_{1 \text{ tai } 2} - P_0 \quad (8)$$

$$P_2 = P_{2 \text{ tai } 3} - P_{1 \text{ tai } 2} \quad (9)$$

$$P_3 = 1 - P_{2 \text{ tai } 3} \quad (10)$$

Joissa:

Z_x = luokkakohtainen Z-arvo

P_0 = Luokan 0 todennäköisyys

P_1 = Luokan 1 todennäköisyys

P_2 = Luokan 2 todennäköisyys

P_3 = Luokan 3 todennäköisyys

Regressiomallien suoriutumista havainnointiin tarkastelemalla mallien oikeinennustamien tapausten osuutta, tätä kuvaavaa ristiintaulukointia sekä tästä laskettavaa kappa-arvoa (kaavat 11 & 12). Kappa-arvo on tilastollinen tunnusluku, joka tulkitsee kategoristen kohteiden välistä samankaltaisuutta. Kappa-arvo huomioi mahdollisen kohteiden välisen yhteensopivuuden sattuman kautta, toisin kuin normaali prosentuaalinen yhteensopivuus. Mallit testaan myös satunnaisotannalla valitulla testiaineistolla ja testausvaiheessa tarkastellaan samoja tunnuslukuja kuin malleja muodostettaessa.

$$ef = \frac{\sum R * \sum S}{N} \quad (11)$$

$$Kappa = \frac{\sum a - \sum ef}{N - \sum ef} \quad (12)$$

Joissa:

R = ristitaulukon rivin arvot

S = ristitaulukon sarakkeen arvot

N = arvojen kokonaismäärä

ef = odotetut frekvenssit (jokaiselle kivisyysluokalle lasketaan oma odotettu frekvenssi)

a = yhtäpitävien luokkien määrä

Molempien mallien ennustamistarkkuutta testattiin vielä suorittamalla testiluokittelu 500:lle satunnaisotannalla valitulle koealalle. Mallien testaukseen satunnaisotannalla valitut koealat otettiin kaikista mitatuista koealoista. Testaukseen valittujen koealojen muuttujille suoritettiin arvojen normalisointi sekä tarpeellisten indeksien laskenta, kuten vastaavasti mallien muodostamisessa käytetyille aineistollekin. Testauksessa ennustettiin käyttäen luotuja regressiomalleja testiaineiston koealoille uudet kuljetuskelpoisuusluokat, joita verrattiin alkuperäisiin luokkiin käyttäen samoja tunnuslukuja (kappa, luokittelu-%) ja taulukoita kuin aiemminkin.

4 TULOKSET

4.1 Ennustavien selittäjien analyysi

Valittujen muuttujien tilastollinen analysointi aloitettiin luomalla korrelaatiotaulukko. Tavoitteena oli selvittää, mitkä tien tunnuksat ovat potentiaalisesti merkittäviä muuttujia mallin kannalta ja minkä tunnusten välisiä suhteita olisi syytä tarkastella laatikko- ja kuvakaavojen avulla. Tunnuksien välisten korrelaatioiden avulla saatiin myös käsitys, onko mahdollisille selittäjille tarpeellista suorittaa VIF-testi.

Korrelaatiotaulukosta (taulukko 4) huomataan voimakkaat korrelaatiot Kuljetuskelpoisuuden sekä tunnuksien leveys, pintalaatu ja ”ei kuljetuskelpoinen” välillä. Tästä voidaan olettaa näiden tunnuksien olevan potentiaalisesti merkittäviä selittäjiä luotavissa regressiomalleissa.

Taulukosta on myös huomattavissa kohtalaista negatiivista korrelaatiota tunnuksen ”ei kuljetuskelpoinen” ja tunnusten pintalaatu (-0,726) sekä leveys (-0,557) välillä. Tien leveys sekä pintalaatu korreloivat myös keskenään kohtalaisella tasolla (0,552). Näistä voidaan todeta sekä tien pintalaadulla että leveydellä olevan selkeä yhteys tien kuljetuskelpoisuuteen. Ojariski- sekä kosteusindeksillä ja maalajilla ei ole yhtä voimakasta korrelaatiota kuljetuskelpoisuuteen kuin alussa olisi voinut olettaa. Ojariski-indeksi kasvaa, kun ojien laatu ja syvyys laskee, jolloin oletettavasti huonommilla maalajeilla (turve ja hienoainesmoreeni) ojariski-indeksi on pienempi, mikä tarkoittaa ojien parempaa kuntoa ja suurempaa syvyyttä. Huono maalaji kasvattaa tien laadun standardeja, jotta voidaan saavuttaa hyvä kuljetuskelpoisuus. Vastapainona parempien maalajien (hiekkä ja sora) alueilla ojien ei tarvitse olla syviä, sillä vesi ei jää seisomaan lähelle pintaa karkeammilla maalajeilla.


Taulukko 4. Taulukossa näkyvät muuttujien väliset korrelaatiot. Negatiivisissa korrelaatioissa rivissä olevan muuttujan arvon kasvaminen aiheuttaa sarakkeessa olevan muuttujan arvon alenemisen.

	Kuljetus- kelpoisuus	Leveys	Pintalaatu	Ojariski- indeksi	Kosteus- indeksi	Ei kuljetus- kelpoinen	Maalaji
Kuljetuskelpoisuus	1	0,702	0,785	-0,135	-0,220	-0,787	-0,183
Leveys	0,702	1	0,552	-0,151	-0,244	-0,557	-0,210
Pintalaatu	0,785	0,552	1	-0,308	-0,170	-0,726	-0,376
Ojariski-indeksi	-0,135	-0,151	-0,308	1	-0,025	0,106	0,544
Kosteusindeksi	-0,220	-0,244	-0,170	-0,025	1	0,247	0,028
Ei kuljetuskelpoinen	-0,787	-0,557	-0,726	0,106	0,247	1	0,160
Maalaji	-0,183	-0,210	-0,376	0,544	0,028	0,160	1


Korrelaation suhteen kiinnostavista tunnuspareista tehtiin kuvaajia, jotta nähtäisiin kuinka kahden tunnuksen arvot jakautuvat suhteessa toisiinsa, eli kuinka hyvin korrelaatio on arvojen/luokkien suhteen havaittavissa. Kuvassa 7 nähdään selkeä trendi ajokaistan leveyden vaikutuksesta kuljetuskelpoisuuteen. Suurin osa mitattujen teiden leveyksistä asettui 3 – 4 metrin luokkiin, mikä huomataan myös kuljetuskelpoisuusluokkien hajontana näiden leveyksien suhteen. Leveyksien ääripäiden arvoista (<3 & ≥4,5) nähdään hyvin tien leveyden tärkeys kuljetuskelpoisuudessa.

Kuvassa 8 nähdään myös selkeästi, kuinka pintalaadun luokat jakautuvat suhteessa kuljetuskelpoisuusluokkiin. Heikko (1) ja hyvä (3) pintalaatu asettuvat selkeästi vastaamaan kuljetuskelpoisuusluokkien ääripäitä ja pintalaadun luokassa 2 (tydyttävä) ilmenee selkeää

hajontaa eri kuljetuskelpoisuusluokissa, eli kyseinen pintalaatu kattaa tapauksia kaikista kuljetuskelpoisuusluokista, mutta painottuu kuitenkin luokkiin 1 (kuiva kesä) ja 2 (kesä).



Kuva 7. Laatikko-janakuvaaja kuljetuskelpoisuusluokkien suhteesta tien leveyteen



Kuva 8. Laatikko-janakuvaaja esittää kuljetuskelpoisuusluokkia tien pintalaadun luokkien suhteen.

Laatikko-janakuvaajia muodostettiin lisäksi kuljetuskelpoisuudelle ja kosteusindeksille (liite1), leveydelle ja pintalaadulle (liite2) sekä maalajille ja ojariski-indeksille (liite3). Kuljetuskelpoisuuden ja kosteusindeksin välille muodostetusta kuvaajasta huomataan, kosteusindeksien arvojen hyvin heikko jakautuminen kuljetuskelpoisuusluokkien kanssa. Tämä kuvaaja (liite 1) havainnollistaa kosteusindeksin ja kuljetuskelpoisuusluokkien välillä olevan hyvin heikko suhde, jossa ainoastaan kosteusindeksin arvo 1 (suurin kosteus) asettui heikompien kuljetuskelpoisuusluokkien tasolle.

Pintalaadun ja leveyden suhteen (liite 2) oli havaittavissa selkeää jakautumista kapeiden teiden ja huonomman pintalaadun sekä leveiden teiden ja paremman pintalaadun välillä. Tien leveyden ääripäät asettuvat hyvin pintalaadun luokkiin hyvä ja huono, mutta kuten kuljetuskelpoisuudenkin tilanteessa oli havaittavissa tien leveyden keskimääräiset luokat (3 – 4 metriä) jakautuvat kaikkiin pintalaatuluokkiin.

Ojariski-indeksin ja maalajien välinen laatikko-janakuvaaja (liite 3) osoittaa hyvin aiemmin esitetyn oletuksen maalajin ja ojan syvyyden välisestä tärkeydestä oikeaksi. Kuvaajasta huomataan ojariski-indeksin kasvavan (paranevan) selkeästi siirryttäessä karkeammalle

maalajille, mikä kertoo, karkeammilla maalajeilla olevan yleisesti matalammat ja ”huonokuntoisemmat” ojat (korkea ojariski-indeksi) kuin hienojakoisilla kivennäismailla ja turvemaille. Hiekkamoreenin (maalaji 3) vastaavat ojariski-indeksit jakautuvat koko skaalan alueelle, mutta painottuvat arvoihin (0,4 – 0,6).

Tunnusten välisissä korrelaatioissa havaittiin muutamia korkeita arvoja, joten regressiomalleissa käytettäville tunnuksille tehtiin VIF-testi, jolla saadaan selville, onko tuloksissa riskiä ilmetä multikolinearisuutta (taulukko 5). Yleisenä sääntönä VIF-arvoissa voidaan pitää arvoa 2,5, jonka ylittäessä lopullisessa tuloksessa voi mahdollisesti esiintyä multikolinearisuutta. Yli viiden (5) arvot kertovat jo suuresta riskistä, että tuloksissa esiintyy multikolinearisuutta. Taulukosta 5 kuitenkin huomataan VIF-arvojen olevan pienempiä kuin viisi ja yhtä lukuun ottamatta pienempiä kuin 2,5, mutta moni arvo kuitenkin on lähellä arvoa 2,5. Tästä voimme todeta malleista saatavien tulosten olevan luotettavia ja multikolinearisuuden riskin olevan tässä tapauksessa hyvinkin pieni.

Taulukko 5. Malleissa käytettävien muuttujien väliset VIF-arvot.

	Leveys	Pintalaatu	Ojariski	Kosteusindeksi	Ei kuljetuskelpoinen
Leveys	-	2,385	1,144	1,068	2,250
Pintalaatu	1,496	-	1,029	1,089	1,479
Ojariski	1,585	2,272	-	1,087	2,329
Kosteusindeksi	1,554	2,527	1,142	-	2,359
Ei kuljetuskelpoinen	1,488	1,560	1,112	1,072	-

4.2 Regressiomallit

Regressiomallien luonnissa päädyttiin pudottamaan pois edellä mainituista tunnuksista, kosteusindeksi, sillä se ei statististen testien mukaan ollut millään muotoa merkittävä selittäjä mallissa – mallin ennustustarkkuuskin itseasiassa parani hieman, kun kosteusindeksi poistettiin. Ojariski-indeksi ei ollut tilastollisesti merkittävä muuttuja ja askeltava menetelmä olisi pudottanut sen mallista pois kosteusindeksin lisäksi. Ojariski-indeksi nähdään kuitenkin yleisesti merkittävänä tunnuksena, joten se päätettiin pitää yhtenä mallin selittäjistä. Lineaarisen regressiomallin perusmuoto esitettiin aiemmin kaavassa 1 ja valitun aineiston pohjalta muodostetun lineaarisen mallin selittäjien vakiokertoimet saadaan kertoimet-taulukosta 6. Lopullinen malli on esitetty kaavassa 13.

Taulukko 6. Linearisessa mallissa käytettävät selittäjät, näiden kertoimet ja selittäjien merkitsevyysaste

Selittäjät	Kertoimet	Keskivirhe	Merkitsevyysaste
Vakio	-1,632	0,279	0,000
Ojariski-indeksi	0,157	0,142	0,270
Pintalaatu	0,617	0,065	0,000
Ei kuljetuskelpoinen	-0,767	0,095	0,000
Tien leveys	0,653	0,070	0,000
Maalaji	0,060	0,029	0,035

$$Kulj. = -1,632 + 0,157 * Oja + 0,617 * Pinta - 0,767 * Ei + 0,653 * Lev + 0,060 * Maa \quad (13)$$

Jossa:

Kulj. = Kuljetuskelpoisuusluokka

Oja = ojariski-indeksin arvo

Pinta = pintalaadun arvo

Ei = Ei kuljetuskelpoinen arvo (0 tai 1)

Lev = Tien leveys

Maa = Maalaji

Kaavasta 11 saadut arvot olivat jatkuvia arvoja, joille täytyi vielä suorittaa luokkiin asettelu perustuen saatuun arvoon. Luokkaan 0 (talvi) asettuivat arvot $<0 - 0,49$, luokkaan 1 (kuiva kesä) asettuivat arvot $0,500 - 1,49$, luokkaan 2 (kesä) asettuivat arvot $1,500 - 2,49$ ja luokkaan 3 (kelirikko) asettuivat arvot $>2,50$.

Lineaarinen malli onnistui ennustamaan valikoidun aineiston tapauksista 63,7% oikeisiin kuljetuskelpoisuusluokkiin ja vastaava Taulukosta 7 huomataan luokittelussa tapahtuvan sekä yli- että aliarvioita, joita edustavat riveille -2, -1 ja 1 osuvat arvot.


Taulukko 7. Ennustettujen kuljetuskelpoisuusluokkien poikkeavuus mitatuista luokista. Arvo nolla kertoo luokan ennustamisen osuneen oikein, eli mallin ennustamistarkkuus on 63,7%.

Luokan poikkeavuus	Määrä	Prosentti	Kumulatiivinen prosentti
-2	1	0,3	0,3
-1	64	20,4	20,7
0	200	63,7	84,4
1	49	15,6	100
Summa	314	100	

Ristiintaulukointeja tulkitaan seuraavasti: riveittäin olevat arvot kertovat kuinka ennustetut luokat sijoittuvat suhteessa mitatussa aineistossa olleisiin luokkiin ja sarakkeittain olevat arvot näyttävät kuinka mallin ennustamat arvot asettuvat alkuperäisiin kuljetuskelpoisuusluokkiin. Vaaka- sekä pystyriivillä olevien kuljetuskelpoisuusluokkien risteyskohdassa on oikein ennustettujen luokkien määrä. Taulukosta 8 nähdään, kuinka malli on suoriutunut kaikkien tapausten luokkakohtaisessa ennustamisessa. Kuljetuskelpoisuusluokan 3 (kelirikko) ennustaminen on onnistunut mallilta melko heikosti ja oikeinennustamis-% on vain 56,63%. Suurin vaikeus mallilla on ollut ennustaa kuljetuskelpoisuusluokkaa 1 (kuiva kesä) oikein, jonka oikeinennustamis-% on vain 27,78%. Tämä kertoo ennustettavan luokan 1 (kuiva kesä) sekoittuvan mitattuihin luokkiin 0 (talvi) ja 2 (kesä), mikä nähdään mitatun kuljetuskelpoisuusluokan 1 (kuiva kesä) rivillä olevien tapauksien jakautumisen ennusteluokkiin nolla (19kpl) sekä kaksi (33kpl). Ristiintaulukoinnista laskettu Kappa-arvo oli 0,508, mikä ilmaisee kohtalaista luokittelun onnistumista, kun on eliminoitu sattuman mahdollisuus.


Taulukko 8. Alkuperäisten ja lineaarisen mallin ennustamien kuljetuskelpoisuusluokkien ristiintaulukointi. Oikeassa laidassa olevat prosenttiarvot kertovat kuinka suuren osan malli on onnistunut ennustamaan oikein suhteessa alkuperäisten luokkien jakaumaan. Kappa 0,508.

		Ennustettu kuljetuskelpoisuus						
			0	1	2	3	Yhteensä	%
Kuljetuskelpoisuus	0	Määrä	59	6	0	0	65	90,77
	1	Määrä	19	20	33	0	72	27,78
	2	Määrä	1	9	74	10	94	78,72
	3	Määrä	0	0	36	47	83	56,63
		Yhteensä	79	35	143	57	314	
		%	74,68	57,14	51,75	82,46		63,69



Kuva 9. Kuljetuskelpoisuusluokkien kanoniset diskriminantti arvot, jotka saadaan laskettua diskriminantti funktioilla valituista selittäjistä. Eri pisteparvien värit edustavat yhteen kuljetuskelpoisuusluokkaan kuuluvia tapauksia.

Kuvasta 9 tehdyt havannot nähdään myös hyvin kuvasta 10, jossa nähdään kuinka y-akselilla olevat alkuperäiset koealojen kuljetuskelpoisuusluokat sijoittuvat x-akselilla näkyviin ennustettuihin kuljetuskelpoisuusluokkiin. Kuvasta 9 nähdään selkeästi kuinka hyvin luokan 0 (talvi) mitattujen koealat painottuvat myös ennustettuun kuljetuskelpoisuusluokkaan 0 (talvi). Luokan 1 (kuiva kesä) mitatut koealat hajoavat ennustettujen luokkien 0 (talvi) ja 2 (kesä) välille, ilman varsinaista painottumista mihinkään luokkaan, mikä huomattin myös kyseisen luokan (1) heikosta oikeinennustamis-% (taulukko 8). Kuljetuskelpoisuusluokan 2 (kesä) tapaukset hajoavat ennustettujen luokkien 1 (talvi) ja 3 (kelirikko) välille, mutta painottuvat selkeästi luokan 2 (kesä) lähistölle, mikä huomataan myös luokan 2 (kesä) korkeasta oikeinennustamis-% (taulukko 8). Kuljetuskelpoisuusluokan 3 (kelirikko) arvot painottuvat ennustettujen luokkien 2 (kesä) ja 3 (kelirikko) väliin, josta johtuu epäselvyys oikeasta luokasta. Tämä nähdään myös taulukosta 8, jossa malli on ennustanut runsaasti (43,37%) luokan 3 (kelirikko) tapauksista virheellisesti luokkaan 2 (kesä).



Kuva 10. Pisteet osoittavat kuinka kuljetuskelpoisuuden alkuperäiset luokka arvot asettuvat lineaarisen regressiomallin ennustamiin luokkiin. Jotta saavutettaisiin hyvä ennustamis-% pitäisi pisteryhmien painottua x-akselilla samoille arvoille, joilla ne ovat y-akselilla.

Ordinaaliregressiomallissa käytettiin samoja selittäjiä kuin lineaarisessa regressiomallissa. Ordinaaliregression tulosten laskeminen oli huomattavasti monimutkaisempaa kuin lineaarisessa regressiossa. Lopullinen kaava, jolla luokkien todennäköisyyksien määrittämiseen tarvittavat Y-arvot saatiin, on esitetty kaavana 14, jossa käytettävät selittäjien kertoimet on saatu taulukosta 9. Kaavassa käytettävät pintaindeksi ja maaindeksi arvot täytyi johtaa maalajin ja pintalaadun luokista (liitteet 4 ja 5) laskennan helpottamiseksi sekä kaavan selkeyttämiseksi, tämä ei vaikuttanut mallin ennustustarkkuuteen heikentävästi. Luokkatodennäköisyyksien laskentaan myös tarvittavat Z-arvot (taulukko 9) saatiin tulosteena mallin kertoimien kanssa, kun ordinaaliregressioanalyysi suoritettiin R ohjelmistolla. Kuljetuskelpoisuusluokkiin sijoittumisten todennäköisyydet laskettiin käyttäen aiemmin esitettyjä kaavoja 2 – 3.

Taulukko 9. Ordinaaliregressiomallissa käytettävät selittäjät, näiden kertoimet ja selittäjien merkitsevyysaste.

Selittäjä	Kerroin	Merkitsevyysaste
Ojariski-indeksi	0,744	0,244
Pintalaatuindeksi	-6,928	0,000
Tien leveys	3,127	0,000
Ei kuljetuskelpoinen	-3,642	0,000
Maaindeksi	-1,652	0,090
Luokkaparit:		
	Z-arvo	
0 1	-0,590	
1 2	4,616	
2 3	7,793	

$$Y = 0,7435 * Oja - 6,928 * Pinta - 3,642 * Ei + 3,127 * Lev - 1,652 * Maa \quad (14)$$

Jossa:

Y = Y-arvo

Oja = ojariski-indeksin arvo

$Pinta$ = Pintaindeksin arvo

Ei = Ei kuljetuskelpoinen arvo (0 tai 1)

Lev = Tien leveys

Maa = Maaindeksi

Ordinaaliregressio onnistui ennustamaan valikoidun aineiston tapauksista 62,7% oikeisiin kuljetuskelpoisuusluokkiin (taulukko 10). Tulokset olivat hyvin samanlaiset lineaarisen regressioanalyysin kanssa, eli malli onnistuu muuten ennustamaan kuljetuskelpoisuusluokkia hyvällä tasolla, paitsi kuljetuskelpoisuusluokkaa 1 (kuiva kesä), joka tuottaa ordinaaliregressiollekin selkeitä vaikeuksia ja oikeinennustamis-% luokalle 1 on vain 30,56%. Tässäkin tapauksessa luokka 1 sekoittuu mitattuihin luokkiin 0 (talvi) ja 2 (kesä), mikä nähdään taulukosta 11 samoin, kuten lineaarisen regressiomallin tuloksissa, eli alkuperäisen kuljetuskelpoisuusluokan 1 rivien arvoista. Ordinaaliregression tulosten ristiintaulukoinnista laskettu Kappa-arvo oli 49,7, mikä ilmaisee kohtalaista luokittelun onnistumista, samoin kuin lineaarisessakin regressiomallissa.

Taulukko 10. Ennustettujen kuljetuskelpoisuusluokkien poikkeavuus mitatuista luokista. Arvo nolla kertoo luokan ennustamisen osuneen oikein, eli mallin ennustamistarkkuus on 62,7%.

Luokan poikkeavuus	Määrä	Prosentti	Kumulatiivinen prosentti
-2	1	0,3	0,3
-1	62	19,7	20,1
0	197	62,7	82,8
1	54	17,2	100,0
Yhteensä	314	100	

Taulukko 11. Alkuperäisten ja ordinaaliregressiomallin ennustamien kuljetuskelpoisuusluokkien ristiintaulukointi. Oikeassa laidassa olevat prosenttiarvot kertovat kuinka suuren osan malli on onnistunut ennustamaan oikein suhteessa alkuperäisten luokkien jakaumaan. Kappa 0,497.

		Ennustettu kuljetuskelpoisuus						
			0	1	2	3	Yhteensä	%
Kuljetuskelpoisuus	0	Määrä	59	6	0	0	65	90,77
	1	Määrä	19	22	31	0	72	30,56
	2	Määrä	1	15	61	17	94	64,89
	3	Määrä	0	0	28	55	83	66,27
		Yhteensä	79	43	120	72	314	
		%	74,68	51,16	50,83	76,39		62,74

4.3 Mallien testaus

Mallien testaus suoritettiin 500:lla satunnaisotannalla valitulla koealalla, joille määritettiin kuljetuskelpoisuusluokat käyttäen luotuja regressiomalleja. Yleisesti ottaen mallit onnistuivat testauksessa luokkien ennustamisessa lähes samalla tasolla kuin mallien luonti vaiheessa, vaikka testiaineisto olikin ominaisuuksiltaan hieman eroava. Molemmilla malleilla ilmeni edelleen vaikeuksia suoriutua kuljetuskelpoisuusluokan 1 (kuiva kesä) ennustamisessa ja molempien mallien ennustamistarkkuus tälle luokalle jäikin vain hieman yli 20%:n (taulukot 13 ja 15).

Mallien testauksen tulokset ovat hyvin samanlaiset molemmilla regressiomalleilla kuin mallien luontivaiheessakin. Molemmat mallit onnistuvat ennustamisessa, jopa odotettua paremmin, mutta kuljetuskelpoisuusluokka 1 (kuiva kesä) tuotti mallille edelleen vaikeuksia, mikä olikin odotettavissa aiempien tulosten perusteella. Satunnaisesti valitulla aineistolla mallien luokkakohtaiset oikeinennustamis-% tasoittuivat, mikä johtunee aineiston rakenteen muuttumisesta, eli painottumisesta runsaastiin luokkiin 2 (kesä) ja 3 (kelirikko). Molempien

mallien kappi-arvotkin pysyivät tasaisina luonti- ja testausvaiheen läpi, mikä kertoo mallien suoriutuvan tasaisesti tyydyttävällä tasolla.

Lineaarisen regressiomallin ennustamistarkkuus testiaineistolla oli hieman parempi kuin mallin luonti vaiheessa, yltäen 70,6% ennustamis-%, kuten taulukosta 12 nähdään. Mallin ennustamistarkkuus oli yllättävää, sillä oletuksena oli mallin ennustamiskyvyn yltävän noin 50%:iin, kun käytettävän aineiston monipuolisuus laskee ja mukaan tulee runsaasti ominaisuuksiltaan samanlaisia koealoja, jolloin potentiaalisesti yksi väärin ennustettu koeala moninkertaistuu. Testiaineistolla lineaarinen malli onnistui paremmin kuljetuskelpoisuusluokan kolme ennustamisessa (56,63% → 71,68%), mutta luokan nolla oikeinennustamis-% laski melkein 10% (taulukko 13). Kokonaisuutena lineaarinen regressiomalli onnistui luokkien ennustamisessa hyvin ja luokkien välillä odotettua tasaisemmin ja suuri osa yli- sekä aliarvioista on selitettävissä luokan 1 (kuiva kesä) huonosta ennustustarkkuudesta. Lineaarisen mallin testausvaiheessa saavutettiin kappi-arvo 0,525, mikä on parempi kuin mallin luontivaiheessa, mutta luokittelun onnistuminen on silti vain kohtalaisella tasolla.

Taulukko 12. Linearisella mallilla testiaineistosta ennustettujen kuljetuskelpoisuusluokkien poikkeavuus mitatuista luokista. Arvo nolla kertoo luokan ennustamisen osuneen oikein, eli mallin ennustamistarkkuus on 70,6%.

Luokan poikkeavuus	Määrä	Prosentti	Kumulatiivnen prosentti
-1	63	12,6	12,6
0	353	70,6	83,2
1	84	16,8	100,0
Yhteensä	500	100	

Taulukko 13. Testiaineiston alkuperäisten ja lineaarisen regressiomallin ennustamien kuljetuskelpoisuusluokkien ristiintaulukointi. Oikeassa laidassa olevat prosenttiarvot kertovat kuinka suuren osan malli on onnistunut ennustamaan oikein suhteessa alkuperäisten luokkien jakaumaan. Kappi 0,525.

		Ennustettu kuljetuskelpoisuus				Yhteensä	%	
		0	1	2	3			
Kuljetuskelpoisuus	0	Määrä	36	8	0	0	44	81,81
	1	Määrä	14	18	57	0	89	20,23
	2	Määrä	0	17	218	19	254	85,83
	3	Määrä	0	0	32	81	113	71,68
		Yhteensä	50	43	307	100	500	
	%	72,00	41,86	71,01	81,00		70,60	

Ordinaaliregressiomalli onnistui kuljetuskelpoisuusluokkien ennustamisessa myös varsin hyvin yltäen 68,2%:n ennustustarkkuuteen (taulukko 14) ja saavuttaen kappa-arvon 0,495, joka on liki sama kuin mallin luomisen vaiheessa. Huomioitavaa on ordinaaliregressiomallin onnistuminen luokkien 2 (kesä) ja 3 (kelirikko) ennustamistarkkuudessa käyttäen testiaineistoa: luokka 2 (kesä), 64,89% → 79,92%, luokka 3 (kelirikko), 66,27% → 74,34% (taulukko 15). Kokonaisuutena ordinaaliregressiomalli onnistui luokkien ennustamisessa lineaarisen regressiomallin tavoin hyvin ja luokkien välinen ennustamistaso tasoittui. Tässäkin tapauksessa suuri osa mallin yli- ja aliarvioista on selitettävissä luokan 1 (kuiva kesä) huonosta ennustustarkkuudesta.

Taulukko 14. Ordinaaliregressiomallilla testiaineistosta ennustettujen kuljetuskelpoisuusluokkien poikkeavuus mitatuista luokista. Arvo nolla kertoo luokan ennustamisen osuneen oikein, eli mallin ennustamistarkkuus on 68,2%.

Luokan poikkeavuus	Määrä	Prosentti	Kumulatiivinen prosentti
-1	60	12	12,0
0	341	68,2	80,2
1	97	19,4	99,6
2	2	0,4	100,0
Total	500	100	

Taulukko 15. Testiaineiston alkuperäisten ja ordinaaliregressiomallin ennustamien kuljetuskelpoisuusluokkien ristiintaulukointi. Oikeassa laidassa olevat prosenttiarvot kertovat kuinka suuren osan malli on onnistunut ennustamaan oikein suhteessa alkuperäisten luokkien jakaumaan. Kappa 0,495.

			Ennustettu kuljetuskelpoisuus				Yhteensä	%
			0	1	2	3		
Kuljetuskelpoisuus	0	Määrä	36	8	0	0	44	81,81
	1	Määrä	14	18	55	2	89	20,23
	2	Määrä	0	17	203	34	254	79,92
	3	Määrä	0	0	29	84	113	74,34
		Yhteensä		50	43	287	120	500
	%		72,00	41,86	70,73	70,00		68,19

Tarkasteltaessa luokkaan 1 (kuiva kesä) kuuluvia tapauksia ordinaaliregression avulla laskettujen luokkatodennäköisyyksien suhteen, huomattiin kyseiseen luokkaan kuuluvilla tapauksilla olevan suhteellisen matalat luokkatodennäköisyydet. Useassa tapauksessa todennäköisyyksien ero toiseen luokkaan sijoittamisessa oli vain muutaman prosenttiyksikön.

Muilla luokilla luokkatodennäköisyyksien erot verrattuna toisiin luokkiin olivat selkeät, mutta todennäköisyys laski tietenkin siirryttäessä lähelle kahden luokan rajaa.

5 TULOSTEN TARKASTELU

Tutkimuksen tavoitteena oli analysoida kerättyä maastoaineistoa ja luoda tämän pohjalta kuljetuskelpoisuutta ennustava mallit, jota voitaisiin myöhemmin verrata Arbonaut Oy:n tekemään kuljetuskelpoisuusmalliin. Tässä tutkimuksessa luotavassa mallissa hyödynnetään pääasiassa maastossa mitattuja teiden ja ojien tunnuksia, joita ei ole julkisesti saatavana sekä Arbonaut Oy:n luomaa kosteusindeksiaineistoa. Aiempia kuljetuskelpoisuutta tarkastelevia tutkimuksia on toteutettu (Vuorimies ym. 2015) Suomessakin, mutta vastaavaa kuljetuskelpoisuuden mallia ei ole yritetty luoda. Luokittelujen tulosten tarkastelussa käytetään pääasiallisina tunnuslukuina oikeinennustus-% ja kappa-arvoa.

Aineistoa käsitellessä huomattiin, tien kunnan vaihtelun yksittäisen piston tai tien osuuden koealojen välillä olevan harvinaista. Tien kunnan havainnoinnista tiedetään, että tien kosteuteen vaikuttavilla ominaisuuksilla on suuri vaikutus kuljetuskelpoisuuteen, joten merkittävimpinä tekijöinä voidaan pitää tien leveyttä, kosteusindeksiä, pintalaatua, ojien syvyyttä ja maalajia. Maalajin ja ojien syvyyden arvot vaihtelevat eniten yksittäisen tien koealojen välillä. Kerätyn aineiston maalajitietojen perusteella voidaan sanoa, että maaperäkarttaan voidaan luottaa suurissa määrin, varsinkin alueilla, joissa kartan tarkkuus on 1:20 000 tai 1:50 000. Tutkimuksessa käytetyt ojien laadut on määritetty maastomittauksilla, mutta niitä pystytään määrittämään suhteellisen luotettavasti myös kaukokartoitusaineistoilla ja Kiss ym. (2015) tutkimuksessa onnistuttiin määrittämään ojien kunto 60 % tarkkuudella käyttäen tiheäpulsista lentolaserkeilausaineistoa.

Tilastollisten analyysien tuloksista huomataan tien leveyden sekä pintalaadun olevan selkeästi merkittävimpiä muuttujia sekä selittäjiä malleja muodostettaessa. Selittäjä ”ei kuljetuskelpoinen” toimi mallissa ohjaavana selittäjänä, joka auttoi määrittämään millaisilla ominaisuuksien tasoilla tie ei enää ole kuljetuskelpoinen. Yksi merkittävä ominaisuus voisi olla myös tien rungon leveys, mutta tässä tutkimuksessa kyseiseltä ominaisuudelta ei ollut tarpeeksi mittausdataa tämän päätelmän tekemiseksi. Nisula (2019) päätyi tutkimuksessaan

vastaavaan tulokseen tien leveydestä merkittävänä tekijänä kuljetuskelpoisuudessa. Pintalaadun korkea merkittävyys muuttujana johtuu mahdollisesti kyseisen ominaisuuden sekä tien kuljetuskelpoisuuden arviointimenetelmän subjektiivisuudesta, mikä väkisininkin luo autokorrelaatiota näiden havaintojen välille.

Pintalaadun ja tien leveyden merkittävyys on mallien yleisen käytön kannalta selkeä heikkous, sillä teiden pintalaatu sekä leveys ovat hyvin työläitä ominaisuuksia mitata ja arvioida, eikä niistä ole saatavilla vielä toistaiseksi kattavaa avointa-aineistoa. Aiemmat tutkimukset (Kiss ym. 2015, Carven & Wing 2014, Nisula 2019) ovat kuitenkin osoittaneet, että tien pintalaatua sekä leveyttä on mahdollista tarkastella melko luotettavasti käyttäen lentolaserkeilausaineistoa.

Yhtenä mahdollisena tien pinnan laadun kartoitusmenetelmänä laserkeilauksen ohella olisi käyttää liikuteltavaa gammaspektrometria. Pintamaan mineraalien tuottamia gammasäteitä voidaan tarkastella gammaspektrometrilla 30 senttimetrin syvyydestä. Gammasäteiden voimakkuus riippuu maan kosteudesta, joka heikentää oleellisesti säteilyä. Liikuteltavalla gammaspektrometrilla voitaisiin kartoittaa metsäautoteiden kosteutta, joka on merkittävä tekijä urien muodostumiselle. Tien pintakerroksen kosteustieto voisi myös kertoa kuinka hyvin tien pintakuivatus toimii ja onko tiellä riskiä kärsiä pintakelirikosta. Suomessa kerättyä aeroradiometristä aineistoa voisi yrittää hyödyntää tien ympäristön kosteuden tarkastelussa. Samaa aineistoa on jo käytetty esimerkiksi metsäkoneiden aiheuttaman uran syvyyden tutkimisessa (Mattila & Tokola 2018). Ennen kaikkea gammaspektrometri voisi olla hyödyllinen työkalu pintamurskeen laadun määrittämisessä.

Pintalaadun tarkasteluun on runsaasti mahdollisia metodeja, kuten aiemmat tutkimukset ovatkin osoittaneet, etenkin erilaiset laserkeilausaineistot ovat hyvin potentiaalisia työkaluja tien pinnan ja leveyden tarkastelussa. Tarkka pintalaadun selvittäminen lentolaserkeilausaineistosta on kuitenkin haastavaa. Tähän kuitenkin on vaihtoehtoisia menetelmiä, kuten liikkuva laserkeilaus (MLS) sekä maastolaserkeilaus (TLS) (Hruza ym. 2018). Etenkin liikkuvaa laserkeilausta on käytetty päällystettyjen teiden kunnon tarkasteluun, joten menetelmän hyödyntämistä myös metsäautoteillä tulisi tutkia tarkemmin (Liikenneviraston ohjeita 15/2016). Lentolaserkeilausaineiston käyttöä on tutkittu enemmän kuin maastolaserkeilausta tai liikkuvaa laserkeilausta, koska näistä kolmesta ainoastaan lentolaserkeilausaineistoa on saatavilla julkisesti. Haastavuutta tarkasteluun luo myös

pintalaadun muuttuminen vuoden ajan ja tien käytön määrän mukaan, joten vuosi sitten kerätty tieto ei välttämättä ole enää nykyään validia.

Tien leveydellä ja pintalaadulla on liitteen 2 mukaan myös havaittavissa lievää yhteneväisyyttä ja lisäksi näiden muuttujien välinen korrelaatio on suhteellisen korkea (0,552). Tämä johtunee siitä, että kapeat tiet ovat yleensä pistoja, joita käytetään liikennöinnissä vähän ja joista ei välttämättä pidetä huolta. Leveämmät tiet ovat taas suurempia runkoteitä ja näitä yhdistäviä väliteitä, jotka ovat aktiivisemmassa liikennöintikäytössä ja joiden kuntoon panostetaan tämän takia enemmän.

Ojariski-indeksin ja maalajin välisistä tunnusluvuista sekä laatikko-janakuvaajasta nähdään näillä kahdella muuttujalla olevan myös selkeää yhteneväisyyttä, eli huonommille maalajeille on yleisesti rakennettu syvämmät ojat. Tätä tukee myös maalajin sekä ojariski-indeksin välinen kohtalainen korrelaatio (0,544) (taulukko 4). Karkeamman maalajin alueilla ojien ei tarvitse olla syviä, sillä karkeat maalajit eivät pidätä vettä, jolloin kosteus ei jää vaikuttamaan tiehen. Aineistossa on myös turvemaa kohteita, joilla ojariski-indeksi on korkea, mikä viittaa hyvin suureen kosteuden asettamaan riskiin kyseisillä kohteilla, sillä kosteusindeksi on korkea ja ojien laatu heikko, jolloin veden poistamisen toimivuus ei ole tarpeeksi hyvällä tasolla.

Malleissa ei huomioitu ollenkaan teiden rakennus- ja kunnostushistoriaa, jotka ovat kuitenkin tärkeitä tekijöitä tien laadun kannalta. Täytyy muistaa, että teiden kunto heikkenee ajan ja liikennöinnin myötä, jolloin mallia jatkokehittäessä tulisi siinä olla esimerkiksi kulumista kuvastava kerroin, joka toimisi suhteessa esimerkiksi liikennöinnin määrään sekä vuotuisen sademäärään. Kerroin siis ilmaisisi tien kulumisen runsauden mahdollisesti heikentäen kuljetuskelpoisuusluokkaa, jos tielle ei tehdä parantavia toimenpiteitä.

Tien kuljetuskelpoisuus on haastavaa arvioida silmämääräisesti, sillä tien rungon laatu vaikuttaa voimakkaasti tien kokonaiskuntoon ja liikennöitävyyteen etenkin kelirikkojen aikaan. Kuljetuskelpoisuuden määrittämistä tulisi suorittaa pudotuspainomittauksilla, jonka tuloksiin perustuva kuljetuskelpoisuuden ja urautumisen raja-arvot on jo määritetty (Vuorimies N. ym. 2015). Mittaukset tulisi kuitenkin suorittaa suurella pudotuspainomitalla, jotta saataisiin tietoa myös rungon rakenteesta. Jatkotutkimuksia varten olisi myös tärkeää kerätä kattava ja tarkka referenssiaineisto tien ominaisuuksista, jotka olisi mahdollista määrittää kaukokartoitusaineiston perusteella.

5.1 Mallien saavuttama tarkkuus

Muodostetut regressiomallit onnistuivat melko hyvin kuljetuskelpoisuuden ennustuksessa, ordinaaliregressiomalli saavuttaen 62,7% ennustustarkkuuden ja lineaarinen regressiomalli saavuttaen 63,7% ennustustarkkuuden. Mallien testausvaiheessakin mallit suoriutuvat hyvin lineaarinen regressiomalli saavuttaen 70,6% ennustustarkkuuden sekä ordinaaliregressiomalli saavuttaen 68,2% ennustustarkkuuden. Tutkimuksessa saadut tulokset olivat hyvin yhteneväisiä, esimerkiksi Nisulan 2019 tutkimuksen tulosten kanssa, jossa onnistuttiin ennustamaan tien kuntoluokka 69,8% tarkkuudella. Tutkimuksessa käytetty aineisto kattoi hyvin kaikki ennalta määritetyt kuljetuskelpoisuusluokat, joten mallien luominen tapahtui hyvin tasaisella aineistolla, kattaen eri ominaisuuksien molemmat ääripäät ja keskiarvot.

Huomattavaa on kuitenkin molempien mallien heikko ennustustarkkuus kuljetuskelpoisuusluokalle "kuiva kesä" (Taulukko 8 ja 11), mikä pudotti mallien ennustamistarkkuutta merkittävästi. Molemmat mallit sekoittivat luokan 1 (kuiva kesä) koealat joko luokkaan 0 (talvi) tai 2 (kesä), kuten myös nähdään kuvasta 9, jossa luokan 1 pisteparven pisteet ovat kaukana luokakeskiarvosta sekä lisäksi sekaisin luokkien 0 (talvi) ja 2 (kesä) kanssa. Luokka "kuiva kesä" tulisi mahdollisesti poistaa kokonaan, jotta luokittelun epäselvyyttä saataisiin vähennettyä. Luokan voisi korvata esimerkiksi luokalla, "syksy", eli tie on liikennöitävissä syyskelirikon aikaan, mutta ei kevätkelirikon aikaan. Kuljetuskelpoisuusluokka syksy olisi muutenkin tärkeä lisä kuljetuskelpoisuusluokitteluun.

Kuten aiemmin mainittiin, mallin toimivuus on kuitenkin hyvin riippuvainen tien leveydestä sekä pintalaadusta. Yhtenä vaihtoehtona pohdittiin kaikkien subjektiivisten selittäjien poistamista mallista. Lineariselle mallille tehtiin yksi koeajo, jossa pintalaatu poistettiin kokonaan käytettävistä muuttujista, jolloin mallin ennustamistarkkuus putosi huomattavasti. Pintalaadun poistuessa, ojaindeksi nousee yhdeksi merkittäväksi muuttujaksi tien leveyden rinnalle, joten ojaindeksin merkittävyyttä tien kuljetuskelpoisuuden kannalta ei voida sanoa varmaksi. Yllättävää onkin, että mikään muu tien tai ympäristön ominaisuus ei alkuperäisessä mallissa saa samanlaista merkitsevyyttä muuttajana kuin tien leveys ja pintalaatu.

Käytettävänä mallina yksinkertainen lineaarinen regressio on ordinaaliregressiota parempi ja tutkimuksen tuloksista voidaan todeta molempien tuottavan yhtä luotettavia tuloksia. Lineaarisen regression tuottamat juoksevat arvot ovat myös tulkinnan kannalta parempia, eikä niitä ole tarpeellista pakottaa luokkiin kuten aiemmin mahdollisesta luokittelusta

mainittiin. Luokittelu toteutettiin, jotta voitiin saada tulokset saman muotoisiksi kuin ordinaaliregressiolla, jolloin eri mallien tuottamia tuloksia voitaisiin vertailla keskenään. Lineaarisen regression tuottamia arvoja voidaan tulkita ilman, että näille lasketaan luokkatodennäköisyyttä, toisin kuin ordinaaliregressiossa täytyy. Lineaarisen regression tuloksista voidaan helposti tarkastella eri kohteiden epävarmuutta, eli arvolla 1,1 ei ole suurta epävarmuutta luokasta, mutta arvolla 2,5 on. Tällöin mallin ollessa julkisessa käytössä, voitaisiin epävarmoille kohteille suorittaa tarkastuksia ja kehittää mallin toimintaa.

Saaduista tuloksista voidaan todeta kuljetuskelpoisuusluokkien määrittämisen olevan mahdollista. Mallilla, joka käyttäisi hyödyksi kaukokartoitusaineistosta tai lähikeilausaineistosta saatavia pintalaadun tietoja tuottaisi todennäköisesti luotettavia kuljetuskelpoisuuden arvioita. Tämä vaatisi kuitenkin referenssidatan keräämistä eri vuodenojoilta. Etenkin pudotuspainomittaukset olisivat arvokasta tietoa, sillä näille mittauksille on olemassa jo valmiita tutkimuksia, joissa urautumista tarkastellaan pudotuspainomittausten perusteella (Vuorimies N. ym. 2015) ja metsäteho on myös määrittänyt tavoitekantavuusarvot eri päällysrakenneluokille ja vuodenojoille (Strandström M, Metsäteho Oy 2017).

6. JOHTOPÄÄTÖKSET

Malleissa käytetyistä muuttujista tien leveys ja pintalaatu vaikuttaisivat siis olevan merkittävimmät tien ominaisuudet, kun tarkastellaan tien kuljetuskelpoisuutta. Tutkimuksessa mainittiin kuitenkin aiemmin, että pintalaadun suuri merkitsevyys muuttujana voi olla seurausta arviointimenetelmän subjektiivisuuden aiheuttamasta autokorrelaatioista. Mallin jatkokehitystä ja luotettavuutta ajatellen pintalaadulle tulisi löytää toinen tarkastelumenetelmä, joka ei ole yhtä subjektiivinen. Tien ominaisuuksien merkittävyyttä analysoidessa yllättäväksi huomioksi nousi ojien laadun alhainen merkitsevyys kuljetuskelpoisuuden selittäjänä, vaikka toimivien ojien merkittävyys tietä ympäröivän kosteuden poistajana on laajalti tiedostettu.

Molemmat luodut regressiomallit onnistuivat testiaineiston kuljetuskelpoisuusluokkien ennustamisessa jopa odotettua paremmin, vaikka mallit ovatkin yksinkertaisia lineaarisia

malleja. Mallien muodostaminen tapahtui kuitenkin hyvin laajalla ja kattavalla aineistolla, joten kaikkien ominaisuuksien vaihtelut on malleissa huomioitu. Molemmilla malleilla on kuitenkin selkeitä vaikeuksia kuljetuskelpoisuusluokan 1 (kuiva kesä) ennustamisessa. Jatkokehitystä ajatellen, mallien ennustamistarkkuuden parantamiseksi kuljetuskelpoisuusluokan 1 (kuiva kesä) tapaukset tulisi jakaa esimerkiksi luokkiin 0 (talvi) ja 2 (kesä).

Tällä hetkellä kuljetuskelpoisuusmallin kehittämisen esteenä on avoimen ja tarpeeksi laajan aineiston puuttuminen. Yhtenä mahdollisena tien pintalaadun kartoitusmenetelmänä laserkeilauksen ohella olisi käyttää liikuteltavaa gammaspektrometria tai aeroradiometristä aineistoa, kuten Mattila & Tokola (2018) tekivät metsäkoneiden aiheuttaman uran syvyyden tutkimisessa. Teiden kuntoinventointien joukkoistaminen yksityisteiden omistajille ja tieosakkaille, voisi olla toinen mahdollinen tiestöaineiston lähde. Lisänä voitaisiin hyödyntää tässäkin tutkimuksessa käytettyä Viominer-ohjelmistoa, jolla kerätty aineisto olisi apuna tulkitsemaan subjektiivisten muuttujien luokkaa eri teillä, sillä laajan aineiston kerääminen olisi nopeaa ja halpaa. On kuitenkin muistettava, että tien kuljetuskelpoisuuden tarkka määrittäminen pinnalta nähtävien ominaisuuksien lisäksi vaatisi tien rungon rakenteen tuntemisen ja pinnan kantavuuden arvot, jotka saadaan määritettyä pudotuspainomittauksilla.

Kuljetuskelpoisuusmallin yleistä käyttöä ajatellen normaali lineaarinen regressiomalli olisi käytännöllisempi kuin ordinaaliregressio, sillä lineaarisen regressiomallin tuottamat juoksevat arvot kuvastavat selkeästi ennustuksen luotettavuutta ja kuinka hyvin tien segmentti asettuu kuljetuskelpoisuusluokkaan. Molemmat mallit tuottavat yhtä hyviä ennusteita, joten sen suhteen ei ole merkitystä kumpaa mallia kannattaa hyödyntää. Molemmat mallit vaativat kuitenkin jatkokehitystä ennen kuin niitä on kannattavaa vapauttaa julkiseen käyttöön.

KIRJALLISUUS

Bussman Sebastian 2017. Paikkatiedon hyödyntäminen soratieverkon kantavuustilan arvioinnissa. Utilizing geographical information to locate thaw weakening on the gravel road network. Helsinki 2017. s61+3

Chunsun Zhang 2009. Monitoring the condition of unpaved roads with remote sensing and other technology. Final Report for US DOT DTPH56-06-BAA-0002

Craven, M. & Wing, M.G. 2014. Applying airborne LiDAR for forested road geomatics. *Scandinavian Journal of Forest Research*, 29(2): 174-182

Ferraz, A., Mallet, C. & Chehata, N. 2016. Large-scale road detection in forested mountainous areas using airborne topographic lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 112: 23-36

Greis, I., Perälä, M., Perälä, T. & Teppo, M. (toim.). 2015. Metsänhoidon suositukset metsäteiden kunnossapitoon, työopas. Tapion julkaisuja: 58.

Gumus, S., 2009. Constitution of the forest road evaluation form for Turkish forestry 8, 5389–5394

Hotanen J-P., Nousiainen H., Mäkipää R., Reinikainen A., & Tonteri T. 2013. Metsätyypit – opas kasvupaikkojen luokitteluun. Metsäkustannus. 192s.

Hrůza P.; Mikita T. & Janata P. 2016. Monitoring of Forest Hauling Roads Wearing Course Damage using Unmanned Aerial Systems. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis* 64(5):1537-1546

Hrůza P.; Mikita T.; Tyagur N.; Krejza Z.; Cibulka M.; Procházková A. & Patocka Z. 2018. Detecting Forest Road Wearing Course Damage Using Different Methods of Remote Sensing. Published in *Remote Sensing 2018* DOI:10.3390/rs10040492

Hämäläinen, E. & Rahja, J. (toim.). 2012. Yksityisteiden kunnossapito – Kunnossapitotöiden suunnittelun ja toteuttamisen perusteet.

Jaakkola Anttoni 2015. Low-cost Mobile Laser Scanning and its Feasibility for Environmental Mapping. Aalto University publication series DOCTORAL DISSERTATIONS, 65/2015. ISBN:978-952-60-6198-6

Kaakkurivaara T. & Uusitalo J. 2011. Kelirikkoaikaisen puunkuljetuksen haasteet – Ratkaisuja metsäteiden kuljetuskelpoisuuden ongelmiin sekä metsäteiden kantavuuden mittaukseen ja kunnostamiseen. Metlan työraportteja 200.

Kaakkurivaara, T. 2018, Innovative methods for measuring and improving the bearing capacity of forest roads. *Dissertationes Forestales* 251: 57,

Kiss, K., Malinen, J. & Tokola, T. 2015. Forest road quality control using ALS data. *Canadian Journal of Forest Research*, 45(11): 1636-1642

Kiss, K., Malinen, J. & Tokola, T. 2016. Comparison of High and Low Density Airborne LIDAR Data for Forest Road Quality Assessment. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume III-8: 167-172.

Kokkila Mervi 2011. Maastoa ja tiestöä kuvaavan monilähdeinformaation hyödyntämismahdollisuudet puunhankinnassa. Metsätehon raportti 217. <http://www.metsateho.fi/maastoa-ja-tiestoa-kuvaavan-monilahdeinformaation-hyodyntamismahdollisuudet-puunhankinnassa-esiselvitys/>

Korpilahti A. (toim.) 2001. Metsätieohjeisto. Metsäteho Oy. <http://www.metsateho.fi/metsatieohjeisto/>

Korpilahti, A. (toim.) 2008. Metsäteiden kuntoinventoinnin ja kuntotiedon hyödyntämisen toimintamalli. Metsätehon raportti 202. http://www.metsateho.fi/wpcontent/uploads/2015/02/Raportti_202_AK.pdf

Kukko Antero 2013. Mobile laser scanning - system development, performance and applications. Helsinki 2013. s247

Leinonen Seppo 2019. Metsäohjelmien seuranta. <https://www.metsakeskus.fi/sites/default/files/amo-seuranta-koko-maa.pdf>

Liikennevirasto 2013. Teiden ja ratojen kuivatuksen suunnittelu. Liikenneviraston ohjeita 5/2013. https://julkaisut.vayla.fi/pdf3/lo_2013-05_teiden_ja_ratojen_web.pdf

Liikennevirasto. 2014. Sorateiden kunnossapito. Liikenneviraston ohjeita 1/2014. https://julkaisut.vayla.fi/pdf8/lo_2014-01_sorateiden_kunnossapito_web.pdf

Liikennevirasto. 2016. Liikenneviraston ohjeita 15/2016. Ajoneuvolaserkeilaus tien painumamittauksessa. 31.12.2016 https://julkaisut.vayla.fi/pdf8/lo_2016-15_ajoneuvolaserkeilauksen_hyodyntaminen_web.pdf

Liikennevirasto. 2018. Liikenneviraston ohjeita 34/2018. Kelirikkoteiden liikenteen rajoittaminen. https://julkaisut.vayla.fi/pdf8/lo_2018-34_kelirikkoteiden_liikenteen_web.pdf

Luonnonvarakeskus (Luke) 2019. Runkopuuta kaatui 2018 enemmän kuin koskaan, 13.6.2019. <https://www.luke.fi/uutiset/runkopuuta-kaatui-2018-enemman-kuin-koskaan/>

Luoranen J.; Saksa T.; Finer L. & Tamminen P. 2007. Metsämaan muokkausopas. <https://jukuri.luke.fi/handle/10024/522555>

Malinen J.; Nousiainen V.; Palojärvi K. & Palander T. 2014. Prospects and Challenges of Timber Trucking in a Changing Operational Environment in Finland. Croatian Journal of Forest Engineering : Journal for Theory and Application of Forestry Engineering, Vol. 35 No. 1, 2014. 91-100.

Nisula Kalle 2019. Metsäteiden kunnan määrittäminen avoimen paikkatietoaineiston avulla. Helsinki 2019. s52

Piiparinen Heikki 2003. Metsäteiden kunnossapitokustannukset Etelä-Suomen yksityismetsissä. Metsätieteen aikakauskirja 3/2003: 275–290.

Pisto Timo 2019. Rakennettujen ja perusparannettujen metsäteiden kantavuuteen liittyvät laadulliset poikkeamat.

Saarelainen S. & Makkonen L. 2007. Ilmastonmuutokseen sopeutuminen tienpidossa. Tiehallinnon selvityksiä 4/2007, 53s.

Salminen Joel 2016. Metsäautoteiden rakentamisen taloudellinen kannattavuus. Mikkeli 2016 s32

Strandström Markus, Metsäteho Oy 2017. Päälysrakenneluokat – Metsätieohjeiston uudistettu materiaali 2017. <http://www.metsateho.fi/wp-content/uploads/P%C3%A4%C3%A4lysrakenneluokat.pdf>

Uusitalo J.; Kaakkurivaara T. & Haavisto M. 2012. Utilizing Airborne Laser Scanning Technology in Predicting Bearing Capacity of Peatland Forest. Croatian Journal of Forest Engineering. Vol. 33 No. 2, 2012. 329-337

Venäläinen P.; Raatevaara A.; Hämäläinen J.; Strandström M.; Pihlajisto I.; Melander M. & Hienonen P. 2017. Metsätehon tulosalvosarja 7/2017. Tilannekuva ja automatisoitu tiedonkeruu metsäsektorin kuljetuksista. https://vayla.fi/documents/20473/367242/Tulosalvosarja_2017_07_Tilannekuva_ja_automatisoitu_tiedonkeruu/e94dd7d6-d713-41a3-97f1-42aff0e87013


Venäläinen P.; Alanne H.; Ovaskainen H.; Poikela A. & Strandström M. 2017. Metsätehon tulosalvosarja 8/2017. Kausivaihtelun kustannukset ja vähentämiskeinot puun toimitusketjussa. http://www.metsateho.fi/wp-content/uploads/Tulosalvosarja_2017_08_Kausivaihtelun-kustannukset.pdf

Viitala E-J.; Saarinen V-M.; Mikkola A. & Strandström M. 2004. Metsäteiden lisärakentamistarpeen määrittäminen paikkatietoaineistojen avulla. Metsätieteen aikakauskirja 2/2004: 175–192.


Viitala, E-J. & Uotila, E. 1999. Optimaalinen tietiheys yksityismetsätalouden kannalta. Metsätieteen aikakauskirja 2/1999: 167–179.

Vuorimies N.; Kolisoja P.; Kaakkurivaara T. & Uusitalo J. 2015. Estimation of the Risk of Rutting on Forest Roads During the Spring Thaw. Transportation Research Record Journal of the Transportation Research Board 2474:143-148


LIITTEET



Liite 1. laatikko-janakuvaaja kosteusindeksin suhteesta kuljetuskelpoisuusluokkiin.



Liite 2. laatikko-janakuvaaja pintalaadun suhteesta tien leveyteen



Liite 3. laatikko-janakuvaaja ojariski-indeksin suhteesta maalajiin

Liite 4. Maalajin muutos maaindeksiksi

Maalaji	Maaindeksi
Turve (0)	0,8
Savimaa (1)	1
Hienoainesmoreeni (2)	0,9
Hiekkamoreeni (3)	0,5
Hiekka/sora (4)	0,3
Kalliomaa (5)	0,1

Liite 5. Pintalaadun muutos pintaindeksiksi

Pintalaatu	Pintaindeksi
Hyvä (3)	0,2
Tyydyttävä (2)	0,5
Huono (1)	0,9