



Pro gradu -tutkielma

Maantiede  
Luonnonmaantiede

Periglasiaalisten ilmiöiden alueellinen mallintaminen  
subarktisessa ympäristössä

Juha Aalto

2011

Ohjaaja:  
Miska Luoto

HELSINGIN YLIOPISTO  
GEOTIETEIDEN JA MAANTIETEEN LAITOS  
MAANTIETEEN OSASTO

PL 64 (Gustaf Hällströmin katu 2)  
00014 Helsingin yliopisto



# Sisällys

<b>1. Johdanto</b>	<b>4</b>
<b>2. Periglasiaaliset ilmiöt</b>	<b>6</b>
2.1 Geomorfologia tieteenalana	6
2.2 Periglasiaalinen viitekehys ja globaalimuutos	6
2.3 Ei-lineaarisuus geomorfologiassa	9
2.4 Tutkittavat periglasiaaliset ilmiöt	10
2.4.1 Kryoturbaatio	10
2.4.2 Rinneprosessit	16
2.4.3 Rapautuminen	19
2.4.4 Deflaatio	22
2.4.5 Nivaatio	23
2.4.6 Fluviaaliprosessit	25
<b>3. Tutkimusalue</b>	<b>27</b>
3.1 Sijainti ja topografia	27
3.2 Kallioperä	30
3.3 Deglasiaatio ja maaperä	30
3.4 Ilmasto ja hydrologia	31
3.5 Kasvillisuus	32
<b>4. Aineisto ja menetelmät</b>	<b>34</b>
4.1 Mallinnusaineisto	34
4.1.1 Havaintoaineisto	34
4.1.2 Selittävät ympäristömuuttajat	36
4.1.3 Selittävien ympäristömuuttajien valinta	40
4.1.4 Aineiston jako ja mallinnusresoluutio	41
4.2 Tilastollinen mallinnus	43
4.2.1 Taustaa	43
4.2.2 Yleistetyt lineaariset mallit	44
4.2.3 Yleistetyt additiiviset mallit	46
4.2.4 Hierarkkinen ositus	47
4.2.5 Mallien kalibraatio ja evaluointi	48

<b>5. Tulokset</b>	<b>53</b>
5.1 Kryoturbaatio	53
5.2 Rinneprosessit	60
5.3 Rapautuminen	66
5.4 Deflaatio	72
5.5 Nivaatio	77
5.6 Fluviaaliprosessit	84
5.7 Mallinnusresoluution vaikutus	90
<b>6. Tulosten tarkastelu</b>	<b>92</b>
6.1 Periglasiaaliset ilmiöt	92
6.2 Tulosten luotettavuus ja metodologiset kysymykset	100
<b>7. Yhteenveto</b>	<b>107</b>
<b>8. Kirjallisuus</b>	<b>109</b>
<b>9. Liitteet</b>	<b>123</b>

# 1. Johdanto

Geomorfologia on tieteenala, joka tutkii maanpinnan muotoja sekä niitä muodostavia prosesseja (Huggett 2007: 3). Sen alalaji on periglasiaalinen geomorfologia, joka on kiinnostunut kylmillä ei-glasiialisilla alueilla vaikuttavista prosesseista ja muodoista (French 2007: 5). Niiden syntyyn vaikuttavat voimakkaat jäätymiset talvella, eli routailmiöt, ja lumesta vapaat olosuhteet kesällä (Huggett 2007: 278). Näitä prosesseja on usein tutkittu hyödyntämällä perinteisiä kenttätyömenetelmiä, mutta periglasiaalisiin prosesseihin vaikuttavia tekijöitä voi olla hankala tunnistaa etenkin laajoilla alueilla (Hjort 2006: 1).

Viime vuosikymmeninä geomorfologian alalla on yhä enemmän ryhdytty hyödyntämään matemaattisia malleja, jotka esimerkiksi ennustavat maanpinnan muodoissa tapahtuvia lyhytaikaisia muutoksia. Näitä mallinnusmenetelmiä on hyödynnetty muun muassa maankäyttöä suunniteltaessa ja hasardeja ennustettaessa (Guzzetti et al. 1999; Dai & Lee 2002; Ermini et al. 2005; Hugget 2007: 11; Carrara & Pike 2008). Geomorfologiassa on siirrytty vähitellen pois kuvailevasta perinteestä kohti selittävämpää hypoteesien kokeilua (Hjort & Luoto 2010; Tucker & Hancock 2010). Paikkatietojärjestelmät (GIS = Geographic Information System) tarjoavat analyttisen kehyksen, jolla voi tallentaa, yhdistää, esittää ja analysoida suuria määriä alueellista tietoa eri mittakaavoilla (Walsh et al. 1998: 184). Paikkatietokannat yhdistettynä satelliittikuviin ovat tärkeä apuväline geomorfisia prosesseja selittävien ympäristömuuttujien keräämisessä (Etzelmüller et al. 2001). GIS-ohjelmistot ja kehittyneet tilastolliset mallinnusmenetelmät tarjoavat kustannustehokkaan työkalun sekä uuden teoreettisen näkökulman laajojenkin alueiden tutkimiseen. Tämä on tärkeää, sillä kallein ja usein aikaa kuluttavin osa tutkimuksessa ovat kenttätyöt (Etzelmüller et al. 2006).

Maanpinnan prosessien ja muotojen alueellinen mallintaminen on tärkeä osa tämän päivän periglasiaalista tutkimusta. Tieto geomorfisten prosessien ja ilmiöiden esiintymisestä on avainasemassa sekä teoreettisessa että soveltavassa luonnonmaantieteessä (Luoto & Hjort 2005: 311). Modernit mallinnustekniikat voivat tarjota esimerkiksi hyödyllisiä ennusteita ilmiöiden esiintymisestä tutkimattomilla alueilla (Marmion et al. 2008: 2241). Jatkuvasti lämpenevällä ilmastolla on suuri merkitys periglasiaalisten ilmiöiden alueelliseen esiintymiseen (Luoto & Seppälä 2003;

Fronzek 2006). Näistä monilla voi olla suuria yhteiskunnallisiakin vaikutuksia (Harris et al. 2001a; Kneisel et al. 2007; Hugelius et al. 2010). Ennustavassa geomorfologisessa kartoittamisessa kehitetään tilastollinen malli ympäristömuuttujien ja geomorfologisten ilmiöiden välille. Tätä mallia sovelletaan maantieteelliseen tietokantaan, josta tuloksena saadaan ennustekartta tutkittavalle alueelle (Luoto & Hjort 2005: 300). Alueellisen mallintamisen lähestymistapa on vielä suhteellisen uusi geomorfologiassa, mutta esimerkiksi Skandinaviassa on tehty paljon tutkimusta tämän saralla ja vertailtu eri mallinnusmenetelmien soveltuvuutta periglasiaalisten ilmiöiden tutkimiseen (Etzelmüller et al. 2001; Brenning et al. 2007; Marmion et al. 2008; Hjort & Luoto 2010).

Tämän pro gradu -tutkielman tavoitteena on (1) mallintaa ja ennustaa subarktisessa ympäristössä esiintyvien periglasiaalisten ilmiöiden alueellisen esiintymisen runsautta sekä niiden riippuvuutta eri ympäristömuuttujista tilastollisten mallinnusmenetelmien (Poisson-regressio) avulla, (2) selvittää ilmiöiden esiintymiseen eniten vaikuttavia tekijöitä hierarkkisen osituksen (HP = Hierarchical Partitioning) avulla, 3) vertailla keskenään kahta geomorfologisessa tutkimuksessa suosittua mallinnusmenetelmää: yleistettyjä lineaarisia malleja (GLM = Generalized Linear Models) sekä yleistettyjä additiivisia malleja (GAM = Generalized Additive Models), (4) tutkia mallinnusresoluution vaikutusta syntyvään ennusteeseen sekä (5) tutkia pistemäisen havaintoaineiston muuttamista alueellisesti kattavaksi.

## 2. Periglasiaaliset ilmiöt

### 2.1 Geomorfologia tieteenalana

Geomorfologia tutkii maanpinnan muotoja ja niiden syntyyn vaikuttaneita prosesseja. Perimmiltään muodot ovat peräisin veden ja kiven kieroista, rapautumisesta ja sedimentaatiosta sekä tektoniikasta, eroosiosta ja ilmastosta (Huggett 2007: 31). Alueellisella ja paikallisella tasolla tärkeimmät prosesseihin vaikuttavat tekijät voivat olla vaikeita selvittää (Hjort 2006: 1). Geomorfiset prosessit mielletään usein muuttumattomiksi, kunnes ne vaikuttavat jollakin, esimerkiksi katastrofaalisella tavalla ihmisten elämään. Oikeastaan maisemat ja maanpinnan muodot voidaan katsoa olevan jatkuvassa muutoksessa (Phillips 2009: 17). Pohjimmiltaan geomorfologia tutkii sitä, miten maanpinnan muodot ja maisemat reagoivat muuttuviin olosuhteisiin ja erilaisiin häiriötekijöihin. Myös se on tärkeää, miten geomorfinen prosessi kehittyy ilmaston, ekosysteemin, maaperän sekä muiden ympäristötekijöiden kanssa (Phillips 2009: 28; Tucker & Hancock 2010).

Yhä enemmän geomorfologisessa tutkimuksessa otetaan huomioon ihmisen ja maanpinnan muotojen vuorovaikutus (Huggett 2007: 11). Ihmiset levittäytyvät jatkuvasti marginaalialueille, joissa todennäköisyys joutua jonkin luonnon hasardin vaikutuksen alaiseksi on suurempi. Esimerkkinä tällaisesta tutkimuksesta on maanvyöryjen esiintymisen mallintaminen (Dai & Lee 2002; Ermini et al. 2005; Carrara & Pike 2008). Ihmiskunta muokkaa tänä päivänä niin paljon omaa elinympäristöään, että Hooken (2000) mukaan ihminen on yksi tärkeimmistä geomorfisiin prosesseihin vaikuttavista tekijöistä.

### 2.2 Periglasiaalinen viitekehys ja globaalimuutos

Termi periglasiaalinen viittaa erilaisiin kylmiin, ei-glasiaalisiin prosesseihin (French 2000: 41; French 2007: 5). Periglasiaalisilla alueilla maiseman kehitystä ohjaavat pääosin maaperän jäätymis-sulamismekanismit niin sanotussa aktiivikerroksessa, joka on kesäisin sulava osa jäätyneestä maaperästä (Washburn 1979: 57; André 2003: 149). Tärkein yksittäinen muotoja synnyttävä prosessi on roudan toiminta. Taulukossa 1 on esitetty eräs periglasiaalisten prosessien luokittelu perustuen Frenchin (2007) teokseen.

Ikiroudalla (maa jäässä yli kaksi vuotta peräkkäin) on periglasiaalisten prosessien esiintymisessä hyvin keskeinen merkitys, vaikka täydellistä alueellista riippuvuutta ei näiden välillä olekaan. Yhden määritelmän mukaan periglasiaaliset alueet sijaitsevat suurin piirtein siellä, missä vuoden keskilämpötila on alle +3 °C (French 2007: 5, 13, 31). Karkeasti voidaan arvioida, että noin neljäsosa maankamarasta kuuluu näihin alueisiin (Huggett 2007: 278).

Periglasiaalisia alueita ei ole pelkästään korkeiden leveysasteiden tundra-alueilla, vaan myös metsittyneillä vyöhykkeillä metsärajan alapuolella sekä vuoristoalueilla matalemmilla leveysasteilla. Periglasiaalisiin alueisiin kuuluvat arktiset polaari- ja puoliaavikot, tundra, boreaaliset metsät ja subarktiset alueet. Tämän lisäksi Tiibetin ylänkö ympäristöineen voidaan lukea mukaan periglasiaalisiin ympäristöihin. Eteläisellä pallonpuoliskolla periglasiaalisia alueita ovat Etelä-Amerikan karkiosat, subantarktiset saaret, Antarktiksien niemimaa ja monet jäätä vapaat alueet Antarktiksella. Myös jäätiköiden reuna-alueet sisällytetään tähän joukkoon (French 2000; French 2007: 11–13). Koska monet tämän päivän periglasiaaliset alueet ovat vasta hiljattain vapautuneet mannerjäätikön alta, vain harvat näistä alueista ovat geomorfisessa tasapainotilassa. Niiden voidaankin sanoa olevan paraglasiaalisia, joka viittaa vaiheittumiseen proglasiaalisista, jäätikön läheisyyden aiheuttamista olosuhteista kohti periglasiaalista tasapainotilaa (André 2003; French 2007: 16–17). Periglasiaalisten prosessien esiintymiseen vaikuttavat hyvin monet tekijät. Washburnin (1979: 10–17) mukaan tärkeimmät ympäristömuuttujat ovat ilmasto, topografia, kallio- ja maaperä, kosteusolot, lumipeite sekä kasvillisuus.

Taulukko 1. Periglasiaalisten prosessien jako Frenchin (2007) mukaan.

<b>Jako</b>	<b>Periglasiaalisia muotoja</b>
Ikirouta ja maajää	Palsat, kivijäätiköt, jääkiilat, pounut
Aktiivikerros	Kuviomaat
Termokarsti	Termokarsti reliefi, sulamisjärvet ja painanteet
Rinneprosessit	Solifluktio kielekkeet ja terassit, kyntävät kivet, maanvieremät, lumivyöryt, kivivyöryt
Fluviaaliprosessit ja muodot	Palmikoivat uomat, periglasiaaliset sandurit, epäsymmetriset laaksot
Eoliset prosessit ja muodot	Deflaatio painanteet, ventifaktit, lössi, hiekkadyynit

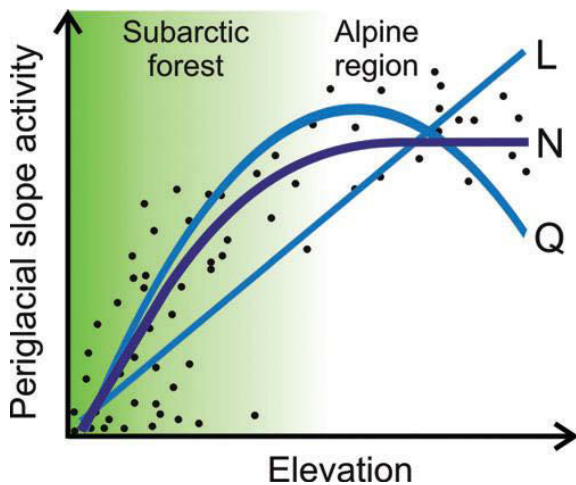


Kiinnostus periglasiialisia alueita kohtaan on lisääntynyt huomattavasti näin globaalimuutoksen aikakaudella (Kullman 2010; Virtanen et al. 2010). Käynnissä olevan ilmaston lämpenemisen ennustetaan olevan suurinta juuri korkeilla leveysasteilla, missä periglasiialiset prosessit ovat vallitsevia (Anisimov et al. 2007: 655). Vaikka ilmasto onkin tärkeä tekijä ikiroudan ja maajään esiintymisessä, ovat myös paikalliset tekijät kuten kasvillisuus, lumipeite, maaperän fyysiset- ja lämpöominaisuudet sekä maaperän kosteusolot hyvin merkittäviä. Ilmaston lämpeneminen on jo pienentänyt sekä ikiroudan, että kausittaisen maajään ja täten aktiivikerroksen alueellista esiintymistä (Lemke et al. 2007). Jylhä et al. (2004: 137–139) mukaan ilmasto Suomessa on lämmennyt vuosina 1901–2000 0,7 °C. Vuoteen 2039 eri ilmastonmuutosskenaarioiden keskiarvon ennustama nousu on lämpötilan suhteen 1,3–3,1 °C ja sadannan suhteen 2–16 %. Lämpenemisestä ja sen aiheuttamasta sadannan lisääntymisestä on jo todisteita Luoteis-Lapista Kilpisjärven alueelta (Virtanen et al. 2010: 814). Tällä on suuri merkitys periglasiialisten ilmiöiden alueelliselle esiintymiselle, sillä esimerkiksi palsasoiden alueellinen esiintyminen liittyy alhaisiin lämpötiloihin (-3 - (-5 °C)) sekä alhaiseen sadantaan (<450 mm) (Luoto et al. 2004: 1382).

Korkeiden leveysasteiden maaperä on suuri orgaanisen hiilen varasto ja täten tärkeässä osassa hiilen kierrossa (Hugelius et al. 2010: 16). Sulavalla ikiroudalla on näin ollen vaikutusta ilmastonmuutokseen lisäämällä osaltaan hiilidioksidi- (CO<sub>2</sub>) ja metaani- (CH<sub>4</sub>) pitoisuuksia ilmakehässä sekä vähentämällä esimerkiksi palsasoihin liittyvää biodiversiteettiä (Fronzek et al. 2006: 10; Kuhry et al. 2010). Ilmastonmuutos on jo vaikuttanut kasvien levinneisyyskuvaan Euroopassa ja Fennoskandiassa. Lämpenevä ilmasto sallii monien lajien esiintymisen yhä korkeammilla alueilla (Lenoir et al. 2008; Kullman 2010). Tällä on suuri merkitys periglasiialisiin prosesseihin, sillä kasvillisuudella ja geomorfologisilla ilmiöillä on vahva yhteys (Naylor et al. 2002). Toisaalta kasvillisuus voi toimia geomorfisia prosesseja stabiloivana tekijänä (Viles et al. 2008: 1420). Toisaalta esimerkiksi periglasiialisten ilmiöiden aiheuttama häiriö saattaa kiihdyttää eliöiden alueellista heterogeenisyyttä eli monimuotoisuutta (Zeng et al. 2007: 380). Tästä syystä geomorfologinen aktiivisuus tunturien rinteillä edistää kasvillisuuden muutosta ilmaston lämmetessä (Virtanen et al. 2010: 811).

### 2.3 Ei-lineaarisuus geomorfologiassa

Systeemi on ei-lineaarinen jos prosessien välinen suhde ei pysy vakiona koko tutkittavalla skaalalla. Periglasiialisten prosessien ja ympäristömuuttujien suhde on usein monimutkainen ja ei-lineaarisuus on yleistä geomorfisissa systeemeissä. Se sallii prosessi-ympäristösuhteet, jotka eivät ole mahdollisia lineaarisissa systeemeissä (Phillips 2003: 4). Usein vasteen ja selittävän muuttujan suhde oletetaan lineaariseksi, vaikka se ei sitä todellisuudessa olekaan. Tämä nousee ongelmaksi etenkin silloin, kun tehdään alueellista mallintamista. Monet tilastolliset mallit perustuvat lineaariseen vasteen ja muuttujan suhteeseen (Hjort & Luoto 2010: 1). Kuten kuvasta 1 nähdään, lineaarinen ja toisen asteen malli eivät kuvaa niin hyvin prosessi-ympäristösuhdetta kuin ei-parametrinen malli. Tämä tarkoittaa mallia, jossa selittäville ympäristömuuttujille ei estimoida regressiokertoimia, vaan se antaa aineiston määrätä mallin muodon ollen täten useita muita menetelmiä joustavampi. Tässä ei-parametrisessä mallissa vastaan tulee saturaatiotaso, jonka jälkeen rinneaktiivisuus ei enää kasva.



Kuva 1. Hypoteettinen esimerkki rinneprosessien aktiivisuudesta (Periglacial slope activity) periglasiialisessa ympäristössä korkeuden (Elevation) funktiona perustuen kolmeen eri malliin: L = Lineaarinen, Q = Toisen asteen ja N = Ei-parametrinen (Hjort & Luoto 2010).

Ei-lineaarisuutta geomorfisiin systeemeihin tulee monesta lähteestä. Kynnyskäyttäytyminen on yleistä luonnossa, jolloin jonkin systeemin käytös muuttuu tietyn pisteen yli mentäessä. Esimerkkinä voidaan mainita jäätikön dynamiikan muuttuminen sulamisnopeuden ylittäessä kerrostumisen. Jos systeemissä tulee vastaan

saturaatitaso, on se silloin ei-lineaarinen (kuva 1). Muita lähteitä on muun muassa itsevahvistuva positiivinen palautemekanismi, josta esimerkkinä nivaation kehitys. Kun prosessi on kerran käynnistynyt, se vahvistaa itseään, nopeuttaa prosessia entisestään sekä lakkaa olemasta lineaarinen (Phillips 2003: 9–14). Varastointiefekti fluviaalisysteemeissä, itseään rajoittava vaikutus rapautumisessa sekä monimutkaiset kasvillisuus-disturbanssi interaktiot ovat esimerkkejä ei-lineaarisuuden lähteistä geomorfologiassa (Phillips 2003: 17; Viles et al. 2008).

Muutos geomorfologiassa on riippuvainen mittakaavatasosta. Jollakin tarkastelutasolla esimerkiksi maanvyöry voi olla nopea ja epäjatkuva tapahtuma, kun taas toisella tasolla sitä voidaan pitää jatkuvana muutoksena. Useissa tapauksissa geomorfologisilla prosesseilla on oma temponsa ja syklinsä, johtuen esimerkiksi kausittaisista ilmaston vaihteluista (Phillips 2009: 18). Tärkeä termi geomorfologiassa on tasapaino, jonka voi ajatella olevan eräänlainen ”lepovaihe”, jolloin systeemiin vaikuttavat tekijät ovat keskenään tasapainossa. Pienikin muutos prosessiin vaikuttavissa tekijöissä voi kuitenkin saada systeemin kehittymään johonkin suuntaan (Phillips 2003). Tilastolliset mallinnusmenetelmät olettavat tutkittavan ilmiön olevan tasapainossa ympäristönsä suhteen, mikä harvoin pitää paikkaansa geomorfologiassa (vrt. Guisan & Zimmermann 2000: 153). Toisaalta monet periglasiaaliset ilmiöt ovat luonteeltaan niin hitaita, joten tilastollinen mallinnus on mahdollista (Hjort 2006: 123).

## **2.4 Tutkittavat periglasiaaliset ilmiöt**

### **2.4.1 Kryoturbaatio**

Kryoturbaatio eli routakuohunta on yleisnimitys kaikelle roudan aiheuttamalle maaperän liikkeelle ja se on vallitseva maaperän prosessi periglasiaalisilla alueilla. Siihen kuuluu routanousu, sulamisen aiheuttama laskeutuminen sekä kaikki muut liikkeet mistä aiheutuu maaperän supistumista tai laajentumista lämpötilan muutosten johdosta (Vandenberghé 1988: 181; Bockheim & Tarnocai 1998; French 2007: 144). Pelkät alhaiset lämpötilat eivät riitä aiheuttamaan kryoturbaatiota, vaan faasimuutos vedestä jääksi on välttämätön (ACGR 1988: 25). Kun vesi jäätyy maaperän huokostiloissa aktiivikerroksessa, se laajenee 9 % ja syntyneet jääkiteet luovat painetta joka suuntaan, mutta se näkyy maaperän liikkeenä ainoastaan vertikaalisesti ja

horisontaalisesti (Washburn 1979: 79; Seppälä 2005a: 171). Ylöspäin liikkuneet kivet ja muut kappaleet ovat suoraan seurausta maaperän jäätymisestä. Tämä liike on erityisen tehokasta heterogeenisissä ja konsolidoitumattomissa maaperissä esimerkiksi moreenissa. Hiekassa ja muissa karkeammissa maa-lajitteissa ei pääse kausittaisen roudan aikana muodostumaan eristynyttä jäätä (Williams & Smith 1989: 54). Mekanismeja ei täysin tunneta, mutta ainakin kahta eri hypoteesia on ehdotettu. Routaveto (engl. frost-pull) mekanismissa etenevä ”jäätymistaso” nappaa karkean fraktion mukaansa ja nostaa sitä ylöspäin yleisen routanoston johdosta. Toinen mekanismi on routatyöntö (engl. frost-push). Siinä kiven suurempi lämmönjohtavuus aiheuttaa sen, että kappaleen ympärille ja alle kehittyvä jää aiheuttaa ylöspäin suuntautuneen liikkeen. Molemmissa tapauksissa hienompi aines syrjäyttää kappaleen jättämän tyhjän tilan, jolloin jään sulaessa kivi jää uudelle paikalleen (Washburn 1979; French 2007: 144–146). Kaikille malleille on yhteistä, että niin sanottu kryoimu (engl. cryosuction) kehittyy jäätyvään maahan ja vetää kosteutta maaperään (Davis 2001: 85). Routatyöntö saattaa myös muodostaa gradientteja, jolloin mekanismin voimakkuus vaihtelee syvyyden muuttuessa (Williams & Smith 1989: 162). Eristäytynyttä jäätä pääsee muodostumaan maaperään, kun 1) lämpötila on pakkasella ja maaperän huokoskoko mahdollistaa kryoimun, 2) vettä on saatavilla, 3) maaperän hydraulinen johtavuus on riittävän suuri, 4) lämmönjohtavuus ja lämpötilagradientti sallivat lämpöenergian siirtyä sisään ja ulos systeemistä sekä 5) kryoimun voimakkuus sallii syntyvän jään paineen ylittävän ympäröivän materiaalin painon (Davis 2001: 87).

Roudan toiminta maaperässä aiheuttaa myös muun muassa aineksen lajittumista, josta voidaan erottaa kolme mekanismia: routatyöntön aiheuttama lajittuminen, hienoaineksen lajittuminen jäätymistason edetessä sekä mekaaninen lajittuminen. Viimeinen tarkoittaa sitä, että suuremmat partikkelit liikkuvat painovoiman vaikutuksesta routatyöntön aiheuttaessa esimerkiksi kumpuja. Kryoturbaatio on kaikkein tehokkainta hienojakoisessa maaperässä esimerkiksi moreenissa, jotka ovat hyvin alttiita routimiselle kosteusominaisuuksiensa ansiosta (French 2007: 146–148). Yksi tärkeimmistä kryoturbaation alueelliseen esiintymiseen maisematasolla vaikuttavista tekijöistä on kasvillisuus, jolla on positiivinen vaikutus lumen kerrostumiseen ja sitä kautta roudan muodostumiseen (Hjort & Luoto 2009: 331). Useimmat kryoturbaation aiheuttamat muodot (esimerkiksi lajittumattomat ympyrät) kehittyvät lähes tasaisille alueille. Tämä yhdessä runsaan kosteuden ja sopivan maa-

aineksen kanssa edesauttavat näiden ilmiöiden syntymistä (Daanen et al. 2008: 2).

Kryoturbaatiota voi esiintyä monessa eri muodossa. Kuviomaa on ryhmätermi enemmän tai vähemmän symmetrisille muodoille, kuten ympyröille, polygoneille, verkoille, askelmille ja raidoille, jotka ovat luonteenomaisia voimakkaalle roudan toiminnalle (Washburn 1956: 824; ACGR 1998: 61). Ne voidaan myös jakaa lajittuneisiin ja lajittumattomiin muotoihin (Washburn 1979: 123). Kun ympyröitä ja polygoneja on useita vierekkäin, ne voivat muodostaa verkon. Nämä muodot esiintyvät useimmiten tasaisella alueella. Rinteissä muodot venyvät ja vaihtelevat hiljalleen raidoiksi (French 2007: 148). Kuviomaiden alkuperä ei ole täysin selvillä, mutta se on todennäköisesti polygeneettinen ja kaikki muodot eivät ole syntyneet samalla tavalla (Mann 2003; French 2007: 152). Lajittuneiden polygonien syntyyn vaikuttaa oleellisesti maaperän halkeilu. Niiden koko vaihtelee halkaisijaltaan kymmenistä sentteistä jopa kymmeneen metriin (Washburn 1979: 142, 160). Paikallisella tasolla kuviomaiden syntyyn vaikuttavia tekijöitä ovat esimerkiksi mikroilmasto, topografia, maaperä, hydrologia, kasvillisuus ja lumipeite (Matthews et al. 1998: 160–161; Hjort 2006: 12; Daanen et al. 2008). Suurin osa kuviomaa muodoista syntyy aktiivikerroksessa (French 2007: 148). Yleisin muoto on lajittumaton ympyrä (Washburn 1997) (kuvat 2 ja 3). Ne esiintyvät yksin tai ryhmissä ja vaihtelevat halkaisijaltaan 0,5 – 3 metriin. Korkeutta lajittumattomilla ympyröillä on maksimissaan puoli metriä ja ne ovat usein hieman kupolin muotoisia (Washburn 1979: 128; French 2007: 148).



Kuvat 2 ja 3. Lajittumattomia ympyröitä Ailakkavaaran pohjoispuolella 4.7.2010 noin 620 m mpy (metriä merenpinnan yläpuolella). Pistokairan pituus on yksi metri. Kaikki valokuvat ovat tekijän ottamia, ellei toisin mainita. Liitteessä 1 on merkitty kaikkien tutkittavien ilmiöiden valokuvien sijainti.

Lajittuneet kuviomaat määrittää hienon ja karkeamman aineksen vaihtelu ja niillä on usein kivinen raja. Lajittumattomat kuviomaat erottuvat yleensä mikrorelieftään ja kasvillisuuden vaihtelun ansiosta (Washburn 1956: 827–829, Hjort 2006: 11–12). Lajittumattomat polygonit ovat kuviomaita, jotka ovat pääosin polygonin muotoisia ja niiltä puuttuu kivinen reuna, kun taas lajittuneita polygoneja reunustaa selkeä kivinen raja (Washburn 1979: 133–141). Ballantyne & Matthews (1982: 348) mukaan muodon koko riippuu siitä, kuinka kauan kuviomaa on saanut kehittyä. Mutakuopat (engl. mud boil) kuuluvat kuviomaihin ja ne muodostuvat huonosti lajittuneisiin maaperiin, joissa on suuri siltti- tai savipitoisuus. Niissä sedimentin luonnollinen kosteuspitoisuus on hyvin suuri, jolloin maa-aines virtaa helposti kosteusolojen sekä ulkoisten tai sisäisten jännitteiden vaikutuksesta (French 1988: 173; French 2007: 150) (kuva 4).



Kuva 4. Lajittunut mutakuoppa (halkaisija noin 40 cm) Ailakkavaaran luoteisrinteellä 5.7.2010 noin 820 m mpy.

Pohjois-Suomi sijaitsee epäjatkuvan ikiroudan alueella ja ainoita todellisia ikiroutamuotoja ovat palsasuot (Seppälä 1997: 87). Palsa on turvekumpu, jonka sisällä on ikiroutaydin sekä turvetta ja/tai mineraaliainesta (Seppälä 1982: 36; ACGR 1988: 60) (kuva 5). Palsojen morfologia vaihtelee pienistä halkaisijaltaan muutaman metrin laajuisista ja alle metrin korkuisista kummuista jopa seitsemän metriä korkeisiin ja useiden satojen metrien laajuisiin palsakomplekseihin (Seppälä 1983: 233). Palsojen esiintymiseen vaikuttavat eniten ilmastolliset tekijät (keskilämpötila alle  $-1\text{ }^{\circ}\text{C}$  ja alhainen sadanta), suhteellisen ohut lumikerros, lämpötila alle  $0\text{ }^{\circ}\text{C}$  yli 200 päivän ajan

sekä riittävä määrä turvetta eristämään jäädyin lämpimän kesän ajaksi (Seppälä 1982: 36; Seppälä 1988: 247). Palsasoilla on ainutlaatuinen syklinen kehityskaari palsan muodostumisesta sen kasvuun ja lopulta hajoamiseen (Seppälä 1976; Seppälä 1988: 271). Seppälä (1982) on kokeellisesti osoittanut, että ohut lumipeite sallii roudan muodostumisen maaperässä ja käynnistää palsan kehityksen. Palsat sijaitsevat usein topografisissa painanteissa, mihin suotkin pääosin muodostuvat. Nämä paikat keräävät myös kylmää ilmaa talvisin (Seppälä 1988: 252–254). Tulevaisuudessa ilmaston lämpeneminen tulee todennäköisesti pienentämään palsasoiden alueellista esiintymistä (Fronzek et al. 2006).




Kuva 5. Hajoamassa oleva palsasuo Akuvaarassa Utsjoen lähellä (Maantieteen laitos 2011). Korkeus merenpinnasta ei tiedossa.

Pounut ovat normaalisti alle metrin korkuisia ja maksimissaan kaksi metriä halkaisijaltaan olevia osittain turpeesta ja mineraaliaineksesta muodostuneita kumpuja, jotka ovat kohonneet roudan vaikutuksesta (kuva 6). Turvekerros on yleensä alle 60 cm paksu ja pounun sisällä oleva mineraalimaaydin voi koostua myös kivistä tai jopa yhdestä suuresta lohkarresta. Pounut ovat usein myös kasvittuneita (Seppälä 1983: 236; Seppälä 1998: 369; Vliet-Lanoë & Seppälä 2002: 187–188). Pounut eivät ole riippuvaisia ikeroudan esiintymisestä, vaan niitä on pääosin kausittaisen roudan alueilla (Vliet-Lanoë & Seppälä 2002). Pounuja esiintyy erityisen paljon epäjatkuvan ikeroudan alueella pohjoisilla boreaalisilla ja subarktisilla alueilla. Monilla Fennoskandian subarktisilla alueilla jopa 50 % maa-alasta on pounujen peitossa (Luoto & Seppälä 2002: 127). Tärkeimpiä pounujen alueelliseen esiintymiseen vaikuttavia tekijöitä ovat muun muassa lumipeitteen paksuus, lämpötilat ja alueen kosteusolot (Luoto & Seppälä 2002: 135).



Kuva 6. Noin metrin korkuinen pounu Ailakkavaaran eteläpuolella 3.7.2010 550 m mpy.

Kryoturbaation aktiivisuutta voidaan arvioida esimerkiksi sammaleen olemassaolosta ja kasvillisuudesta tai sen puutteesta (Washburn 1979: 129; Ballantyne & Matthews 1982: 348) (kuva 7). Kryoturbaatio ei vaikuta pelkästään maaperän morfologisiin ominaisuuksiin, vaan sillä on merkitystä myös kemiallisiin ja fyysisiin ominaisuuksiin. Se esimerkiksi sekoittaa orgaanista hiiltä paljon sisältävää pintakerrosta alapuolella olevaan maaperään (Bockheim & Tarnocai 1998: 283).



Kuva 7. Kryoturbaatiota Ailakkavaaran etelärinteellä 8.7.2010 noin 880 m mpy.



## 2.4.2 Rinneprosessit

Massaliikunnot ovat materiaalin kulkeutumista rinnettä alaspäin painovoiman vaikutuksesta. Rinneprosessit ovat erityisen tehokkaita periglasiaalisessa ympäristössä. Tämä johtuu siitä, että ensinnäkin mekaaninen rapautuminen on runsasta. Toiseksi lyhyet jäätymis-sulamissyklit edesauttavat sedimentin liikkumista. Sulanut aktiivikerros sisältää paljon kosteutta, joka lisää huokosvesipainetta helpottaen maanliikettä painovoiman johdosta. Aktiivisuutta lisää myös ikirouta, jonka pinta toimii liukupintana (French 2007: 224; Harris et al. 2008).

Periglasiaaliset rinneprosessit voidaan jakaa kahteen päätyyppiin: solifluktioon ja nopeisiin paikallisiin massaliikuntoihin, jotka tapahtuvat pääosin sulamiskauden aikana (Hjort 2006: 16). Termi solifluktio kuvasi alunperin vedellä kyllästyneen maa-aineksen hidasta valumista alarinteen suuntaan (Andersson 1906, cit. Washburn 1979). Hitaat massaliikunnot kylmissä ympäristöissä johtuvat kuitenkin useista tekijöistä, eivätkä välttämättä vaadi maaperän saturaatiota (Matsuoka 2001: 108). Gelifluktio taas on määritelty periglasiaalisessa ympäristössä tapahtuvaksi solifluktioksi, johon liittyy kiinteästi ikiroudan esiintyminen. Tällöin maaperä valuu jääpintaa vasten painovoiman vaikutuksesta (Washburn 1979: 200–201; French 1988: 165). Vuotomaa (engl. frost creep) on maaperän partikkulien asteittaista liikkumista rinnettä alaspäin. Maaperän jäätyminen aiheuttaa rinteiden normaalin suuntaisen kohoamisen. Keväällä jään sulatessa kohonnut maamassa laskeutuu kohtisuoraan maanpintaan nähden, jolloin nettoliike on rinnettä alaspäin (Washburn 1979: 201). Modernissa käytössä termi solifluktio kuvaa gelifluktioita ja vuotomaailmiön yhteisvaikutusta (French 2007: 225). Tämä prosessi on hidasliikkeinen, vuosittainen liike vaihtelee muutamasta sentistä jopa reiluun metriin riippuen ilmastollisista oloista, maan jäätyneen syvyydestä ja jäätymis-sulamissyklien tiheydestä (Harris et al. 2001b; Matsuoka 2001a, Seppälä 2005b: 359). Yksi hidasta liikettä aiheuttava prosessi on maan ryömiminen, jossa maaperässä olevan jään sulaminen ja uudelleen jäätyminen saa liikkeen aikaan (Williams & Smith 1989: 246–247). Solifluktio on aktiivinen jo noin yhden asteen rinteessä (Davis 2001: 156). Tärkeitä solifluktioita aktiivisuuteen vaikuttavia tekijöitä ovat ilmasto, maaperän kosteus, rinteiden kaltevuus, maaperän raekoko, ekspositio ja kasvillisuus (Washburn 1979: 200–204; Matsuoka 2001a; Ridefelt et al. 2010: 249). Erittäin tärkeitä tekijöitä ovat myös ikiroudan yläosan etäisyys maanpinnasta ja saatavilla oleva sulamisvesien määrä

(Wasburn 1999: 175; Jaesche et al. 2003: 407–408). Kaikkein tehokkainta sen toiminta on tuntureiden puurajan yläpuolella, jossa Fennoskandiassa solifluktion nopeus on noin 20–60 cm/vuosi (Seppälä 2005b: 358–359).

Hitaat massaliikunnot tuottavat useita erilaisia maanpinnan muotoja. Tyypillisiä ovat erilaiset kilvet, kielekkeet, terassit ja virrat. Solifluktion kilvet (engl. sheets) ovat pehmeitä ja jatkuvia laaja-alaisia pintoja ja ne ovat parhaiten kehittyneitä siellä, missä kasvittomuus sallii prosessin toimivan yhtenäisesti koko rinteiden leveydellä (Washburn 1979: 214; French 2007: 229) (kuva 8). Solifluktion kilvet voivat olla joko lajittuneita tai lajittumattomia (Hjort 2006). Kielekkeet ovat kieltä muistuttavia solifluktiomuotoja, joilla voi olla jyrkkä, jopa kolme metriä korkea eturintama (Matsuoka 2005a) (kuva 9). Rintaman korkeus viittaa liikkeen maksimisyvyyteen ja vallitsevaan jäätymissulamistyyppiin (French 2007: 231). Solifluktion terassit tai penkit ovat terassin muotoisia hitaiden massaliikuntojen muotoja, joita esiintyy erityisesti rinteiden alaosissa. Niiden pisin sivu asettuu usein kohtisuoraan rinteiden suuntaan (Hjort 2006: 17). Solifluktion virrat ovat kapeita ja suorita maa-aines-kerrostumia tai lohkkareikkoja. Ne ovat orientoituneet suoraan korkeuskäyriä vasten (Washburn 1979: 216; Hjort 2006: 17). Kyntävät kivet ovat myös solifluktiomuotoja, joissa yksittäinen kivenlohkare valuu rinnettä alas jättäen jälkeensä suoran painanteen ja kerrostaen eteensä pientä harjannetta (kuva 8). Painanteen ja etupuolella olevan harjanteen koko ovat suoraan riippuvaisia kiven koosta (Washburn 1979: 223; Hjort 2006: 17). Hitailta massaliikunnoilla on suuri merkitys periglasiialisten ympäristöjen maiseman muokkaajana niin sanotussa kryoplaneatiossa, eli periglasiialisen maiseman kehityksessä jyrkkäpiirteisestä kohti tasaisempaa (Davis 2001: 156; French 2007: 245–246).



Kuva 8. Aktiivista solifluktiota Ailakkavaaralla 3.7.2010 noin 840 m mpy. Kuvassa etualalla vasemmalla on myös kyntävä kivi.



Kuva 9. Lähes metrin korkuinen solifluktiokieleke Ailakkavaaran lounaisrinteellä 8.7.2010 noin 810 m mpy.

Periglasiassa ympäristössä esiintyy myös nopeita ja voimakkaita, mutta harvoin toistuvia massaliikuntoja (French 2007: 232). Nopeita massaliikuntoja voi tapahtua paljon jäätä sisältävässä tai konsolidoitumattomassa sedimentissä aktiivikerroksen sulaessa ja ikeroudan toimiessa liukupintana, jolloin sulava tai sulanut aktiivikerros irtaava ikeroudasta. Joskus seurauksena voi olla esimerkiksi mutavyöry tai laaja-alainen, mutta matala vyöryarpi (Washburn 1979: 195–197; French 1988: 168; French 2007: 232). Maaperä peittää usein nopean kevätulamisen aikaan tai voimakkaiden sateiden yhteydessä (French 2007: 233; Harris et al. 2008: 440). Runsaiden lumisateiden alueella nopeat massaliikunnot voivat tapahtua lumi- ja maanvyöryinä. Useimmat vyöryt alkavat lumivyöryinä, mutta matkalla ne keräävät irtainta ainesta mukaansa. Näin niistä tulee niin sanottuja ”sekavyöryjä”. Suurin osa maanvyöryistä tapahtuu voimakkaiden sateiden yhteydessä tai lumialueiden nopeasti sulaessa (French 2007: 233). Ne jättävät jälkeensä rinteeseen suuntaisia levée muotoja ja levittäytyvät rinteeseen alaosassa keilamaisesti (Ballantyne & Benn 1994: 261–262). Vedellä kyllästettyjä lumivyöryjä kutsutaan sohjuvyöryiksi. Tuloksena on vaihtelevan kokoisesta materiaalista koostuva keila rinteeseen alaosassa (Washburn 1979: 193–195; Seppälä 2004: 69).

Pystysuorilla tai lähes pystysuorilla jyrkänteillä kivivyöryt ovat tavallisia ja ne muodostavat alarinteeseen vyörysorakeiloja eli taluksia, jotka ovat usein suurista kivenlohkareista muodostuneita peitteitä tai kartioita (Davis 2001: 156) (kuva 10). Sekundaariset prosessit, kuten esimerkiksi lumi- ja loskavyöryt muokkaavat talusrinteitä

(Hjort 2006: 18). Talukset ovat kaikkein yleisimpiä periglasiaalisissa ympäristöissä, missä maisema on menneiden jääkausien jäljiltä jyrkkäpiirteistä ja pakkasrapautuminen toimii tehokkaasti. Kuten muutkin nopeat massaliikunnot, kivivyöryt ovat kausittaisia. Ne myös vaihtelevat suuresti voimakkuudeltaan ja alueelliselta esiintymiseltään jyrkän teellä (French 2007: 235). Hyvin kehittyneellä jyrkän teellä talukset ovat lajittuneita: pienemmät kivet ovat lähellä jyrkännettä suurempien ollessa rinteiden alaosassa (Washburn 1979: 232). Kivivyöryjen esiintymiseen vaikuttavat suuresti kallioperä, jäätymis-sulamissykliin määrä sekä kosteusolot (Lewkowicz 1988: 347; Matsuoka & Sakai 1991: 321–324).



Kuva 10. Talus kalliiojyrkänteen alapuolella Pikku-Mallan itärinteellä 12.7.2010 noin 510 m mpy.

#### 2.4.3 Rapautuminen

Rapautumisen tehokkuus on luonteenomaista periglasiaalisille ympäristöille. Veden faasimuunnos nesteestä kiinteäksi aiheuttaa sen laajenemisen 9 %, jolloin se ja jääkiteiden pitkittäinen kasvu kallioperän raoissa sekä huokostilassa aiheuttaa 2100 kg/cm<sup>2</sup> maksimi-paineen ja kiviaineksen hajoamisen (Washburn 1979: 73; French 2007: 63). Veden olemassaolo ja sen määrä ovat tärkeitä muuttujia rapautumisessa (Matsuoka 2001b). Tämän lisäksi kivilajilla on luonnollisesti tärkeä merkitys. Sedimentti- tai liuskekivi rapautuu helpommin kuin esimerkiksi kiteinen graniitti (Washburn 1979: 74–75). Lautridoun (1988) mukaan rapautumisen kannalta tärkeitä parametrejä ovat kiviaineksen huokosten koko, läpäisevyys, mikrorakojen määrä, jäätyksen intensiteetti

sekä saatavilla olevan veden määrä. Hall (1999: 48) painottaa, että kiven ominaisuuksien, kosteusolojen sekä lämpötilaolosuhteiden ajallinen ja alueellinen vaihtelu ovat kriittisiä tekijöitä rapautumisen esiintymiselle. Viime vuosina on yhä enemmän korostettu lämpöstressiä yhtenä tärkeimpänä rapautumismekanismina (Hall 1999; French 2007: 61). Siinä kiviaines ei pysty sopeutumaan voimakkaaseen lämpötilan vaihteluun deformatumalla, vaan se antaa periksi. Auringonsäteilyn lisäksi myös tuulella on vaikutusta tähän mekanismiin (Hall 1999: 48). Kuvissa 11 ja 12 on nähtävissä mekaanista rapautumista Ailakkavaaran rinteillä. Rapautumisella on tärkeä rooli periglasiaalisen maiseman kehityksessä, sillä se irrottaa materiaalia muiden prosessien, esimerkiksi solifluktion käyttöön (Washburn 1979: 77). Yhä enemmän ajatellaan, että roudan toimintaa on liioiteltu ja että lämpötila ei olisikaan tärkein rapautumista kontrolloiva tekijä kylmässä ilmastossa (French 2007: 49).



Kuvat 11 ja 12. Mekaanista rapautumista Ailakkavaaran pohjois- ja luoteisrinteellä kuvattuna 4.7. (kuva 11) ja 5.7.2010 (kuva 12). Korkeudet merenpinnasta ovat 850 ja 750 metriä.

Mekaanisen rapautumisen muodoista suurimpia ovat laajat rapautumiskivikot, jotka peittävät tunturien rinteitä (Washburn 1979: 220) (kuva 13). Toinen periglasiaalisessa ympäristössä tavallinen muoto on tor. Se on kallioperän eroosiojääne, jonka syntyyn on vaikuttanut hyvin kehittynyt kallioperän rakosteemi sekä pohjaveden toiminta (Washburn 1979: 78).

Suolan rooli rapautumisessa kylmässä ilmastossa vaatii lisää tutkimusta, mutta sen

tiedetään olevan merkittävä tekijä kuivilla ja kylmillä alueilla (Hall et al. 2002: 593). Suolarapautuminen toimii yleensä yhteistyössä pakkasrapautumisen kanssa. On osoitettu, että jotkin normaalisti rapautumista hyvin kestävät kivilajit tulevat hyvin alttiiksi mekaaniselle kulutukselle, kun ne altistuvat suolaliuokselle. Suola edistää rapautumista ainakin kahdella mekanismilla: pintahaihdunnan ansiosta suola kerrostuu kiven pinnalle tukkien huokoset ja raot. Tämä lisää jäätyneen veden aiheuttamaa painetta. Toiseksi suolakiteiden kasvu yhdessä jääkiteiden kanssa saattaa edistää mekaanista rapautumista (French 2007: 72).



Kuva 13. Lohkarekenttää Ailakkavaaran lounaisrinteellä 8.7.2010 noin 870 m mpy.

Kemiallisen rapautumisen roolia periglasiassa ympäristössä on vähätelty, vaikka se joidenkin arvioiden mukaan on prosessina jopa mekaanista rapautumista tehokkaampi (French 2007: 68). Perinteinen argumentti on, että alhaiset lämpötilat hidastavat kemiallisia prosesseja, vaikka esimerkiksi hiilidioksidi liukenee helpommin veteen juuri alhaisissa lämpötiloissa (Lautridou 1988: 14; Hall et al. 2002: 581). Tällöin puhutaan usein kalkkikiven rapautumisesta ja siitä seuraavasta karstimaisemasta (French 2007: 69). Koska lumi toimii sekä eristeenä, että kosteuden lähteenä, voidaan olettaa lumenviipymäalueiden olevan paikallisia kemiallisen rapautumisen keskittymiä (Lautridou 1988: 15). Myös biologinen rapautuminen on yleistä periglasiassa ympäristöissä aiheuttaen kiviaineksen hajoamista monimutkaisten kemiallis-fyysisten prosessien yhteisvaikutuksesta (Hall et al. 2002: 595–596; French 2007: 79).

#### 2.4.4 Deflaatio

Koska periglasiassa ympäristössä kasvillisuus on usein matalaa, on tuulen kulutus- ja kasaustoiminta tehokasta (Seppälä 2004a: 36; Seppälä 2005b: 361). Tuulella on ratkaiseva rooli lumen uudelleen kerrostajana vaikuttaen täten kryoturbaation lisäksi esimerkiksi rinteiden valuntaprosesseihin (French 2007: 265). Deflaatiolla tarkoitetaan tuulieroosiota, joka irrottaa hienojakoista maa-ainesta ja kasaa sitä toisaalle. Tuloksena on erilaisia deflaatiopintoja sekä -painanteita. Toimiakseen deflaatio tarvitsee sopivan raekoon omaavan maaperän, joka on melko hyvin lajittunut, huonosti kehittyneen kasvillisuuden sekä matalan pohjaveden tason (French & Demitroff 2001; Seppälä 2004a: 142, 145; Hjort 2006: 22). Myös aktiivikerroksen syvyys ja metsäpalot ovat deflaatioon vaikuttavia tekijöitä (Seppälä 1995: 808; Bateman & Murton 2006: 2552). Sopivaa ainesta deflaatiolle on Pleistoseenin deglasiation jälkeen jättämät glasifluviaaliset muodostumat, kuten esimerkiksi harjut ja deltat (Seppälä 1997: 82–83; Bateman & Murton 2006). Eläinten, esimerkiksi laiduntavien porojen, kuluttava vaikutus kasvittuneilla hiekkapinnoilla saattaa olla deflaatiota käynnistävä tekijä (Seppälä 2004a: 147) (kuva 14).

Deflaatiopainanne voi olla laajuudeltaan useita hehtaareja ja yli kymmenen metriä syvä (Seppälä 1995: 799). Tässä tutkielmassa deflaation yhteyteen kuuluu myös tuulen mukana kulkevien kiinteiden partikkelien kuluttava vaikutus eli abraasio (Seppälä 2004a: 119). Abraasiota ei aiheuta pelkästään tuulen mukana kulkeva mineraaliaines, vaan lumen ja jään kuluttava vaikutus on myös huomattava (Seppälä 2003: 146; Seppälä 2004: 130–131) (kuva 15). Se toimii tehokkaasti muotoihin, jotka nousevat roudan vaikutuksesta ympäristöstään korkeammalle (Seppälä 2004a: 158). Näin sillä on suuri vaikutus esimerkiksi palsoihin, joissa abraasio kuluttaa turvepintaa ja saattaa olla niiden hajoamista edistävä tekijä (Seppälä 2003). Tyypillisiä tuulen aikaansaamia muotoja periglasiassa ympäristössä ovat esimerkiksi deflaatiopainanteet, hiekkadyynit, hiekkapeitteet, lössikerrostumat, ventifaktit sekä muut tuulen muodostamat kivipinnat (Seppälä 1997: 82).



Kuva 14. Laiduntavien porojen kuluttamaa joen pengertä Ailakkavaaran pohjoispuolella 4.7.2010 noin 620 m mpy.



Kuva 15. Abraasion kuluttamaa kasvillisuutta Ailakkavaaran lounaisrinteellä 8.7.2010 noin 895 m mpy.

#### 2.4.5 Nivaatio

Nivaatio ei kuvaa pelkästään yhtä prosessia lumenviipymäympäristöissä (Thorn 1988: 10). Se on paikallista eroosiota ja lumen viipymäalueita kuvaava yleistermi, johon liittyy kiinteästi voimakkaiden sulamis-jäätymissykliä aiheuttama mekaaninen- ja



kemiallinen rapautuminen, solifluktkio sekä rinteiden eri valuntaprosessit (Thorn 1979: 42; 1988: 12; Washburn 1979: 236; French 2007: 238) (kuva 16). Nämä prosessit yhdessä tuottavat matalia nivaatio-, tai kuten Thorn (1988: 27) ehdottaa, lumenviipymäpainanteita. Lewis (1939: 153) on jakanut nivaatiopainanteet kolmeen luokkaan: poikittaisiin, pitkittäisiin sekä pyöreisiin. Näiden painanteiden muodostumiseen vaikuttavat suuresti muun muassa alueen kivilaji sekä topografiset olosuhteet (Washburn 1979: 237; Thorn 1988). Suurilla lumenviipymäpainanteilla ja onsilojäätiköillä on olemassa jatkumo (Thorn 1988: 22). Nivaatiolla on suuri potentiaali subarktisilla alueilla, sillä lumipeite on runsas monin paikoin ja täten sillä on merkittävä rooli kryoplaanaatiossa periglasiialisten alueiden maiseman kehityksessä (Washburn 1979: 237–239; Christiansen 1996: 112). Lumenviipymäpainanteet kasvavat ajan mittaan ja keräävät enemmän lunta joka vuosi (Söderman 1980: 112).

Nivaatio on aktiivisinta pohjoisrinteillä, missä suoran auringonsäteilyn määrä on pienempi. Luonnossa lumenviipymäpainanteet on mahdollista erottaa esimerkiksi matalamman ja vaatimattomamman kasvillisuuden perusteella (kuva 17). Lumenviipymäpainanteisiin voidaan liittää myös niin sanotut kivipäällysteet (engl. stone pavements). Nämä ovat usein esimerkiksi laakson pohjalla esiintyviä tiheitä kivimuodostumia, joissa kivien tai lohcareiden tasainen pinta on ylöspäin (Washburn 1979: 173; Hjort 2006: 21).



Kuva 16. Sulava lumenviipymäalue Ailakkavaaran itärinteellä 8.7.2010 noin 920 m mpy.



Kuva 17. Laaja nivaatiopainanne Ailakkavaaran länsirinteellä 2.7.2010 noin 830 m mpy.

#### 2.4.6 Fluviaaliprosessit

Kylmän ilmanalan fluviaaliprosesseilla on joitakin subarktisille alueille tyypillisiä piirteitä. Niille on ominaista hyvin voimakas kevättulvapiikki, joka johtuu lumen nopeasta sulamisesta sekä liikkuvien jäälohkojen aiheuttamasta patoamisesta. Suurimman osan vuodesta joet ovat jään peittämiä ja maaperän jäätyminen estää veden pystysuoran virtauksen (Seppälä 1983: 241; 1997: 82; Mol et al. 2000). Kasvillisuus pystyy hidastamaan veden kulkeutumista uomiin ja täten pienentämään sekä siirtämään tulvapiikkiä (French 2007: 254). Myöhemmin kesällä aktiivikerros on paksumpi ja pohjavesivarastot täyttyvät sekä evapotranspiraatio lisääntyy, jolloin esimerkiksi ukkosmyrskyn aiheuttamat rankkasateet eivät välttämättä saa aikaan suurtulvia (Clark 1988: 424).

Virtaavalla vedellä on suuri maisemaa muokkaava vaikutus periglasiialisilla alueilla. Koska lumen sulaminen tapahtuu keväällä nopeasti, yleensä noin 2–4 viikon aikana, on tulvapiikki hyvin voimakas. Vaikka sadanta onkin usein matala, noin 25–75 % koko valunnasta saattaa keskittyä vain muutamaan päivään. Tällöin aktiivikerros on matala ja maaperän jää estää veden perkoloitumisen uomien täytyessä nopeasti (French 2007: 249). Virtaama saattaa vaihdella myös vuorokauden aikana siten, että päivisin auringonsäteily sulattaa enemmän lunta ja kasvattaa täten vedenmäärää uomissa

(McCann et al. 1971: 78). Spatio-temporaaliset muutokset periglasiialisten alueiden sedimenttilähteissä aiheuttavat vaihteluita valunta ja sedimentin kuljetusmäärissä sekä lyhyellä että pitkällä aikavälillä (Orwin et al. 2010: 172). Kuvasta 18 nähdään fluviaalieroosion aiheuttamia jälkiä Saanan rinteellä.

Fluviaalisten prosessien vaikutusta periglasiialisen maiseman kehitykseen on vähätelty (McCann 1971; Clark 1988: 418). Yksi tärkeä kylmässä ilmastossa toimiva mekanismi on fluvio-terminen eroosio. Normaalin mekaanisen vaikutuksen ohella virtaava vesi pystyy sulattamaan ikiroutaa, täten esimerkiksi leikkautumaan uoman reunaan normaalia tehokkaammin (French 2007: 260). Muun muassa näiden tekijöiden vaikutuksesta periglasiialisilla alueilla on ominainen uomamorfologia. Kaikenlaisia uomatyyppejä (yksittäinen, moniuomainen, suora, meanderoiva) esiintyy, mutta kaikkein yleisin tyyppi on palmikoiva joki. Uomat ovat usein matalia ja jyrkkäreunaisia (Clark 1988; French 2007: 260) (kuva 19).

Tämän tutkielman myöhemmässä vaiheessa fluviaaliprosesseilla tarkoitetaan virtaavan veden aiheuttamia sekä kulutus- että kasaantumismuotoja. Tutkimusalueella tavattavia muotoja ovat erilaiset uomat ja sedimentin kerrostumisalueet alarinteillä.



Kuva 18. Fluviaalieroosiota Saanan etelärinteellä 9.7.2010 noin 780 m mpy.

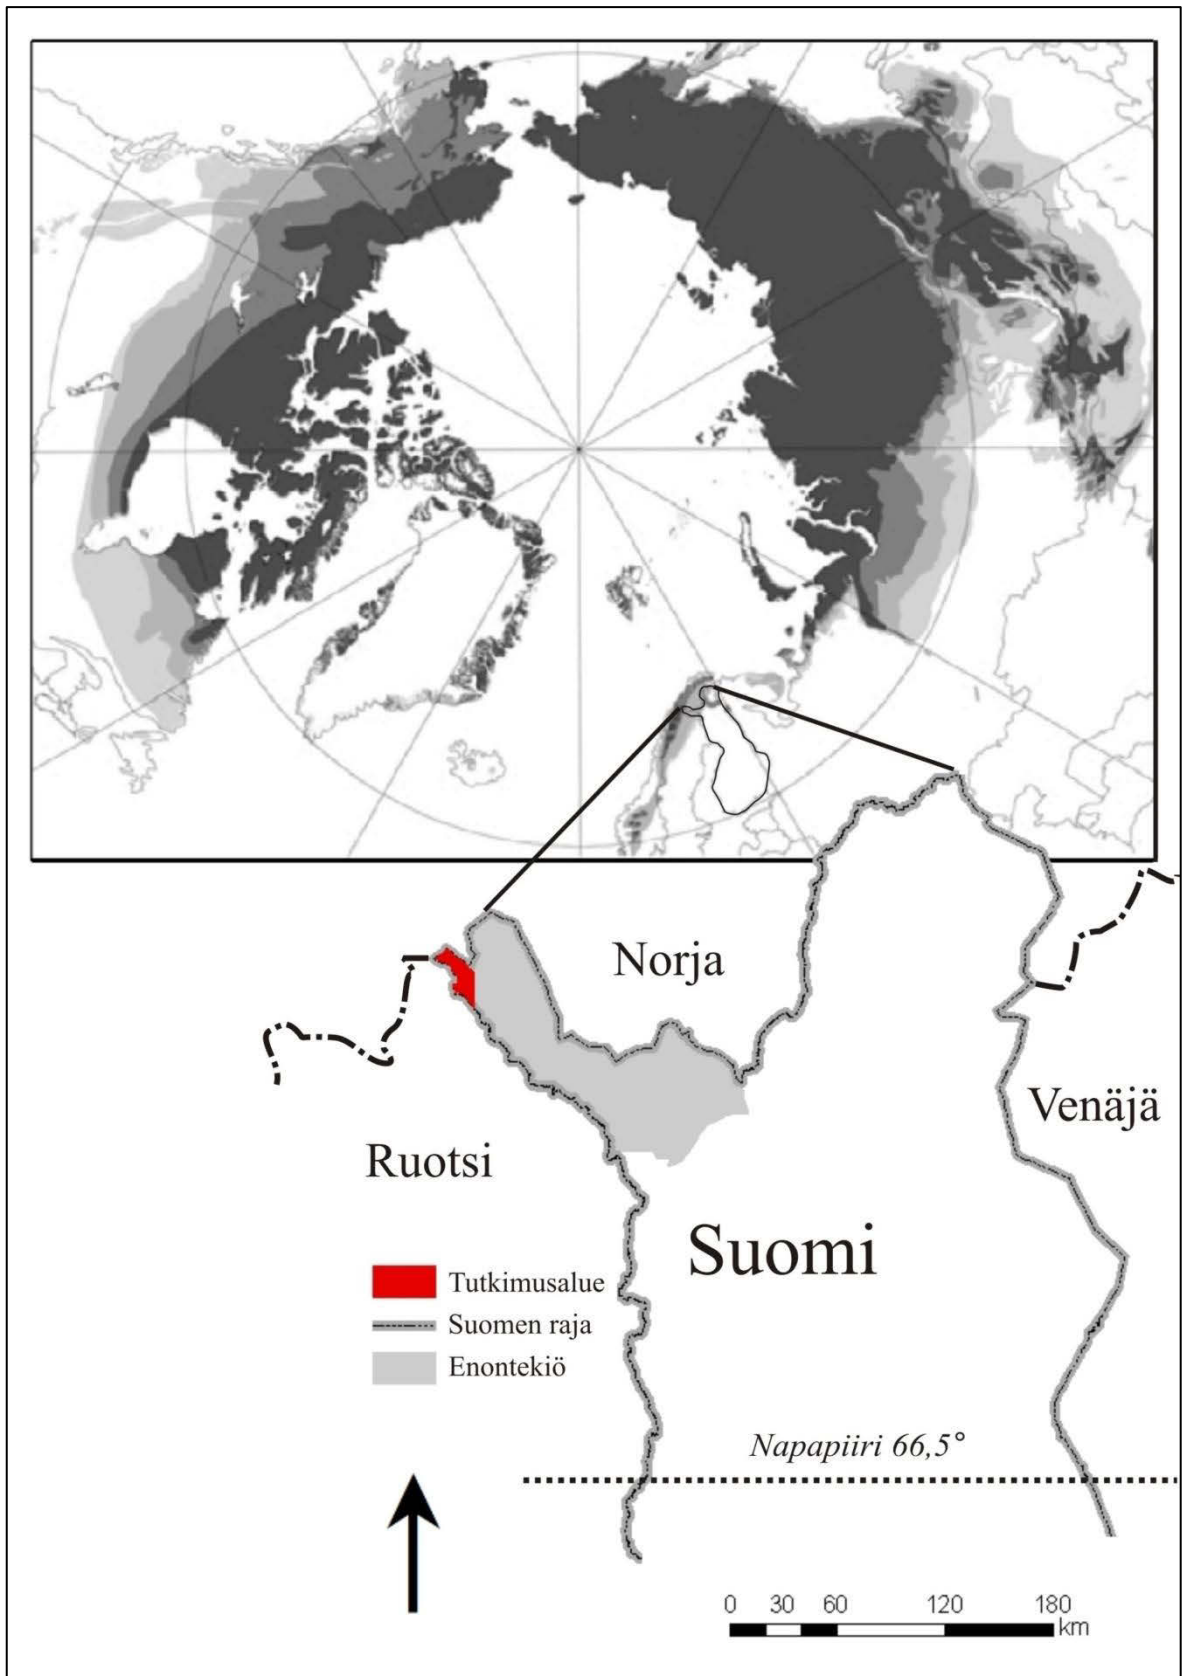


Kuva 19. Subarktisen joen uomaa Ailakkavaaran pohjoispuolella 4.7.2010 noin 620 m mpy.

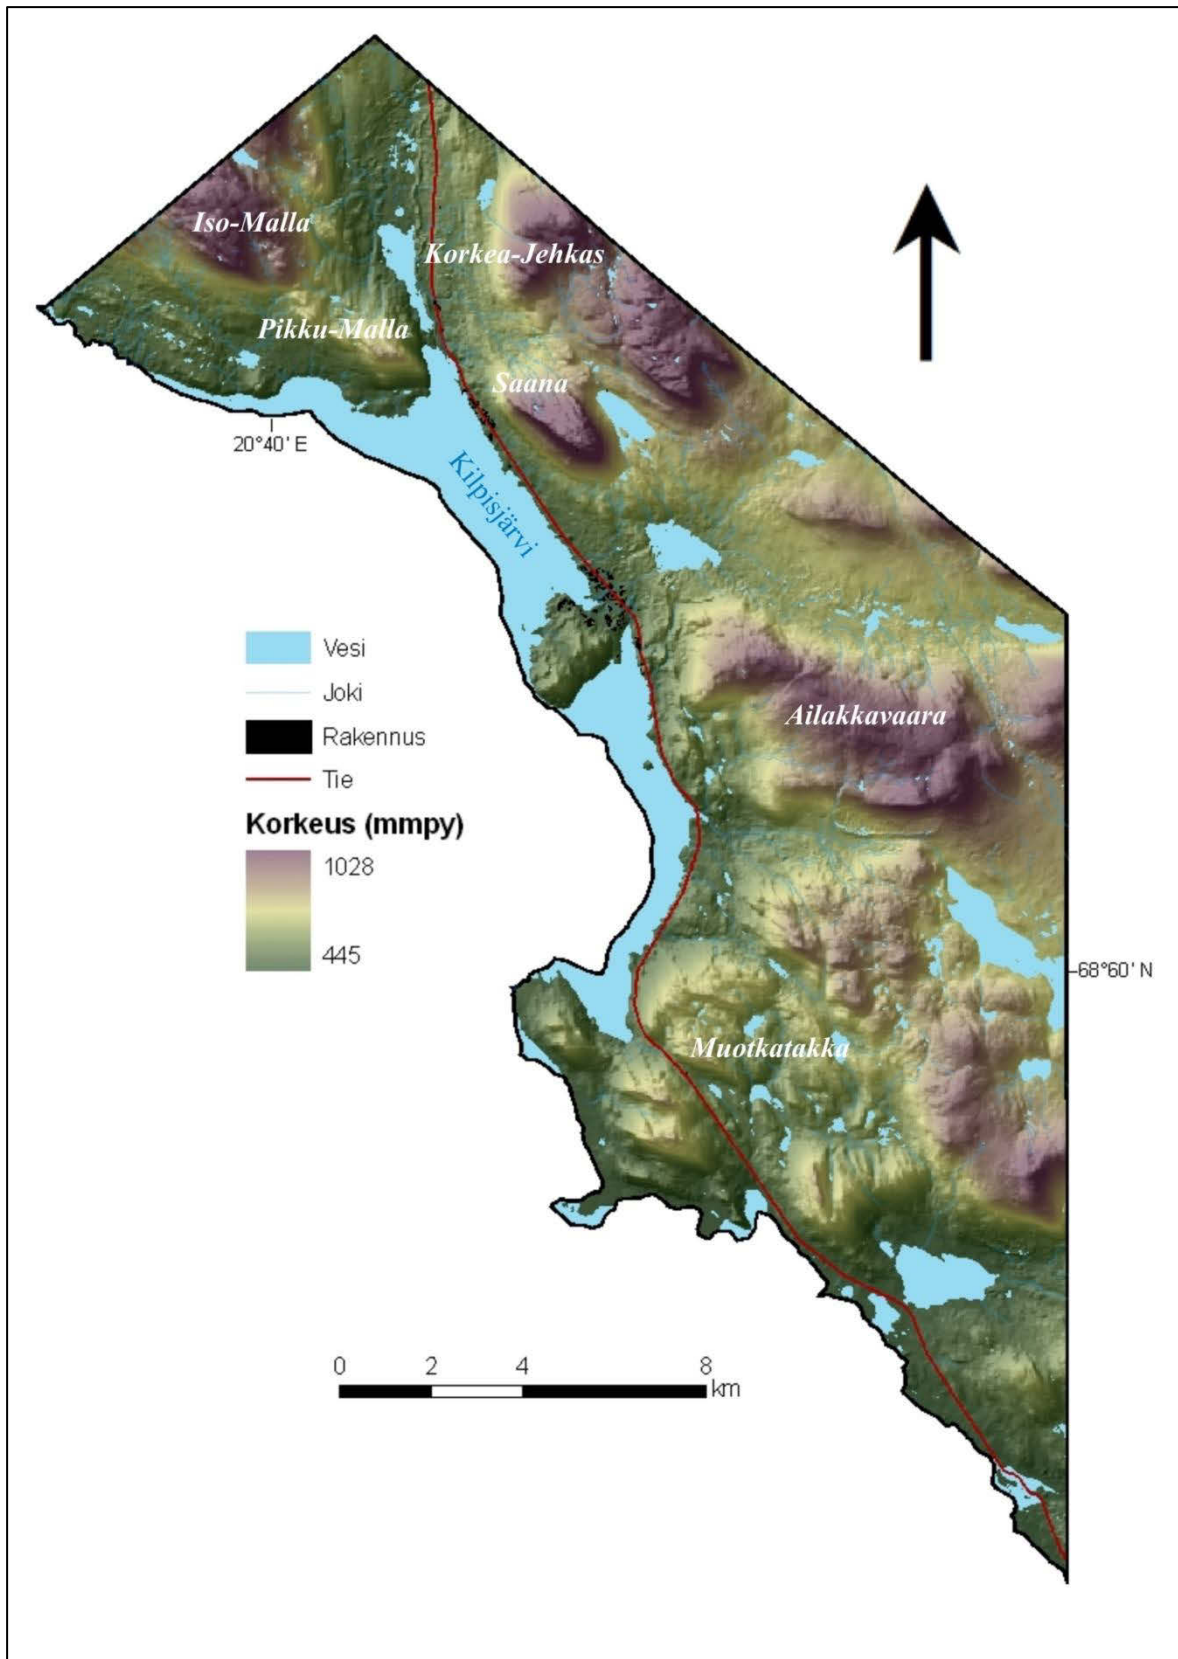
### 3. Tutkimusalue

#### 3.1 Sijainti ja topografia

Tutkimusalue sijaitsee Kilpisjärvellä Enontekiön kunnassa Käsivarren Lapissa Ruotsin ja Norjan rajojen tuntumassa epäjatkuvan ikeroudan alueella (luoteiskulma 69°07'9''N 20°42'58''E, kaakkoiskulma 68°50'29''N, 21°10'17''E) (kuva 20). Tämän suurtuntureiden alueen korkokuvatyyppi koostuu suhteellisen jyrkkärinteisistä kohoumista, joiden suhteelliset korkeuserot ovat suuria. Digitaalisen korkeusmallin perusteella korkeudet vaihtelevat 445–1028 metrin välillä, jolloin suurin suhteellinen korkeusero on 582 metriä (kuva 21). Korkein kohta on Saanan huippu 1029 m mpy (Eronen 2004: 50). Kilpisjärven pinta sijaitsee 473 m mpy, jolloin noin 1,7 km:n matkalla korkeuseroa syntyy 556 metriä (Kauppila & Salonen 1997: 146). Tutkimusalueen keskikorkeus on 631 metriä ja korkeuden keskihajonta on 130 metriä. Muita korkeita tuntureita alueella ovat Iso-Malla (noin 950 m mpy), Korkea-Jehkas (noin 950 m mpy) ja Ailakkavaara (noin 950 m mpy). Tutkimusalueen koko on 291 km<sup>2</sup>, josta vesistöjä on 35,2 km<sup>2</sup> eli noin 12 % tutkimusalueen pinta-alasta. Aivan tutkimusalueen luoteiskulmassa on Kaledonisten liuskeiden luonnehtimaa ja tektonisten liikuntojen muovaamaa vuoristoa. Ylityönnöt ovat alueella tavallisia ja liuskekallioiden kuluessa on syntynyt jyrkkiä pahtoja. Tunturien rinteillä on myös laajoja rakkakivikoita (Suomen kartasto 1986: 18).



Kuva 20. Tutkimusalueen sijainti. Harmaan eri sävyt merkitsevät ikeroudan tyyppiä, jotka ovat tummasta vaaleaan: jatkuva, epäjatkuva, satunnainen ja eristynyt (Nelson et al. 2002; tekijän muokkaama).



Kuva 21. Tutkimusalue ja sen korkeussuhteet. Aineisto on maanmittauslaitoksen maastotietokannasta (Maanmittauslaitos 2011).

### 3.2 Kallioperä

Alue kuuluu geologialtaan Kaledonidien vyöhykkeeseen, joka on muodostunut noin 450–400 miljoonaa vuotta sitten jo kerran penepaaniksi tasoittuneen vuoriston uudelleen poimuttuessa (Laitakari 1998: 321; Kujansuu 2005a: 19). Siinä muinaiset merisedimentit (konglomeraattia, hiekka- ja savikiviä sekä dolomiittista kalkkikiveä) ovat poimuttuneet ja työntyneet toistensa sekä idässä sijaitsevan arkeaisen alueen ikivanhojen gneissien päälle 150–190 metrin vahvuisena loiva-asentoisena kerroksena. Tämän päälle on työntynyt luoteeseen kallistunut Kaledoninen gneissilaatta, joka koostuu myloniittisesta liuskeesta ja gneissistä (Suomen kartasto 1990: 3). Ylityöntökompleksille tyypillistä kivilajia kutsutaan myös tunturiliuskeeksi (kuva 22). Vyöhykkeeseen kuuluu myös mafisia ja ultramafisia syväkiviä, jotka ovat tunkeutuneet ylityöntölaattojen sisään ja väleihin (Suomen kartasto 1990: liite 1; Laitakari 1998: 321).



Kuva 22. Tunturiliusketta Saanan luoteisrinteellä 12.7.2010. Korkeus merenpinnasta ei tiedossa.

### 3.3 Deglasiatio ja maaperä

Veiksel-jäätikön virtaussuunta tutkimusalueella on ollut kaakosta luoteeseen (Johansson 2005: 80). Kilpisjärven alue vapautui Skandinavian mannerjään alta noin 9 500 vuotta sitten, jolloin sen eteläpuolelle patoutui lyhytaikainen jääjärvi, jonka vedenpinta oli korkeimmillaan 95 metriä nykyisen pinnan yläpuolella (Kauppila & Salonen 1997: 146). Tutkimusalueelle on tyypillistä rapautumissora tunturien lakialueilla. Yleisin

maalaji on moreeni, jota on noin 45 % tutkimusalueesta. Sitä esiintyy alueella ohuena pohjamoreenipeitteenä. Suuri osa (36 %) tutkimusalueen maaperästä on kalliota ja louhikkoa. Hiekka- ja sorakerrostumia on tutkimusalueella hyvin vähän, vain noin 3 % koko alasta (GTK 2010a). Tutkimusalueella on yksi lähes pohjois-eteläsuuntainen harju (Suomen kartasto 1986: 18; Suomen kartasto 1990: liite 2). Tutkimusalue on supra-akvaattista aluetta, joten syvänmeren savikerrostumia ei esiinny ollenkaan (Suomen kartasto 1990: 11; Kujansuu 2005b: 77). Orgaanisia kerrostumia tutkimusalueella on melko vähän, vain noin 4 % koko pinta-alasta. Ne sijaitsevat alavilla, tasaisilla alueilla tunturien välissä. Vallitseva maannostyyppi on podsolimaannos (Mikkola & Sepponen 1986: 4).

### **3.4 Ilmasto ja hydrologia**

Kilpisjärven alueen ilmasto on subarktinen ja siihen vaikuttavat hyvin monet eri tekijät. Fennoskandia sijaitsee niin sanotulla polaaririntamalla, jossa yleensä lännestä itään länsituulten mukana liikkuvat matalapaineet muuttavat vallitsevaa säätilaa hyvinkin nopeasti. Orografisen vaikutuksen ansiosta suurin osa länsituulten kuljettamasta kosteudesta on tiivistynyt sateeksi Skandien länsipuolella. Tämä nostaa lämpötiloja sekä vähentää kosteutta vuoriston itäpuolella. Golf-virran läheisyys nostaa alueen keskilämpötiloja huomattavasti (Tikkanen 2005). Seuraavat tiedot on koottu Enontekiön Kilpisjärven meteorologiselta asemalta (69°02'N 20°47'E, korkeus merenpinnasta 480 metriä) (Drebs et al. 2002: 74–75). Vuoden keskilämpötila kaudella 1971–2000 oli -2,3 °C, sekä vaihteluväli +1,8 °C ja -6,6 °C. Absoluuttinen ylin lämpötila oli +27,8 °C (vuonna 1971) ja alin -41,9 °C (vuonna 1977). Päiviä, jolloin lämpötila on alle -10 °C, on ollut vuodessa keskimäärin 128 kappaletta. Maksimilämpötila alle 0 °C on ollut 156 päivänä ja minimilämpötila alle 0 °C 240 päivänä (Tilastoja Suomen ilmastosta 1991). Vuoden sademäärä on keskimäärin 458 mm. Sadepäiviä vuodessa (>0,1 mm sadetta) on keskimäärin 210 (58 %), sekä suhteellinen kosteus 79 %. Sateisimpia kuukausia ovat heinä- ja elokuu, jolloin sataa 116 mm eli noin 25 % vuotuisesta sadannasta. Vähiten sataa maaliskokuussa yhteensä 76 mm, joka on noin 17 % vuoden sademäärästä. Lumipeite on yhdeksän kuukautta vuodessa alkaen syyskuun lopulta kestäen aina toukokuun loppuun saakka. Lumipeitteen keskisyvyys on noin 53 cm. Routakausi Enontekiöllä kestää noin kahdeksan kuukautta (Suomen kartasto 1986: 16). Roudan



maksimisyvyys lumesta raivatulla moreenimaalla on noin 200 cm (vuosien 1955-1975 keskiarvo) (Suomen kartasto 1987: 14). Kilpisjärvellä on osoitettu tilastollisesti merkitsevä nousu sekä lämpötilojen, että sademäärän suhteen vuosien 1961-2008 väliseltä ajalta (Virtanen et al. 2010: 4-5).

Tutkimusalueen suurin järvi on Kilpisjärvi, jonka koko on 37,1 km<sup>2</sup> ja tilavuus 742 Mm<sup>3</sup>. Sen keskisyvyys on 20 metriä sekä syvin kohta 57 metriä. Kilpisjärven valuma-alueen koko on 271 km<sup>2</sup> (Kauppila & Salonen 1997: 146). Alueen muita järviä ovat esimerkiksi Ailakkajärvi (3,01 km<sup>2</sup>), Čähkajärvri (1,11 km<sup>2</sup>), Siilasjärvi (0,97 km<sup>2</sup>), sekä Saanajärvi (0,74 km<sup>2</sup>). Kuten jo aiemmin on todettu, tutkimusalueella on subarktiselle alueelle tyypilliset hydrologiset olot. Tämä näkyy hyvin voimakkaina kevättulvina, jolloin fluviaaliprosessit ovat erityisen aktiivisia.

### 3.5 Kasvillisuus

Tutkimusalueen kasvillisuus vaihtelee Saanan lounaisrinteiden rehevistä lehdoista tuntureiden huippujen karuihin paljakoihin. Koivumetsärajan korkeus vaihtelee ekspositiosta riippuen 550–700 metrin välillä (kuva 23). Varpu- ja jäkäläkankaat ovat vallitsevia. Ruohoisia ja runsassammaleisia tuoreita kankaita esiintyy ainoastaan vesistöjen läheisyydessä sekä Kilpisjärven alueen ravinteisilla ja mereisillä alarinteillä. Tunturien rinteet ovat tunturikoivun (*Betula pubescens* ssp. *czerepanovii*) peittämiä (Mikkola & Sepponen 1986: 4; 26) (kuva 24). Metsärajan yläpuolella on puuton tunturipaljakka, joka alkaa matalalla pensaskasvillisuudella. Tämän muodostavat pajut (*Salix*), vaivaiskoivu (*Betula nana*) ja kataja (*Juniperus communis* ssp. *alpina*) (Laine 2004: 83). Ylöspäin mentäessä alkaa esiintymään mustikkaa (*Vaccinium myrtillus*) sekä variksenmarjaa (*Empetrum nigrum*) (Eurola et al. 2003: 20). Tuntureiden huipuilla kasvillisuus on hyvin matalaa, usein vain 10–20 cm korkea. Laiduntavilla poroilla on suuri kasvillisuutta kontrolloiva vaikutus erityisesti tuottavuudeltaan alhaisemmillä alueilla (Virtanen et al. 2010: 8). Tutkimusalueella esiintyy paljon paljaita kivilouhikoita eli rakkoja, joiden kasvillisuuden muodostavat pääosin jäkälät, sammaleet ja muutamat harvat putkilokasvit. Paljakalla kasvillisuus vaihtelee suuresti vallitsevien lämpötila-, kosteus- ja ravinneolosuhteiden mukaan. Myös geomorfisilla prosesseilla on suuri merkitys (Laine 2004: 83).



Kuva 23. Metsärajaa Pikku-Mallan etelä-rinteellä 12.7.2010 yli 550 m mpy.



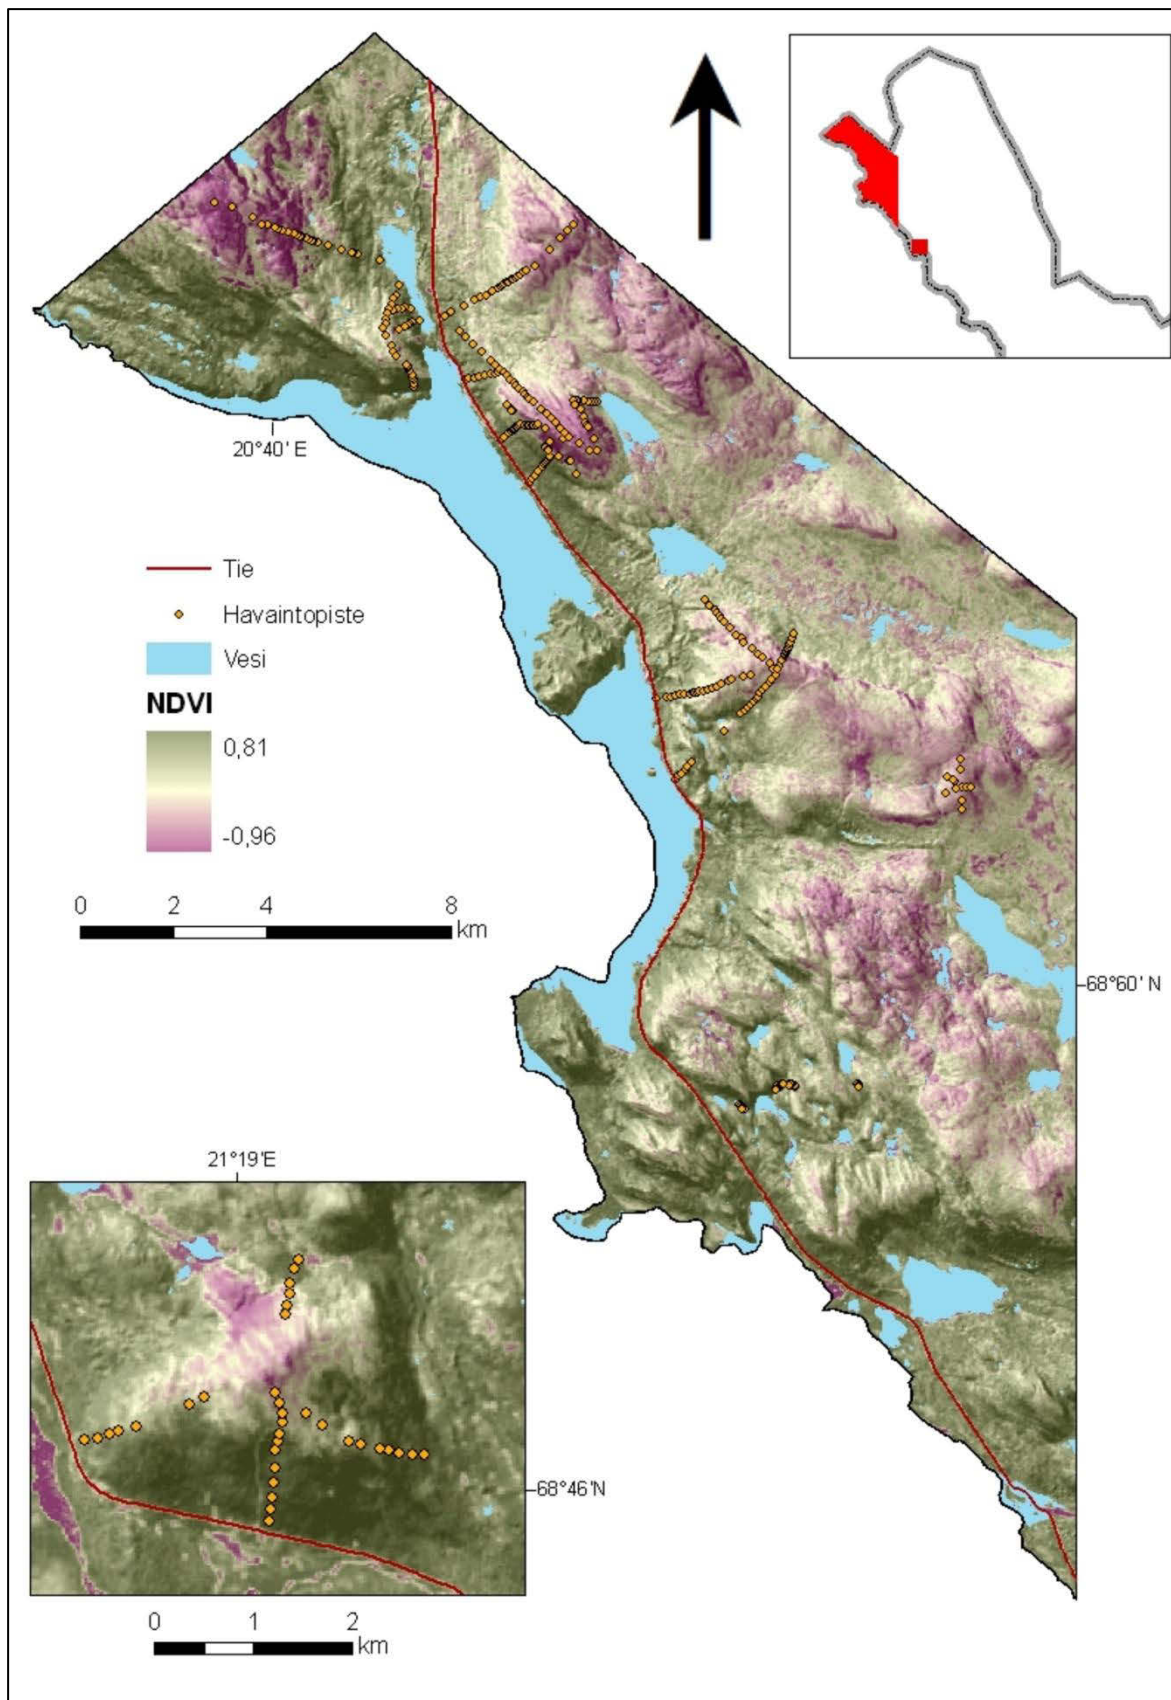
Kuva 24. Tunturikoivikkoa (*Betula pubescens* ssp. *czerepanovii*) Saanan lounaisrinteellä 9.7.2010. Korkeus merenpinnasta ei tiedossa.

## 4. Aineisto ja menetelmät

### 4.1 Mallinnusaineisto

#### 4.1.1 Havaintoaineisto

Tutkimuksen havaintoaineisto koostuu 369 koealasta, jotka on tutkittu kesien 2009 ja 2010 aikana professori Miska Luodon, professori Jan Hjortin sekä kirjoittajan toimesta. Aineisto on pääosin kerätty muodostaen suoria linjoja korkeuskäyriä vasten Saanalla (6 kpl), Iso-Mallalla (1 kpl), Pikku-Mallalla (3 kpl), Korkea-Jehkaksella (1 kpl), Ailakkavaaralla (4 kpl) ja Lammasóavilla (4 kpl) (Virtanen et al. 2010) (kuva 25). Linjat ovat suunniteltu antamaan mahdollisimman hyvä kuva tutkimusalueen geomorfologisesta aktiivisuudesta tarjoamalla kattavia gradientteja ja ottamalla huomioon eksposition vaikutus. Näiden linjojen lisäksi havaintoja on tehty hyödyntäen aikaisemmin tehtyjen tutkimusten koealoja Saanalla ja Muotkatakan alueella (esim. Virtanen et al. 2010). Tutkimuslinjoilla havaintoja tehtiin 20 korkeusmetrin välein. Koeala kattoi 10 x 10 metriä, joissa havainnoitiin kunkin tutkittavan geomorfologisen ilmiön (6 kpl) aktiivisuutta 0-100 %. Prosessin aktiivisuus määritettiin perustuen kivien ja lohcareiden jäkäläpeitteeseen, rapautumiseen, yleiseen maaperän ja kasvillisuuden häiriöön sekä kasvillisuuden tiheyteen (Washburn 1979: 133; Harris 1994: 187; Luoto & Hjort 2004: 329). Jos ilmiötä oli edes hieman, se sai arvon yksi. Koealojen keskipisteen sijainti tallennettiin YKJ-koordinaatistoon (KKJ3) GPS-laitteella (Garmin eTrexVenture CX), jonka sijaintitarkkuus on alle 15 metriä (Garmin 2011). Havaintopisteiltä kerättiin monia muitakin ominaisuustietoja, mutta niitä ei käytetty tulevissa mallinuksissa, sillä ne eivät ole koko tutkimusalueen kattavaa informaatiota.

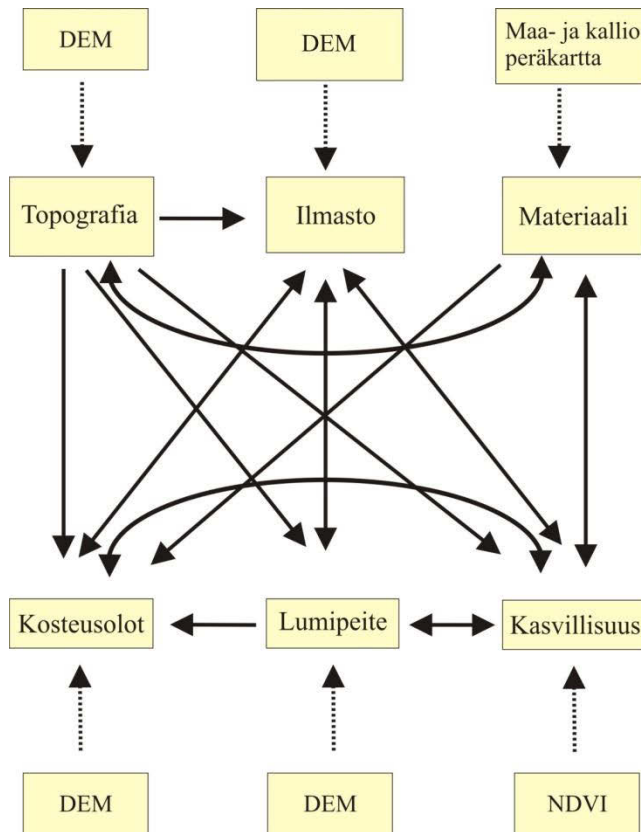


Kuva 25. Koalojen sijainti tutkimusalueella ja Lammasöavilla. Osa aineistosta on maanmittauslaitoksen maastotietokannasta (Maanmittauslaitos 2011).

#### 4.1.2 Selittävät ympäristömuuttajat

Alueellisessa mallinnuksessa käytettäviä selittäviä ympäristömuuttujia voidaan kerätä useasta eri lähteestä. Niistä voidaan erottaa neljä tärkeintä: kenttätutkimukset, paperi- tai digitaaliset kartat, kaukokartoitusaineistot sekä paikkatietojärjestelmillä tuotetut kartat (Guisan & Zimmermann 2000: 156). Kenttätöyt ovat usein suurin kustannuserä sekä eniten aikaa vieviä toteuttaa (Etzelmüller 2006). Kaukokartoitusaineistolla on mahdollista saada nopeasti ja helposti alueellisesti kattavaa jatkuvaa informaatiota. Ehkä tärkein yksittäinen selittävien ympäristömuuttujien lähde on digitaalinen korkeusmalli (DEM = Digital Elevation Model) (Etzelmüller 2001: 85; Hjort & Luoto 2005: 313). DEM:stä on mahdollista laskea helposti useita erilaisia topografisia muuttujia, joilla on suuri rooli geomorfisia prosesseja selitettäessä (kuva 26).

Tässä tutkimuksessa on käytetty Henri Riihimäen (julkaisematon) tekemää digitaalista korkeusmallia. DEM on interpoloitu ArcInfon *topo to grid* -komennolla käyttäen maastotietokannasta saatuja korkeuskäyriä (2,5 metrin käyräväli), järvien pintojen korkeustietoja sekä yksittäisiä korkeuspisteitä (Willison 2001; Maanmittauslaitos 2011). Syntyneen korkeusmallin spatiaalinen resoluutio on 10 metriä. Korkeusmallista laskettiin yhteensä 14 muuttujaa, joista 11 on puhtaasti topografisia muuttujia. Kuvassa 27 on esitetty kolme korkeusmallista laskettua muuttujaa, joita käytettiin mallinnuksessa. Korkeus ja rinteenkalltevuus ovat tärkeitä epäsuoria muuttujia, jotka kertovat esimerkiksi alueen lämpötilasta, lumen jakaantumisesta sekä potentiaalienergiasta (Hjort 2006: 38). Digitaalisesta korkeusmallista laskettiin korkeuskartta hehtaarin resoluutioon käyttämällä *zonal statistics* -työkalua (Willison 2001). Samalla työkalulla laskettiin korkeudesta myös maksimiarvo, minimiarvo, keskihajonta sekä vaihteluväli. Rinteen kaltevuuskartta laskettiin digitaalisesta korkeusmallista *slope*-työkalulla. Tästä kartasta laskettiin keskiarvo, keskihajonta sekä maksimiarvo hehtaarin resoluutioon *zonal statistics* -työkalulla. Alkuperäisestä rinnekartasta laskettiin myös kartta kuvaamaan tasaisen maaston ( $< 2^\circ$ ) osuutta tutkimusalueella. Se ilmoitetaan prosentteina hehtaaria kohden (Hjort 2006: 38–39).



Kuva 26. Periglasiaalsiin prosesseihin vaikuttavien tekijöiden päävuorovaikutussuhteet. Uloimmat laatikot viittaavat aineiston lähteeseen (Hjort 2006, tekijän muokkaama).

Korkeusmallista laskettiin myös korkeus-reliefisuhte kuvaamaan alueen topografisia olosuhteita. Se laskettiin kaavalla (Pike & Wilson 1971: 1079):

$$E = (Z_{\text{mean}} - Z_{\text{min}}) / (Z_{\text{max}} - Z_{\text{min}}) \quad (1)$$

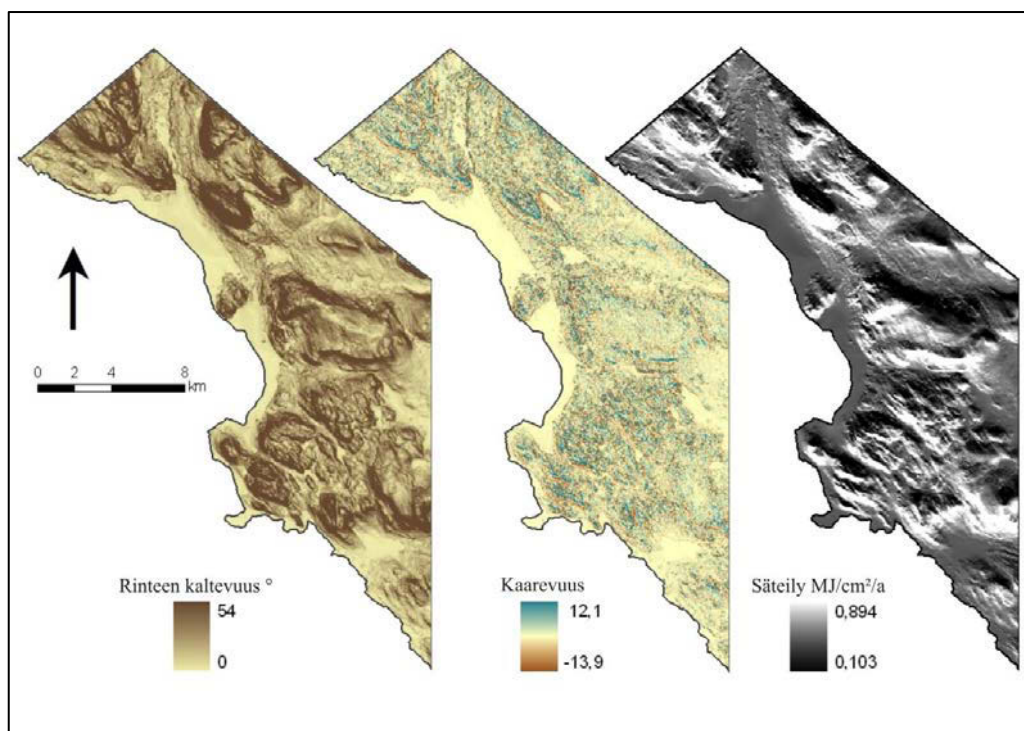
missä  $Z$  on korkeus. Korkeus-reliefisuhteen arvo vaihtelee 0-1. Arvo 0,5 viittaa normaalisti jakautuneeseen ja arvo lähellä nollaa hyvin vinoutuneeseen korkeusjakaumaan mallinnusneliön sisällä. Digitaalisesta korkeusmallista voidaan laskea myös alueen kuperuutta/koveruutta kuvaava arvo Arc Map:n *curvature*-työkalulla. Positiiviset arvot kuvaavat kuperia maastonmuotoja ja negatiiviset koveria muotoja (Willison 2001; Luoto & Hjort 2004: 331). Curvature (suomeksi kaarevuus) kartasta laskettiin keskiarvot mallinnusresoluutioon (1 ha) *zonal statistics* -työkalulla.

Käyttökelpoinen DEM:stä laskettava alueen kosteusolojen kuvaaja on topografinen kosteusindeksi (TWI = Topographical Wetness Index), joka lasketaan seuraavasti (Beven & Kirkby 1979; Sørensen et al. 2005: 1808):

$$\omega = \ln(A_s / \tan\alpha) \quad (2)$$

missä  $A_s$  on ylärinteen veden kerääntymisalue ja  $\tan\alpha$  on rinnekulma radiaaneina. Ennen TWI:n laskemista DEM tulee ”täyttää” interpolointivirheiden aiheuttamista kuopista, jotta se olisi hydrologisesti eheä. Kosteusindeksi on laskettu ArcView 3.2 ohjelman *Terrain analysis* -ekstensiolla (Moore 1991). Myös TWI:stä laskettiin keskiarvo mallinnusresoluutioon *zonal statistics* -työkalulla.

Potentiaalinen vuosittainen suoran auringonsäteilyn määrä ( $\text{MJ}/\text{cm}^2/\text{a}$ ) laskettiin myös korkeusmallista erillisellä koodilla ArcView 3.2 -ohjelmalla. Säteily laskettiin tunnin aikaväleillä ja ilmakehän transmissiviteetin oletettiin olevan 0,9 (McCune & Keon 2002: 603). Myös säteilyarvoista laskettiin keskiarvot mallinnusresoluutioon Arc Map:n *zonal statistics* -työkalulla. Lämpötilaa ja säteilyä epäsuorasti kuvaava muuttuja on aspekti, joka on rinteiden avautumissuunta (Etzelmüller et al. 2001: 81; McCune & Keon 2002: 603). Sillä on tärkeä rooli esimerkiksi kallioperän rapautumista selitettäessä (Hall et al. 2002: 579). Aspekti kartta tehtiin ArcMap:n *aspect*-työkalulla. Tuloksena on kartta, jossa rinteiden suunta on ilmoitettu kompassisuuntina 0-360. Siitä laskettiin *zonal statistics* -työkalulla mallinnusresoluutioon *majority*, eli se suunta, johon suurin osa rinteistä avautuu mallinnusruudun sisällä (Willison 2001).



Kuva 27. Esimerkkejä digitaalisesta korkeusmallista lasketuista selittävästä ympäristömuuttujista.

Geomorfologisia prosesseja selittävät eri alueilla eri tekijät. Hjortin ja Luodon (2009: 324) mukaan subarktisella alueella kasvillisuus on yksi tärkeimmistä geomorfologisiin prosesseihin vaikuttavista tekijöistä. Kasvillisuus muovaa geomorfisia prosesseja ja näin ollen maanpinnan muotoja (Stallins 2006). Corenblitin ja Steigerin (2009: 892) mukaan kasvillisuus olisi jopa yksi merkittävimmistä geomorfisista vaikuttajista aiheuttamalla biomekaanista häiriötä geomorfisiin systeemeihin. Erittäin käyttökelpoinen kasvillisuuden estimaattori on normalisoitu kasvillisuusindeksi NDVI (=Normalized Difference Vegetation Index), joka voidaan laskea multispektraalisista satelliittikuvista. Se on punaisen ja lähi-infrapuna-kanavan normalisoitu suhde ja se lasketaan seuraavalla kaavalla (Tucker 1979):

$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED}) \quad (3)$$

missä NIR on lähi-infrapuna- ja RED on punaisen aallonpituuden kanava. Tutkimuksessa käytettävä Landsat ETM+ kuva on otettu kesäkuussa 2000 kasvukauden aikana. Ennen NDVI:n laskemista satelliittikuvalle on tehty ilmakehä- ja topografikorjaus (Virtanen et al. 2010: 812). NDVI-arvosta laskettiin keskiarvo mallinnusresoluutioon *zonal statistics* -toiminnolla. Kuvasta 25 nähdään kasvillisuuden vaihtelua tutkimusalueella perustuen NDVI-arvoon.

Periglasiialisten ilmiöiden esiintymiseen vaikuttaa suuresti alueen kallioperä. Se ei pelkästään selitä ilmiöiden esiintymistä, vaan myös prosessien nopeutta sekä niiden säilyvyyttä (French 2007: 28). Esimerkiksi hienorakeinen hiekkakivi on huomattavan altis mekaaniselle rapautumiselle (Hall 2002: 594). Kallioperä aineistona käytettiin digitaalista kallioperäaineistoa, jonka spatiaalinen resoluutio on 20 x 20 m (GTK 2010b). Se luokiteltiin uudelleen kahteen kivilajiluokkaan: sedimentti- ja metamorfisiin kiviin. Maaperä vaikuttaa periglasiialisiin prosesseihin, sillä eri maalajeilla on erilaiset fyysiset ominaisuudet. Hienorakeiset maalajit sekä turve pidättävät kosteutta paremmin ja ovat alttiimpia roudan toiminnalle, kuin hiekka- ja soramaat (Washburn 1979: 11–15, 67–68; French 2007: 52). Aineistona käytettiin digitaalista maaperäaineistoa, jonka spatiaalinen resoluutio on 20 x 20 m (GTK 2010a). Käytetyt maaperäluokat ovat turve, moreeni, hiekka- ja soramaat sekä louhikko- ja kalliomaat. Lähes kaikissa kartoissa on käytetty visualisointi tarkoituksessa taustalla rinnevarjostuskuvaa, joka on tehty digitaalisesta korkeusmallista Arc Map:n *Hillshade*-



työkalulla käyttäen seuraavia oletusparametrejä: auringon atsimuuttikulma  $315^\circ$  ja korkeuskulma  $45^\circ$  (Willison 2001).

#### 4.1.3 Selittävien ympäristömuuttujien valinta

Sopivien selittävien ympäristömuuttujien valinta riippuu periglasiaalisiin prosesseihin vaikuttavista tekijöistä, aineiston saatavuudesta ja mallin tarkoituksesta (Austin 2007: 6). On hyvin tärkeää kiinnittää huomiota siihen, onko käytettävillä muuttujilla suora vai epäsuora yhteys tutkittavaan ilmiöön. Suorat ympäristömuuttujat vaikuttavat suoraan ilmiön esiintymiseen (esimerkiksi lämpötila). Epäsuorat muuttujat (esimerkiksi rinnekaltevuus, korkeus, aspekti) eivät vaikuta suoraan ilmiöön, vaan korreloivat suorien muuttujien kanssa. Suorat muuttujat ovat usein pistemäisenä aineistona ja niiden muuttaminen alueellisesti kattavaksi esimerkiksi interpoloimalla tuo analyysihin uusia virhelähteitä. Epäsuorat muuttujat ovat usein helpommin mitattavissa (Guisan & Zimmermann 2000: 151, 157; Austin 2007: 6; Luoto & Hjort 2006: 292).

Periglasiaalisia ilmiöitä selittäviä ympäristömuuttujia oli alunperin 18 kpl (liite 2). Muuttujien suuren määrän lisäksi moni korreloi hyvin voimakkaasti keskenään (Spearmanin järjestyskorrelaatiokerroin  $R_s$  jopa 0,995). Tällä multikollineaarisuudella voi olla vakavia vaikutuksia tilastollisiin analyysihin luoden niihin virheitä ja epävarmuutta (Graham 2003: 2814). Tästä syystä, jos kahden ympäristömuuttujan välinen Spearmanin korrelaatiokertoimen itseisarvo ylitti 0,7 toinen niistä poistettiin analyysistä (Sormunen et al. 2010; Hjort et al. 2010). Esimerkiksi keskikorkeus ja NDVI korreloivat hyvin voimakkaasti keskenään ( $R_s=-0,882$ ). Myös rinte keskikaltevuudella ja topografisella kosteusindeksillä oli hyvin voimakas tilastollinen riippuvuus ( $R_s=-0,978$ ). Tällaisessa tapauksessa on turha pitää molempia muuttujia mukana. Valinta tehtiin muun muassa sen perusteella, montaa muuta muuttujaa se mahdollisesti selittäisi. Monen topografisen muuttujan (esimerkiksi korkeuden maksimiarvo, korkeuden keskihajonta ja rinte maksimikaltevuus) mukaan ottaminen mallinnukseen oli turhaa niiden voimakkaan korreloinnin esimerkiksi keskikorkeuden kanssa. Taulukoissa 2 ja 3 on esitetty lopulliset ympäristömuuttujat, niiden kuvaukset sekä muuttujien väliset korrelaatiot.

Taulukko 2. Tilastollisessa mallinnuksessa käytettävät selittävät ympäristömuuttujat ja niiden kuvaukset (Washburn 1979: 10–17, Etzelmüller 2001: 82–83; McCune & Keon 2002; Hjort 2006)

Muuttuja	Kuvaus
Keskikorkeus (mmpy)	Lämpötila, lumen jakautuminen, säteilyn määrä, pilvisuus, kasvillisuus, kosteusolot
Rinteen keskikaltevuus <sup>o</sup>	Potentiaalienergia, veden virtaus, säteily, maaperän paksuus, kosteusolot
Rinteen keskikaltevuus alle 2 <sup>o</sup> (%/ha)	Kosteuden ja lumen jakautuminen
Kaarevuus	Maaston kuperuus/koveruus, veden, lumen ja sedimentin kerrostuminen, maaperän paksuus
Säteily (MJ/cm <sup>2</sup> /a)	Lämpötila, lumen jakautuminen, kosteusolot, kasvillisuus, kiven rapautuminen
Maaperä	Maaperän kosteusolot, roudan kestävyys
Kallioperä	Rapautuminen

Taulukko 3. Korrelaatiomatriisi mallinnuksessa käytetyistä selittävästä jatkuvista muuttujista (\*\* =  $p < 0,01$ ).

<i>Spearmanin järjestykskorrelaatio</i>	Keskikorkeus	Säteily	Rinteen keskikaltevuus	Rinteen kaltevuus alle 2 <sup>o</sup>	Kaarevuus
<b>Keskikorkeus</b>	1,000	-,031	,377**	-,184**	,267**
<b>Säteily</b>	-,031	1,000	,300**	-,144**	-,039
<b>Rinteen keskikaltevuus</b>	,377**	,300**	1,000	-,385**	,083
<b>Rinteen kaltevuus alle 2<sup>o</sup></b>	-,184**	-,144**	-,385**	1,000	-,022
<b>Kaarevuus</b>	,267**	-,039	,083	-,022	1,000

#### 4.1.4 Aineiston jakaminen ja mallinnusresoluutio

Havaintoaineisto (n=369) jaettiin sattumanvaraisesti (”split-sample”) kalibraatioaineistoksi (70 %, n=258) ja evaluointiaineistoksi (30 %, n=111) (Van Houwelingen & Le Cessie 1990; Luoto & Hjort 2005; Hjort 2006). Näin ennusteiden onnistumista voitiin arvioida erillisen aineiston avulla (Guisan & Zimmermann 2000: 172). Oikeastaan evaluointiaineistoa ei voida pitää täysin itsenäisenä, sillä se on otettu samasta aineistosta kuin kalibraatioaineistokin (Guisan & Hofer 2003: 1235). Jako suoritettiin R tilasto-ohjelman *sample*-komennolla (R Development Core Team 2009) (liite 3).

Mallinnusresoluutiolla on hyvin tärkeä merkitys alueellisessa analyysissä (Luoto & Hjort 2006: 290–291). Mittakaava tulisi valita tutkittavan ilmiön sekä tutkimuksen tavoitteiden mukaan (Hjort et al. 2010: 352). Spatiaalisella skaalalla tarkoitetaan kahta tärkeää ominaisuutta: aineiston resoluutiota sekä alueellista kattavuutta. Prosessi tai parametri, joka on tärkeä jollakin mittakaavatasolla, ei välttämättä ole sitä toisella (Turner 1989; Walsh et al. 1998: 193). Monia periglasiaalisia prosesseja kontrolloi lämpö- ja kosteusolot mikro- ja makrotasolla (Fronzek et al. 2006; Daanen et al. 2008: 7–8). Mesoskaalalla (resoluutio 25 m – 2 km) tärkeimpiä tekijöitä voivat olla jotkin paikkasidonnaiset tekijät esimerkiksi reliefi tai kasvillisuus (Etzelmüller et al. 2001: 81; Luoto & Hjort 2004: 328; 2006: 289; Hjort & Luoto 2009: 331). Resoluution valintaan vaikuttaa suuresti myös saatavilla oleva aineisto (Austin 2007: 4).

Tutkimuksessa käytetään rasteripohjaista lähestymistapaa, jossa malli ennustetaan säännölliselle suorakulmioiden muodostamalle verkolle (Hjort 2006; Araújo & Luoto 2007; Marmion et al. 2008). Mallinnusresoluutio oli yksi hehtaari (100 x 100 m). Tämä mesoskaalan eli maisematason resoluutio valittiin muun muassa siksi, että tutkimusalue ei ole kovin suuri, jolloin mallinnusruutujen määrä ei kasva liian suureksi. Liian karkean resoluution käyttö aiheuttaa merkittävää tiedon menetystä ja alueen fyysisten olosuhteiden vaihtelun häviämistä (Hjort et al. 2010: 352). Toisaalta liian hieno resoluutio kiihdyttää spatiaalista autokorrelaatiota, jolla on haitallinen vaikutus tilastollisiin analyysiin, joissa odotetaan havaintojen olevan itsenäisesti jakautuneita (Legendre 1993). Periglasiaalisten prosessien esiintymistä on mallinnettu hyvin vähän juuri maisematasolla, vaikka tämä on juuri se taso missä monet periglasiaaliset prosessit ovat aktiivisia (Resler 2006; Luoto & Hjort 2009). Mallinnusresoluution vaikutusta tuloksiin on tutkittu mallintamalla kryoturbaatiota ja rinneprosesseja pienelle alueelle (1 x 2 km) Ailakkavaaralla 10 x 10 metrin resoluutiossa. Vettä sisältävät ruudut on poistettu tutkimusalueelta siten, että ruudut, jotka sisältävät vettä yli 75 % hylättiin.

## 4.2 Tilastollinen mallinnus

### 4.2.1 Taustaa

Alueellinen mallintaminen on noussut tärkeäksi työkaluksi geomorfologisessa tutkimuksessa. Sen avulla voidaan saada kustannustehokkaasti uutta ja käyttökelpoista tietoa periglasiialisista prosesseista laajoiltakin alueilta, joilta ei muuten ole tietoa saatavissa (Luoto & Hjort 2005: 229). Malli voidaan määritellä käsitteeksi, joka yrittää selittää jotain osaa todellisuudesta (Wilcock & Iverson 2003: 4). Alueellisella mallilla tarkoitetaan jonkin muuttujan vaihtelun selittämistä jossakin alueellisessa kontekstissa. Alueelliset mallit ovat usein tilastollisia malleja, joissa vastemuuttujan esiintymistä selitetään eri ympäristömuuttujien avulla. Näihin malleihin sisältyy niin sanottu satunnainen komponentti. Tämä satunnaisuus edustaa ennustamatonta vaihtelua, joka voi johtua esimerkiksi mittausvirheestä, pienestä havaintoaineistosta, puuttuvista selittävästä muuttujista tai mallin kalibraatioissa tapahtuneesta virheestä (Thuiller 2004; Heikkinen et al. 2006: 761–764). Käytännössä mallinnusmenetelmät yrittävät ennustaa periglasiialisen ilmiön todennäköisyyttä tai ympäristön soveltuvuutta prosessille valittujen ympäristömuuttujien avulla (Luoto et al. 2010: 355).

Yksi tärkeä peruste alueelliseen mallintamiseen on ennusteiden tekeminen. Tällöin mallin tuloksena on usein todennäköisyys jonkin ilmiön esiintymiseen jossakin paikassa. Tilastollisten menetelmien avulla yritetään mallintaa prosessin ja ympäristön välistä suhdetta. Näin saadaan tietoa myös johonkin prosessiin eniten vaikuttavista tekijöistä (Ermini et al. 2005: 328–331). Alueellista mallinnusta voidaan hyödyntää myös hasardien kartoittamisessa, ympäristön tilan arvioimisessa sekä maankäytön suunnittelussa (Wilcock & Iverson 2003: 4; Kneisel et al. 2007; Carrara & Pike 2008).

Geomorfologisessa tutkimuksessa ennustava malli voi antaa tietoa alueilta, joista ei ole saatavilla perinteistä aineistoa (Marmion et al. 2008: 2241). Alueellisen mallintamisen avulla voidaan muuttaa kentällä kerätty pistemäinen tieto alueellisesti kattavaksi. Suhteellisenkin epätarkkaa alueellista tietoa pystytään käyttämään arvioidessa laajojen alueiden geomorfisia prosesseja riittävän luotettavasti. GIS-menetelmien avulla voidaan helposti kerätä mahdollisia selittäviä ympäristömuuttujia (Luoto & Seppälä 2002: 26). Tärkeitä kehitysaskelia viimeisen 30 vuoden aikana ovat olleet kehitys regressioanalyysissä (muun muassa GLM ja GAM) (Guisan et al. 2002:

89). Uudet tilastolliset tekniikat yhdessä GIS-menetelmien kanssa ovat avanneet täysin uudet mahdollisuudet geomorfisten prosessien tutkimiseen (Walsh et al 1998: 201).

#### 4.2.2 Yleistetyt lineaariset mallit

Regressiomalli liittää vastemuuttujan yhteen tai useampaan selittävään muuttujaan. Klassinen lineaarinen regressio on teoreettisesti sopiva vain, kun vastemuuttuja (selitettävä muuttuja) on normaalisti jakautunut, aineiston varianssi on vakio (aineistossa ei ole trendirakennetta) sekä vasteen ja selittävän muuttujan välinen suhde on lineaarinen (Guisan et al. 2000: 161; Guisan et al. 2002: 92). Nämä oletukset harvoin pitävät paikkaansa geomorfologisten aineistojen yhteydessä (Hjort 2006). Lineaarinen regressiomalli soveltuu ainoastaan jatkuville muuttujille, jolloin kategorisia muuttujia esimerkiksi maaperää ei pystytä mallintamaan (Atkinson 1998: 1185).

Yleistetyt lineaariset mallit (GLM = Generalized Linear Models) ovat lineaaristen mallien matemaattisia jatkeita (McCullagh & Nelder 1989: 1). Ne perustuvat vastemuuttujan keskiarvon ja selittävien muuttujien lineaarisen kombinaation suhteeseen (Guisan et al. 2002: 90). Selittävien muuttujien oletetaan olevan lineaarisia parametreiltään, mutta vasteen jakauma sekä selittävien muuttujien välinen linkki saa olla melko yleinen (Hastie & Tibshirani 1990: 136). Vastemuuttujan todennäköisyysjakauman ei tarvitse olla normaali, vaan GLM pystyy käsittelemään esimerkiksi Poisson-, binomi- ja Gamma-jakautuneita aineistoja (Guisan et al. 2002: 157). GLM:n avulla mallinnetaan siis vasteen ja selittävien muuttujien välistä suhdetta huomattavasti joustavammin verrattuna tavalliseen lineaariseen regressiomalliin (Atkinson et al. 1998: 1185). Tärkeä huomio on kuitenkin, että myös GLM olettaa havaintojen olevan itsenäisiä (McCullagh & Nelder 1989: 21). Vasteen ei tarvitse olla lineaarisessa suhteessa ympäristömuuttujiin, vaan myös käyräviivaisuus on mahdollista (Luoto & Hjort 2005: 335). Myös kategoristen muuttujien hyödyntäminen on sopivaa GLM:n kanssa (Guisan et al. 2002).

GLM on muotoa (Guisan et al. 2002: 92-93).

$$LP = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad (4)$$

missä,

LP = lineaarinen ennustaja, joka liittyy vasteen odotusarvoon  $\mu$  linkkifunktion avulla.

$\alpha$  = vakiotermi

$\beta_k$  = regressiokerroin

$x_k$  = selittävä muuttuja

Linkkifunktio määritellään:

$$g(\mu) = LP \quad (5)$$

Lineaarinen ennustaja (LP) on yhden tai useamman selittävän muuttujan lineaarinen summa ja se liittää jokaisen havaitun arvon ennusteeseen. Linkkifunktio liittää vastemuuttujan arvot lineaariseen ennustajaan muuntamalla vasteen arvot malliin sopiviksi. Kanoniset linkkifunktiot ovat oletuksena kun jokin tietty virhejakauma oletus valitaan. Esimerkiksi mallinnettaessa Poisson-virheoletuksella käytetään *log*-linkkifunktiota. Tämä linkkifunktio muuntaa Poisson-jakautuneen aineiston logaritmi-muunnoksella ja pitää huolen, että ennustetut arvot säilyvät oikeissa raja-arvoissa (McGullagh & Nelder 1989: 31; Crawley 2007: 513–516).

GLM-malli koostuu siis kolmesta komponentista: 1) vastemuuttujasta  $y$ , 2) parametreista  $\alpha$ ,  $\beta$  ja selittävistä muuttujista  $x$  sekä 3) linkkifunktiosta (McGullagh & Nelder 1989: 27). Sen avulla voidaan mallintaa eri jakaumia omaavia muuttujia, mukaan lukien binaarimuuttujia (McGullagh 1989: 32; Collett 2003). GLM-mallit on todettu erittäin käyttökelpoisiksi periglasiaalisten prosessien alueellisessa mallintamisessa ja ne ovat hyvin suosittuja menetelmiä tämän päivän geomorfologisessa tutkimuksessa (Luoto & Seppälä 2002; Hjort 2006; Ridefelt 2010). Tavallisella lineaarisella regressiomallilla ei pystytä tutkimaan kaikkia maantieteellisiä systeemejä, sillä se perustuu ainoastaan jatkuviin muuttujiin. Näin ollen joitakin kategorisia muuttujia, kuten esimerkiksi alueen maaperää on mahdoton mallintaa tavallisella lineaarisella mallilla. GLM sallii ei-lineaarisuuden ja vaihtelevan varianssin aineistossa (heteroskedastisuus) (Luoto & Hjort 2004: 328).

#### 4.2.3 Yleistetyt additiiviset mallit

Aina GLM ei ole riittävän joustava arvioitaessa todellisia prosessi-ympäristö suhteita (Yee & Mitchell 1991: 588; Luoto & Hjort 2004: 337; Hjort & Luoto 2010). Yleistetyt additiiviset mallit (GAM = Generalized Additive Models) ovat yleistettyjen lineaaristen mallien semi-parametrisia jatkeita, jotka sallivat vasteen ja selittävien muuttujien välisen riippuvuuden mallintamisen ei-parametrisesti (Hastie & Tibshirani 1990). Tämä tarkoittaa sitä, että selittäville muuttujille ei määritetä kertoimia. Vasteen todennäköisyysjakauma tulee kuitenkin olla tiedossa ja täten GAM:n voidaankin sanoa olevan semi-parametrinen menetelmä. Kuten GLM, myös GAM hyödyntää linkkifunktiota saavuttaakseen yhteyden vastemuuttujan ja selittävän muuttujan välille (Guisan et al. 2002: 90–93). GAM:n rakenne voidaan määrittellä seuraavasti (Hastie & Tibshirani 1990; Wood & Augustin 2002: 157–158):

$$g(\mu) = \beta_0 + s_1(x_1) + s_2(x_2) + \dots + s_k(x_k) \quad (6)$$

missä,

$g(\mu)$  = linkkifunktio

$\beta_0$  = vakiotermi

$s_k$  = määrittelemätön tasoitusfunktio

$x_k$  = selittävä muuttuja

Rakenne on muuten sama kuin GLM-mallissa, mutta lineaarinen ennustaja on korvattu aineistosta arvioidulla tasoitusfunktiolla (Mc Cullagh & Nelder 1989: 465). GAM käyttää niin sanottua ”takaisin sovitus”-algoritmia, joka on iteratiivinen sovitusmenetelmä (Hastie & Tibshirani 1990: 90–91).

Ei-lineaariset ja tasoittavat regressiotekniikat, kuten GAM, antavat aineiston määrittää vasteiden muodot, eivätkä rajoita niitä mallin määäämiin parametriin muotoihin (Luoto & Hjort 2004: 337). Näin ollen GAM:n voidaankin sanoa olevan enemmän aineiston kuin mallin ohjaama menetelmä, eikä vasteen muodolle ole *a priori* olettamusta. Sen avulla aineiston ominaisuudet, kuten mahdollinen bimodaalisuus ja epäsymmetrisuus on helpompi havaita kuin GLM:lla (Yee & Mitchell 1991: 589). Tärkeä vaihe GAM-mallia sovitettaessa on valita sopiva tasoitusfunktion taso perustuen

vapausasteiden lukumäärään. Näin saadaan kuvattua aineiston vaihtelu oikein, mutta vältytään mallin ylisovittamiselta (Guisan et al. 2002: 93; Wood 2004: 674). GAM:n etu GLM:n nähden on se, että tasoitusfunktio ottaa huomioon aineiston muodon, eikä korkeamman asteen termejä tarvitse erikseen sisällyttää malliin (Yee & Mitchell 1991: 591). Sen heikkous on laskennallinen raskaus, joka saattaa olla ongelma erityisesti suurilla aineistoilla analysoitaessa (Leatwick 2006). Mallinnuksessa käytettävien selittävien muuttujien valintaan tulee kiinnittää erityistä huomiota. Muuttujia voidaan sovittaa malliin esimerkiksi tilastollisen merkitsevyyden perusteella, jolloin ainoastaan tietyn merkitsevyydystason alittavat muuttujat otetaan mukaan (Hjort 2006). Muita menetelmiä on esimerkiksi AIC (Akaike's Information Criterion), jossa alhaisimman AIC-arvon tuottama kombinaatio on paras malli (Akaike 1974). Myös automaattisia menetelmiä on mahdollista käyttää (Guisan et al. 2002: 94).

GAM on hyvin toimiva ja suosittu menetelmä periglasiiaalisten alueiden tutkimuksessa. Esimerkiksi Brenning et al. (2007) ja Brenning & Azócar (2010) ovat mallintaneet kivijäätiköiden toimintaa Pohjois- ja Etelä-Amerikassa. GAM soveltuvuutta geomorfologiseen tutkimukseen ovat selvittäneet esimerkiksi Luoto & Hjort (2005) sekä Hjort & Luoto (2010).

#### 4.2.4 Hierarkkinen ositus

Monimuuttujamallien kanssa on usein tilanne, että aina ei ole selvää mikä muuttuja selittää mallista eniten. Hierarkkinen ositus ottaa huomioon selittävien muuttujien välisen multikollineaarisuuden ja tuo esiin jokaisen selittävän muuttujan yhteisen- tai itsenäisen vaikutuksen (Chevan & Sutherland 1991: 92–94; MacNally 2002: 1398). Se on menetelmä, jossa kaikki mahdolliset mallit otetaan huomioon. Näin saadaan esille todennäköisimmät kausaalitekijät. Hierarkkinen ositus käyttää niin sanottua ”sovituksen hyvyttä” jokaiselle  $2^k$  ( $k$  selittävälle muuttujalle) mahdolliselle mallille. Varianssit ositetaan siten, että selittävän muuttujan kokonaisvaikutus voidaan arvioida ja tuloksena on jokaisen muuttujan itsenäinen vaikutus (Oliver et al. 2000: 23). On tärkeää huomata, että hierarkkisella osituksella ei ole mitään kykyä tehdä ennusteita (MacNally 2002: 1399).

Hierarkkista ositusta on käyttänyt geomorfologisessa ja ekologisessa tutkimuksessa esimerkiksi Heikkinen et al. (2005), Johnston et al. (2008), Hjort et al. (2007) sekä Hjort

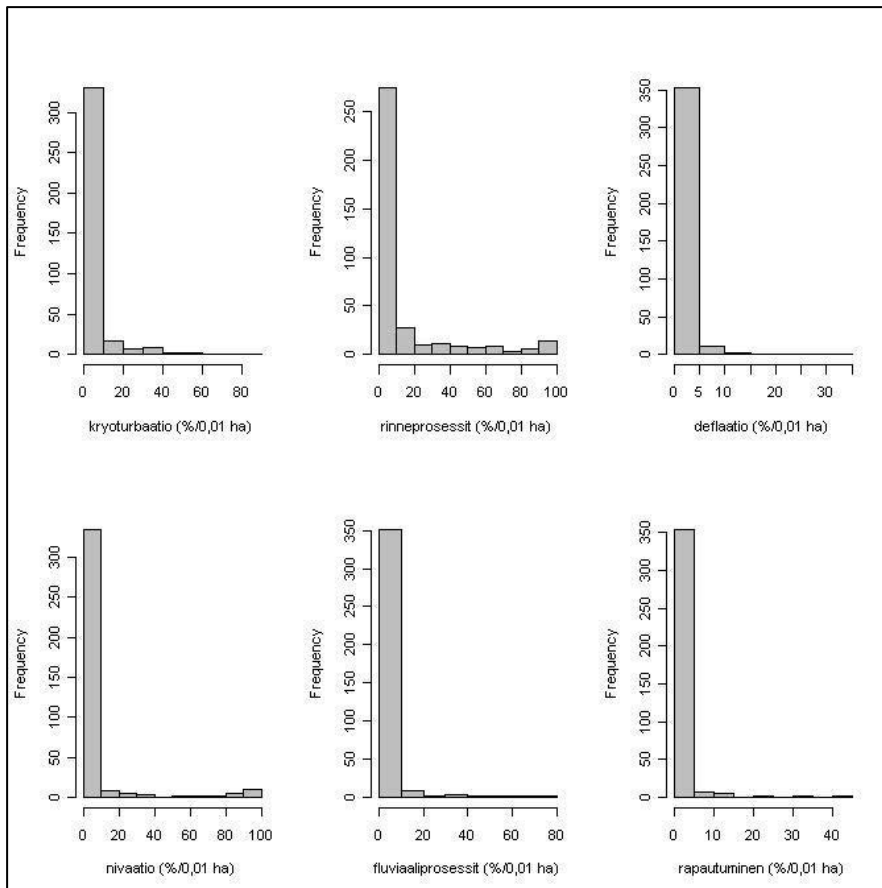


& Luoto (2009). Tässä tutkimuksessa hierarkkinen ositus on tehty R-ohjelmiston *hier.part* -paketilla (Walsh & MacNally 2003). Sovituksen hyvyttä mitattiin *log*-todennäköisyydellä (Heikkinen et al. 2005: 2206). Hierarkkisessa osituksessa käytettiin kaikkia samoja selittäviä muuttujia, mitä GLM-malleissakin. Koska muuttujien maksimimäärä osituksessa on 12, lisättiin analyysihin vielä NDVI, TWI sekä x- ja y-koordinaatti, jotta saataisiin tarkempaa tietoa ilmiöiden esiintymiseen vaikuttavista tekijöistä. Spatiaalisten muuttujien avulla voidaan arvioida mahdollisia maantieteellisiä trendejä (Hjort 2006: 48).

#### 4.2.5 Mallin kalibraatio ja evaluointi

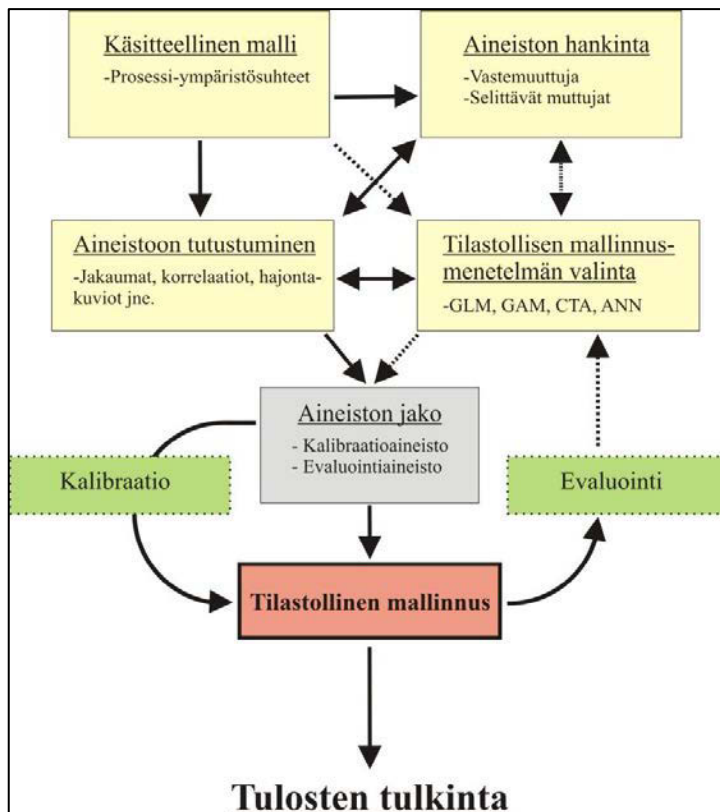
Mallia kalibroitaessa valitaan sopiva mallinnusmenetelmä, selittävät ympäristömuuttujat sekä rakennetaan tilastollinen malli (McGullagh & Nelder 1989: 21; Guisan & Zimmermann 2000: 166). GLM-mallit sovitettiin käyttämällä R tilasto-ohjelman *glm*-komentoa (liite 3). Koska vastemuuttujien arvot noudattavat Poisson-jakaumaa (family = Poisson) (kuva 28), kanoninen linkkifunktio on *log* (McGullagh & Nelder: 1989: 32; Crawley 2007: 514). Poisson-jakauma oletus sopii hyvin vasteille, jotka ovat positiivisia kokonaislukuja, lukumääriä ja eniten havaintoja on pienillä arvoilla (McGullagh & Nelder 1989: 194). Vasteen ja selittävien muuttujien välinen mahdollinen käyräviivainen suhde tutkittiin lisäämällä malliin jatkuvien muuttujien toisen ja kolmannen asteen termit (Austin 2002: 108; Luoto & Hjort 2004: 332). Parsimonian periaatteen mukaan mallin tulisi olla mahdollisimman yksinkertainen, eli se ei saa sisältää turhia parametrejä tai faktoritasoja (Crawley 2007: 326). Tilastollisen mallinnuksen vaiheet on esitetty kuvassa 29.

GLM-mallit sovitettiin käyttämällä termien askeltavaa poistoa, jolloin kalibraatio aloitetaan täydellä mallilla (kaikki selittävät muuttujat mukana) ja niitä poistetaan perustuen tilastolliseen merkitsevyyteen (*F*-testi) (Hjort 2006: 46). Tilastollisen merkitsevyyden raja-arvoksi valittiin  $p < 0,01$  (Fronzek et al. 2006: 5). Ensimmäiseksi poistetaan ei-merkitsevät toisen tai kolmannen asteen termit. Esimerkiksi jos lineaarinen termi ei ole merkitsevä, mutta toisen asteen on, tulee lineaarinen termi pitää mallissa mukana (Crawley 2007: 326). Valmiilla mallilla tehtiin ennuste spatiaaliselle mallinnusruudukolle, joka sisältää tiedot samoista selittävästä muuttujista kuin mallikin. Näin saatiin tutkittavan ilmiön alueellisesta esiintymisestä ennuste kartan muodossa.



Kuva 28. Histogrammit vastemuuttujien arvojen jakaumista.

GAM-mallit rakennettiin käyttämällä R tilasto-ohjelman *mgcv*-pakettia ja sen *gam*-komentoa (Wood 2004) (liite 3). Kaikki selittävät ympäristömuuttujat sovitettiin malliin sallimalla vapausasteiden vaihdella yhden ja neljän välillä ( $k=4$ ) (Araújo & Luoto 2007; Hjort & Luoto 2010: 5). Myös GAM-malleissa käytettiin Poisson-virheoletusta. Mallit sovitettiin käyttämällä termien askeltavaa poistoa perustuen pelkästään muuttujien tilastolliseen merkitsevyyteen ( $\chi^2$ -testi) (Luoto & Hjort 2005; Crawley 2007: 620; Hjort & Luoto 2010: 5). Tilastollisen merkitsevyyden raja-arvoksi valittiin  $p < 0,01$  (Fronzek et al. 2006: 5).



Kuva 29. Vuokaavio tilastollisen mallinnuksen vaiheista (Hjort & Marmion 2008: 342, tekijän muokkaama).

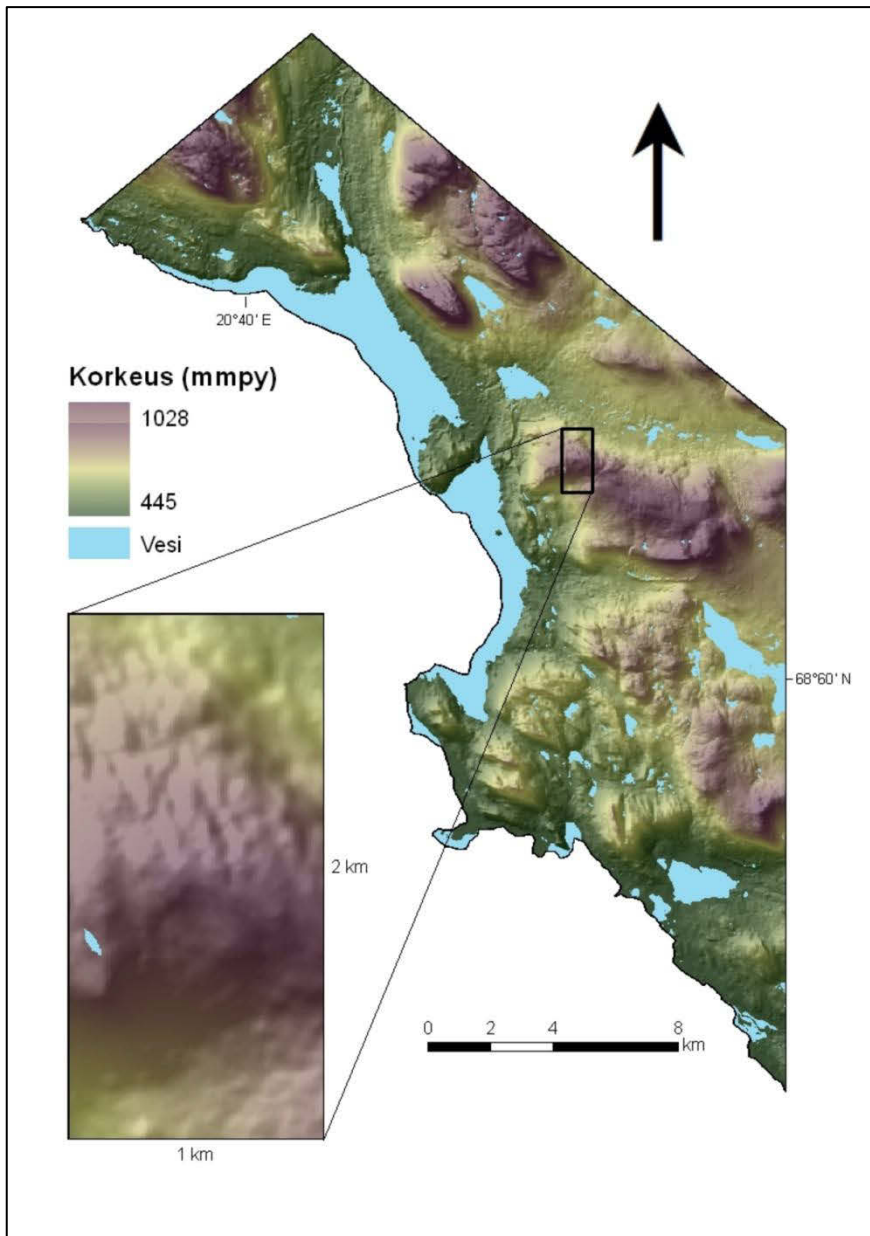
Luotujen mallien arviointi on hyvin tärkeä osa mallinnusprosessia (Pearce & Ferrier 2000: 226). Mallien selityskykyä voidaan arvioida laskemalla selitetyn hajonnan osuus (Hjort 2006: 46):

$$D^2 = (\text{kokonaishajonta} - \text{residuaalien hajonta}) / \text{kokonaishajonta} \quad (7)$$

Tutkimuksessa käytettiin erillistä evaluointiaineistoa, jotta mallien ennusteiden onnistumista voisi arvioida kvantitatiivisesti (Hjort 2006; Marmion et al. 2008). Malli ennustettiin kalibraatio- ja evaluointiaineistoon, jonka jälkeen Spearmanin korrelaatiokertoimet laskettiin havaittujen ja ennustettujen arvojen välille (Guisan & Zimmermann 2000: 173). Myös mallin jäännösvirheiden eli residuaalien tarkastelu on tärkeä osa mallinnusta (Zhang et al. 2005). Niiden avulla voidaan tutkia esimerkiksi mallin sovituksen onnistumista sekä linkkifunktion valintaa. Onnistuneen mallin jäännösvirheet ovat täysin satunnaisia eikä niissä ole huomattavissa mitään systemaattista. Residuaalit voivat myös paljastaa anomalioita aineistosta, jotka saattavat

vaatia lisätutkimuksia (McGullagh & Nelder 1989: 37). Tämän lisäksi malleja arvioitiin visuaalisesti ennusteiden muodossa sekä hierarkkisen osituksen tulosten perusteella. Mahdollinen trendirakenne otettiin mallinnuksessa huomioon siten, että ensiksi sovitettiin malli ilman spatiaalisia muuttujia (x ja y koordinaatti) (Legendre & Fortin 1989). Näitä malleja käytettiin myös ennusteiden tekemiseen. Valmiisiin malleihin lisättiin spatiaaliset muuttujat sekä niiden toisen ja kolmannen asteen termit. Tämän jälkeen uudesta mallista laskettiin selitetyn hajonnan osuus ja tarkasteltiin mahdollisen selityksasteen muutosta. Jos selityksaste kohooa spatiaalisten muuttujien lisäyksen jälkeen, on ilmiön esiintymisessä maantieteellinen trendi (Legendre 1993: 1671). GLM- ja GAM-mallien keskinäinen kvantitatiivinen vertailu suoritettiin laskemalla Spearmanin korrelaatio mallien antamien ennusteiden välille, sekä vertailemalla selitetyn hajonnan osuutta.

Mallinnusresoluution vaikutusta syntyneeseen ennusteeseen tutkittiin omalla pienellä 2 x 1 km koealalla Ailakkavaaralla (kuva 30), jonka spatiaalinen resoluutio on 10 x 10 metriä. Alueen koilliskulman koordinaatit ovat noin 69°00'53''N, 20°58'21''E sekä lounaiskulman koordinaatit 68°59'45''N, 20°57'11''E. Alue valittiin siten, että topografia olisi mahdollisimman vaihtelevaa ja eksposition vaikutus tulisi esille.



Kuva 30. Ailakkavaaran tutkimusalueen sijainti.

Ailakkavaaran tutkimusaluetta varten kalibroidiin kaksi GAM-mallia: krypturbaatio- ja rinneprosessimallit samoilla menetelmillä kuin sivulla 45 on esitetty. Selittävinä muuttujina käytettiin kaikkia 10 x 10 m spatiaalisen resoluution omaavia muuttujia eli keskikorkeus, rinteenkalltevuus, säteily ja kaarevuus. Valmis GAM-malli ennustettiin Ailakkavaara-aineistoon (19 998 mallinnusruutua), joka sisälsi alueellisen tiedon kaikista selittävästä muuttujista. Aineistosta ei poistettu vettä sisältäviä ruutuja tutkimuksen kokeellisen luonteen johdosta, sekä siitä syystä, että pienet lammet saattavat olla temporaaliselta esiintymiseltään melko vaihtelevia. Malleja evaluoitiin selitetyn hajonnan perusteella, sekä tutkimalla ennusteita visuaalisesti.

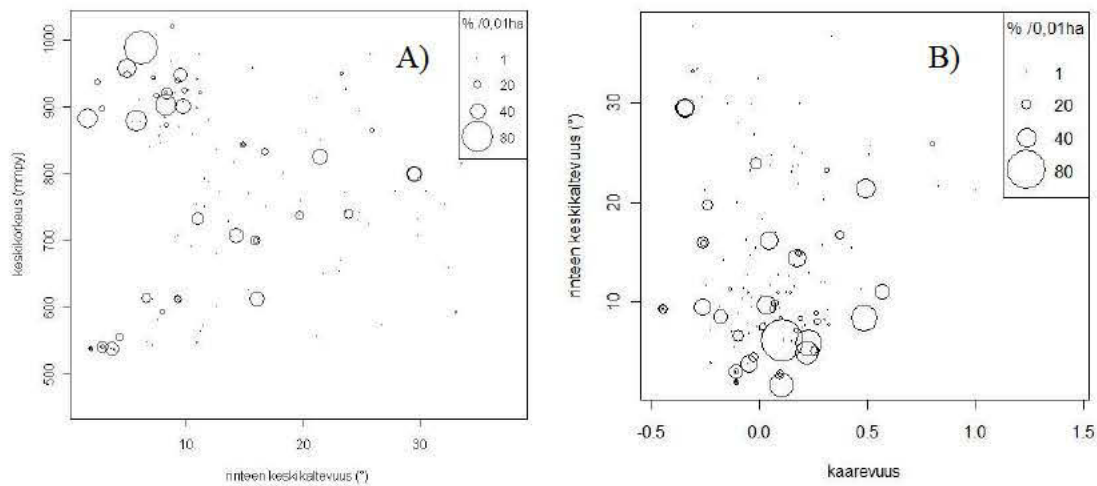
## 5. Tulokset

### 5.1 Kryoturbaatio

Taulukossa 4 on esitetty kaikkien tutkittavien ilmiöiden esiintymisen runsaus suhteessa kahteen topografiseen muuttujaan, keskikorkeuteen ja rinteiden keskikaltevuuteen. Taulukosta 4 ja kuvasta 31 voidaan nähdä, että kryoturbaatiota esiintyy eniten korkealla rinteiden kaltevuuden ollessa suhteellisen pientä. Keskihajonta on kuitenkin korkeuden ja rinteiden kaltevuuden suhteen huomattavan suurta. Kryoturbaatiota esiintyessä runsaasti on kaarevuus lähellä nollaa viitaten tasaiseen maastoon (kuva 31b).

Taulukko 4. Tutkittavien ilmiöiden esiintymisen määrä suhteessa topografisiin muuttujiin (keskikorkeus ja rinteiden keskikaltevuus). Analyysissä on käytetty koko havaintoaineistoa (n=369). Tilastollinen merkitsevyys havaintoarvojen ja ei esiinny -havaintojen välillä on laskettu Mann-Whitneyn U-testillä (\*\*\*) =  $p < 0,001$ ; \*\* =  $p < 0,01$ ; \* =  $p < 0,05$ ; n.s. = ei merkitsevä, (ka=keskiarvo, std=keskihajonta).

	Kryoturbaatio ka ± std	Rinneprosessit ka ± std	Rapautuminen ka ± std	Deflaatio ka ± std	Nivaatio ka ± std	Fluviaaliprosessit ka ± std
<b>1 - 10 % / 0,01 ha</b>						
korkeus (mmpy)	720,3 ± 145,6**	769,5 ± 123,7***	799,4 ± 124,9***	810 ± 123,6***	763,3 ± 127,2 n.s.	652,0 ± 105,0 n.s.
rinteen kaltevuus°	13,7 ± 9,7 n.s.	15,9 ± 7,9*	20,3 ± 9,6***	15,0 ± 9,1 n.s.	20,4 ± 5,3*	15,4 ± 8,3 n.s.
<b>10 - 50 % / 0,01 ha</b>						
korkeus (mmpy)	775,0 ± 155,6***	747,4 ± 108,2***	765,4 ± 115,7*	883,4 ± 87,5***	826,1 ± 73,8***	605,0 ± 64,9 n.s.
rinteen kaltevuus°	11,4 ± 7,9*	21,5 ± 8,2***	16,7 ± 8,0 n.s.	8,6 ± 4,6*	14,5 ± 7,1 n.s.	10,1 ± 7,1*
<b>yli 50 % / 0,01 ha</b>						
korkeus (mmpy)	913,0 ± 51,7**	814,9 ± 79,8***	ei havaittu	ei havaittu	795,8 ± 77,6***	613,0 ± 0 n.s.
rinteen kaltevuus°	5,5 ± 2,8*	21,7 ± 8,8***	ei havaittu	ei havaittu	18,1 ± 6,1***	9,3 ± 0 n.s.
<b>Ei esiinny</b>						
korkeus (mmpy)	626,5 ± 105,7	584,2 ± 91,4	644,0 ± 124,6	637,8 ± 116,4	657,5 ± 135,1	682,9 ± 144,1
rinteen kaltevuus°	15,1 ± 7,9	9,4 ± 5,2	12,6 ± 7,7	14,1 ± 8,5	13,7 ± 8,8	14,3 ± 8,7



Kuva 31. Kryoturbaation havaittu esiintyminen suhteessa A) keskikorkeuteen ja rinteen kaltevuuteen sekä B) rinteen kaltevuuteen ja kaarevuuteen.

GLM-malli perustuen Poisson-virhejakaumaan selitti 46,2 % kryoturbaation alueellisesta vaihtelusta. Spatiaalisten muuttujien lisäämisen jälkeen selitysaste oli 53,1 % eli mallin selitysaste parani 13 %. Valmiin GLM-mallin tulokset on esitetty taulukoissa 5 ja 6. Kryoturbaatiomalliin tuli mukaan kaikki muut muuttujat, paitsi maaperä, säteily<sup>3</sup> ja rinteen kaltevuus alle 2<sup>o</sup>.

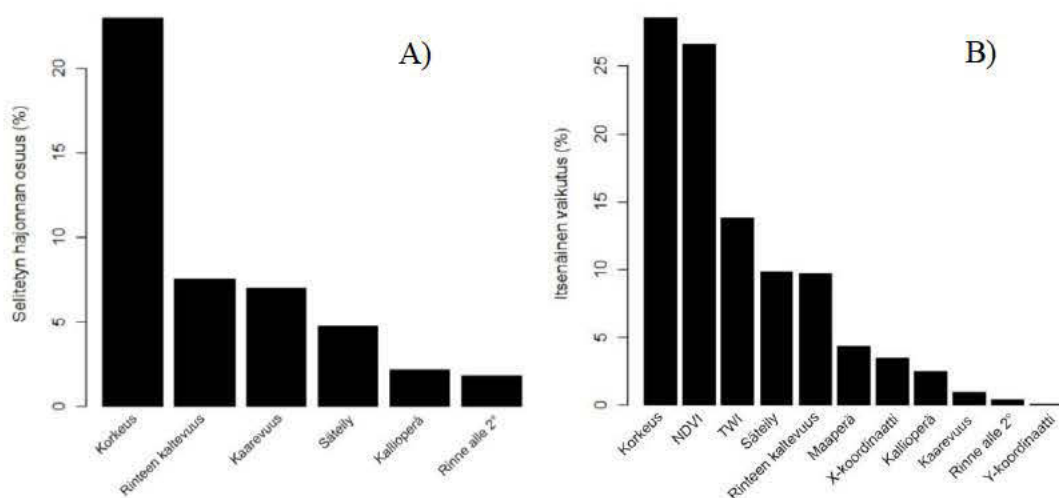
Taulukko 5. Valmiin kryoturbaatiomallin (Poisson-GLM) selittävät muuttujat, niiden kertoimet sekä keskivirheet.

Muuttuja	Kertoimet	SE
Vakiotermi	-23,280	6,728
Keskikorkeus	0,075	0,028
Keskikorkeus <sup>2</sup>	-8,78E-05	0,000
Keskikorkeus <sup>3</sup>	3,56E-08	0,000
Kaarevuus	0,615	0,208
Kaarevuus <sup>2</sup>	8,191	0,490
Kaarevuus <sup>3</sup>	-9,72	0,802
Rinteen keskijyrkkyys	-0,336	0,040
Rinteen keskijyrkkyys <sup>2</sup>	0,013	0,003
Rinteen keskijyrkkyys <sup>3</sup>	-1,08E-04	0,000
Säteily	26,770	3,926
Säteily <sup>2</sup>	-36,21	4,733
Rinteen kaltevuus < 2 <sup>o</sup>	0,045	0,008
Rinteen kaltevuus < 2 <sup>o2</sup>	-0,001	0,000
Kallioperä	-0,665	0,079

Taulukko 6. Tietoa kryoturbaatiomallin (Poisson-GLM) hajonnasta sekä tilastollisista merkitsevyyksistä. Tilastolliset merkitsevyydet perustuvat  $F$ -testiin (\*\* $= p < 0,001$ , \*\* $= p < 0,01$ , \* $= p < 0,05$ ).

Muuttuja	Hajonta	Residuaalien hajonta	<i>d.f.</i>	<i>F</i>	<i>Pr(&gt;F)</i>
Vakiotermi		3333,3	258		
Keskikorkeus	714,3	2619,0	257	714,25	< 2,2E-16 ***
Keskikorkeus <sup>2</sup>	41,1	2577,9	256	41,12	1,432E-10 ***
Keskikorkeus <sup>3</sup>	10,7	2567,2	255	10,69	0,001079 **
Kaarevuus	18,3	2549,0	254	18,27	1,916E-05 ***
Kaarevuus <sup>2</sup>	48,7	2500,3	253	48,66	3,040E-12 ***
Kaarevuus <sup>3</sup>	165,8	2334,6	252	165,75	< 2,2E-16 ***
Rinteen keskijyrkkyys	129,9	2204,6	251	129,91	< 2,2E-16 ***
Rinteen keskijyrkkyys <sup>2</sup>	47,3	2157,4	250	47,25	6,259E-12 ***
Rinteen keskijyrkkyys <sup>3</sup>	74,8	2082,6	249	74,83	< 2,2E-16 ***
Säteily	87,7	1994,9	248	87,67	< 2,2E-16 ***
Säteily <sup>2</sup>	71,0	1923,9	247	71,02	< 2,2E-16 ***
Rinteen kaltevuus < 2°	3,9	1920,0	246	3,89	0,048719 *
Rinteen kaltevuus < 2° <sup>2</sup>	55,8	1864,2	245	55,81	7,974E-14 ***
Kallioperä	72,2	1792,0	244	72,21	< 2,2E-16 ***

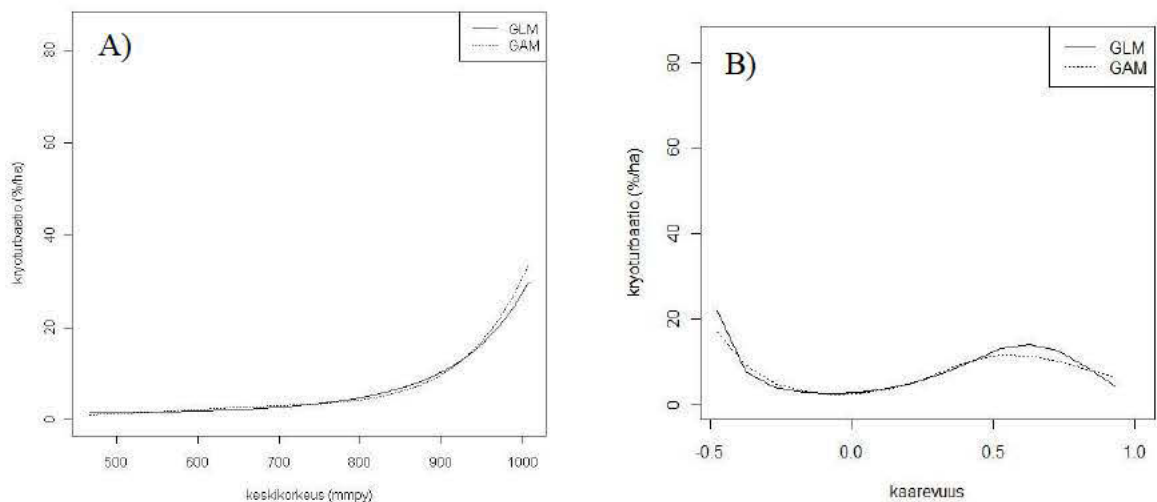
Taulukosta 6 nähdään, että korkeuden lineaarinen termi oli suurin yksittäinen selittäjä mallissa selittäen noin 21 % koko vaihtelusta. Seuraavaksi eniten selittivät kaarevuus<sup>3</sup> ja rinteen keskijyrkkyys. Kuvassa 32a on esitetty selitetyn hajonnan osuus muuttujittain sisältäen kaikki eriaisteiset termit. Hierarkkisen osituksen tulokset kryoturbaatiomallin pohjalta nähdään kuvassa 32b. Sen mukaan suurin itsenäinen vaikutus on korkeudella (28,6 %). Seuraavaksi tärkeimmät muuttujat ovat NDVI (26,7 %) ja topografinen kosteusindeksi (13,8 %). Säteilyn ja rinteen kaltevuuden vaikutus on hieman alle 10 % molemmilla.



Kuva 32. A) Selitetyn hajonnan osuus sekä B) Hierarkkisen osituksen tulokset.

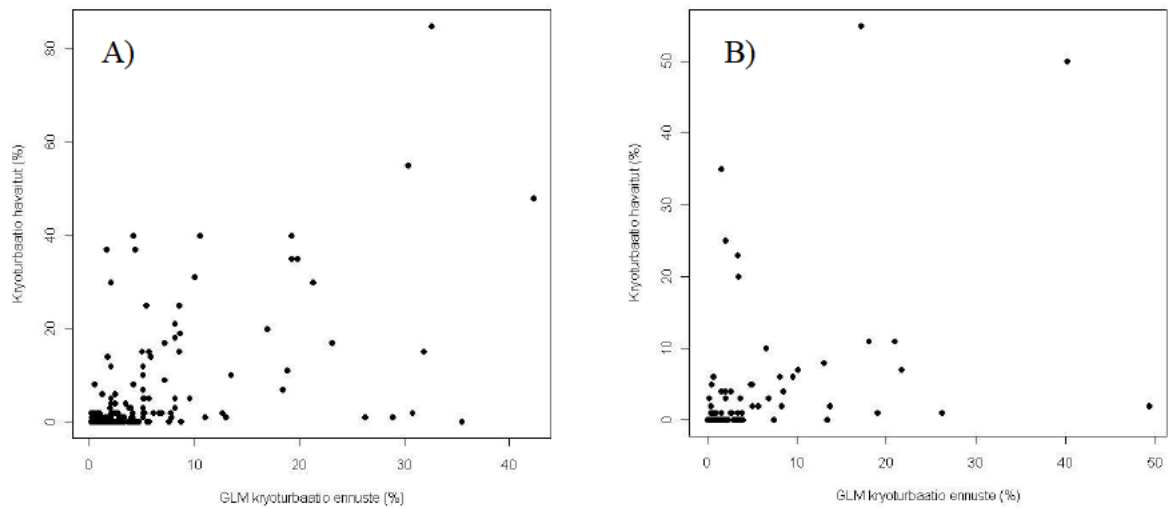


Kuvassa 33 on kryoturbaation ennustetut vasteet keskikorkeuden ja kaarevuuden suhteen. Kryoturbaation määrä kasvaa voimakkaasti noin korkeuden 850 m mpy jälkeen. Kuvasta 33b nähdään, että kryoturbaation määrä on pienin maaston ollessa tasaisin (kaarevuus arvo lähellä nollaa). Molemmat mallit tuottivat hyvin samanlaisia ennusteita. Mallinnusruutujen (1 ha) määrä tutkimusalueella on 26 040. GLM-malli ennusti yli 1 % kryoturbaatioarvoja vain 45 ruutuun (0,16 %). Alueellinen ennuste kryoturbaation esiintymisestä perustuen GLM-malliin on esitetty liitteessä 4.




Kuva 33. Kryoturbaation ennustetut vasteet suhteessa A) keskikorkeuteen ja B) kaarevuuteen.

Spearmanin korrelaatiokerroin kalibraatioaineistolle oli 0,530, joka oli hieman enemmän kuin evaluointiaineistolle 0,516. Kuvasta 34 nähdään havaittujen kryoturbaatio arvojen suhde ennusteisiin. Molemmista diagrammeista voi todeta mallin antavan samankaltaisia tuloksia pienillä arvoilla, mutta ennustearvojen suurentuessa erot alkavat kasvaa.



Kuva 34. Kryoturbaation havaitut arvot GLM ennustetta vastaan. A) Ennuste on sovitettu kalibraatioaineistoon ja B) evaluointiaineistoon.

GLM-mallin jäännösvaihtelu on esitetty kuvassa 35. Residuaaleissa ei tulisi näkyä mitään selvää kuviota, vaan pisteet tulisi olla tasaisesti jakautuneet (Collett 2003: 137). Siitä voidaan havaita kuitenkin merkkejä heteroskedastisuudesta, eli varianssin kasvusta keskiarvon funktiona.



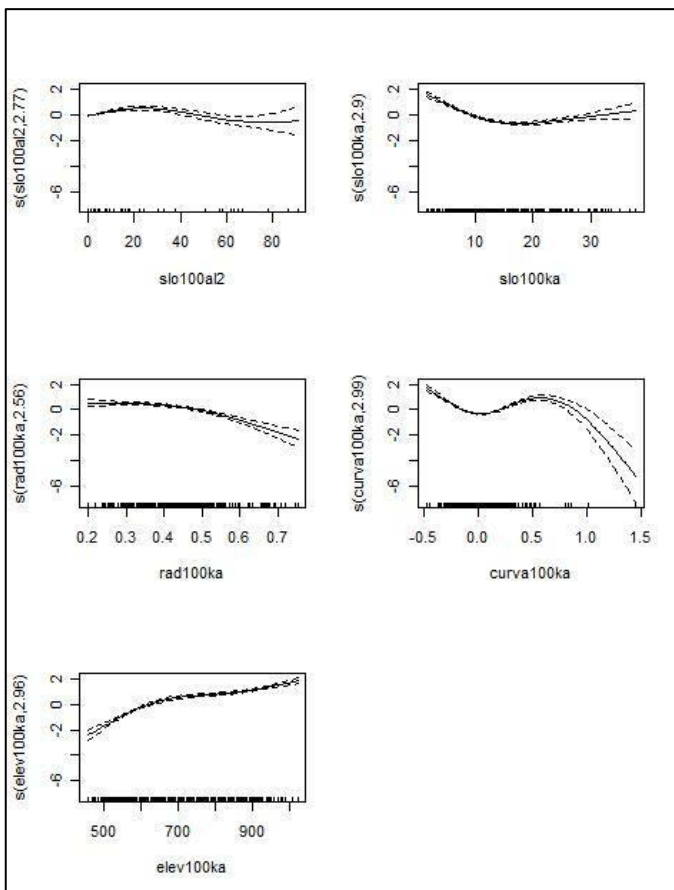
Kuva 35. Kryoturbaatiomallin residuaalit kuvattuna sovitettuja arvoja vastaan.

Valmiiseen GAM-malliin tulivat mukaan kaikki jatkuvat selittävät muuttujat ja tulokset ovat esitetty taulukossa 7 ja kuvassa 36. Malli selitti 44,8 % kryoturbaation vaihtelusta. Spatiaalisten muuttujien lisäämisen jälkeen selitysaste oli 50,9 % eli se parani 12 %.

GAM-malli ennusti yli 1 % krypturbaatioarvoja 2 869 ruutuun eli noin 11 % mallinnusruuduista. Liitteessä 5 on esitetty krypturbaation alueellinen esiintyminen GAM malliin perustuen.

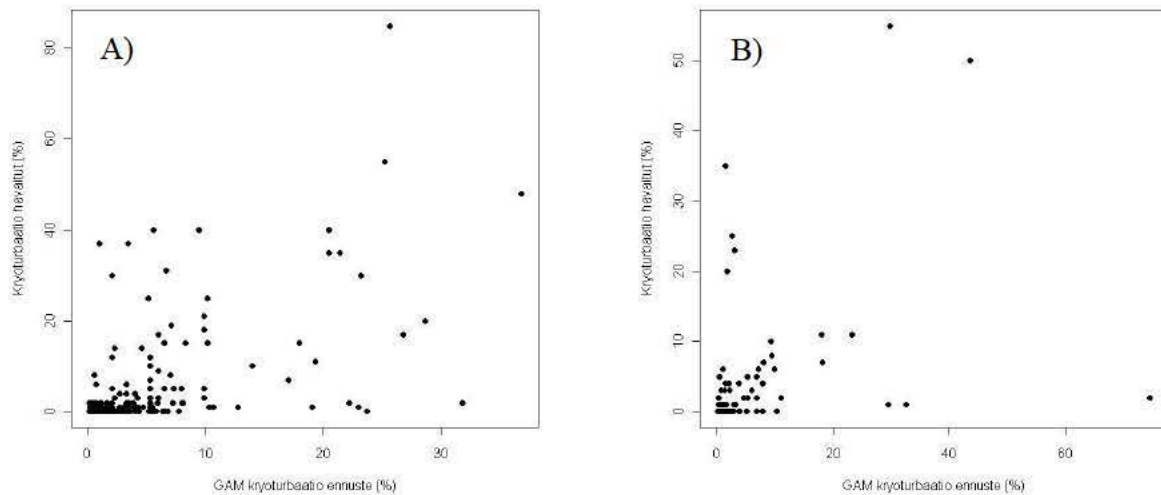
Taulukko 7. Valmiin krypturbaatiomallin (Poisson-GAM) tulokset. *edf* kertoo tasoituksessa käytettyjen vapausasteiden arvioidun määrän. *ref.df* on residuaalien vapausasteiden arvioitu määrä.

<b>Muuttuja</b>	<i>edf</i>	<i>ref.df</i>	<i>Chi.sq</i>	<i>P</i>
Keskikorkeus	2,827	2,975	523,730	< 2E-16 ***
Rinteen keskijyrkkyys	2,902	2,992	157,810	< 2E-16 ***
Rinteen kaltevuus < 2°	2,334	2,648	36,480	3,49E-08 ***
Kaarevuus	2,998	3,000	303,520	< 2E-16 ***
Säteily	2,873	2,989	141,93	< 2E-16 ***




Kuva 36. GAM-mallin tulokset. Tasoitusfunktion arvo näkyy y-akselilla muuttujan nimen yhteydessä. Vastekäyrien ympärillä nähdään 95 % luottamusväli. Slo100al2=rinteen kaltevuus alle 2°, slo100ka=rinteen keskikaltevuus, rad100ka=säteily, curva100ka=kaarevuus, elev100ka=keskikorkeus.

Spearmanin korrelaatiokerroin kalibraatioaineistolle 0,550 ja evaluointiaineistolle 0,519. Kuvasta 37 nähdään havaittujen arvojen suhde GAM-ennusteen arvoihin. Siitä nähdään krypturbaation esiintyminen pääasiassa korkeilla ja suhteellisen tasaisilla alueilla



Kuva 37. Krypturbaation havaitut arvot GAM-ennustetta vastaan. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.

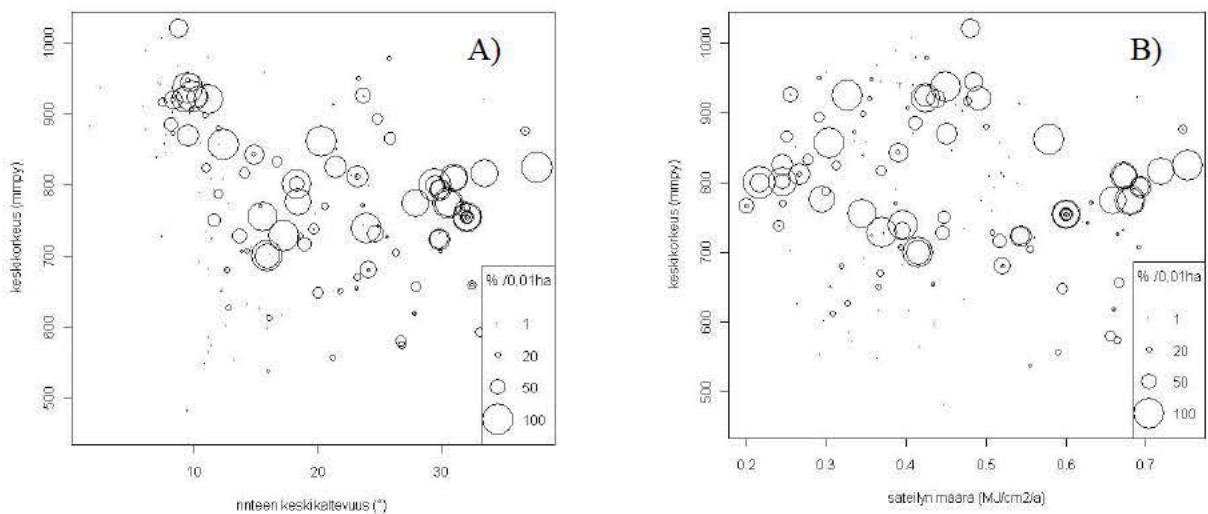
Kuvassa 38 on vertailtu GLM- ja GAM-ennusteita keskenään. Kuvasta nähdään, miten GLM-malli ennustaa huomattavasti pienempiä arvoja kuin GAM. Tästä syystä GLM-ennusteessa (liite 4) näkyy krypturbaatiota vain muutamassa mallinnusruudussa. Kumpikin malli ennustaa pääosin hyvin pieniä määriä krypturbaatiota. Ennusteiden välinen Spearmanin korrelaatio on 0,951.



Kuva 38. GLM- ja GAM-ennusteet kuvattuna vastakkain.

## 5.2 Rinneprosessit

Rinneprosesseja esiintyy keskimäärin noin 770 m mpy ja melko jyrkillä, noin 20° rinteillä. Kuvasta 39 nähdään, että eniten rinneprosesseja on juuri korkeilla alueilla, mutta rinteiden kaltevuus vaihtelee suuresti. Rinneprosesseja esiintyy säteilyn arvojen vaihdellen laidasta laitaan ( $k_a=0,47\text{MJ}/\text{cm}^2/\text{a}$ ), joten säteily ei näytä olevan rinneprosessien esiintymisessä tärkein rajaava tekijä.



Kuva 39. Rinneprosessien havaittu esiintyminen suhteessa A) keskipöytäkorkeuteen ja rinteiden kaltevuuteen sekä B) keskipöytäkorkeuteen ja säteilyn määrään.

GLM-malli selitti 62,2 % rinneprosessien vaihtelusta. Spatiaalisten muuttujien lisääminen malliin nosti selitysasetta 6,9 prosentista 66,8 prosenttiin. Valmiin rinneprosessimallin tulokset on esitetty taulukoissa 8 ja 9. Lopulliseen GLM-malliin tulivat mukaan kaikki muut selittävät muuttujat lukuun ottamatta maaperää.

Taulukko 8. Valmiin rinneprosessimallin (Poisson-GLM) selittävät muuttujat, niiden kertoimet sekä keskivirheet.


<b>Muuttuja</b>	<b>Kertoimet</b>	<b>SE</b>
Vakiotermi	0,900	5,113
Keskikorkeus	-0,077	0,021
Keskikorkeus <sup>2</sup>	1,34E-04	2,73E-05
Keskikorkeus <sup>3</sup>	-6,71E-08	1,19E-08
Kaarevuus	-2,101	0,115
Kaarevuus <sup>2</sup>	-2,368	0,376
Kaarevuus <sup>3</sup>	2,28	0,495
Rinteen keskijyrkkyys	0,530	0,040
Rinteen keskijyrkkyys <sup>2</sup>	-0,016	0,002
Rinteen keskijyrkkyys <sup>3</sup>	1,60E-04	3,29E-05
Säteily	53,920	4,871
Säteily <sup>2</sup>	-113,9	10,550
Säteily <sup>3</sup>	73,300	7,231
Rinteen kaltevuus < 2°	0,099	0,010
Rinteen kaltevuus < 2° <sup>2</sup>	-0,003	5,02E-04
Rinteen kaltevuus < 2° <sup>3</sup>	2,29E-05	5,52E-06
Kallioperä	-0,2243	0,048

Taulukko 9. Tietoa rinneprosessimallin (Poisson-GLM) hajonnasta sekä tilastollisista merkitsevyyksistä.

<b>Muuttuja</b>	<b>Hajonta</b>	<b>Residuaalien hajonta</b>	<b>d.f.</b>	<b>F</b>	<b>Pr(&gt;F)</b>
Vakiotermi		9527,0	258		
Keskikorkeus	2390,2	7136,8	257	2390,233	< 2,2E-16 ***
Keskikorkeus <sup>2</sup>	1481,8	5655,0	256	1481,764	< 2,2E-16 ***
Keskikorkeus <sup>3</sup>	18,6	5636,4	255	18,569	1,638E-05 ***
Kaarevuus	547,1	5089,4	254	547,046	< 2,2E-16 ***
Kaarevuus <sup>2</sup>	16,4	5073,0	253	16,410	5,103E-05 ***
Kaarevuus <sup>3</sup>	16,3	5056,7	252	16,278	5,470E-05 ***
Rinteen keskijyrkkyys	501,4	4555,3	251	501,441	< 2,2E-16 ***
Rinteen keskijyrkkyys <sup>2</sup>	430,0	4125,3	250	429,986	< 2,2E-16 ***
Rinteen keskijyrkkyys <sup>3</sup>	106,7	4018,6	249	106,733	< 2,2E-16 ***
Säteily	10,2	4008,3	248	10,232	0,001380 **
Säteily <sup>2</sup>	50,4	3958,0	247	50,349	1,287E-12 ***
Säteily <sup>3</sup>	183,9	3774,1	246	183,897	< 2,2E-16 ***
Rinteen kaltevuus < 2°	39,4	3734,7	245	39,384	3,481E-10 ***
Rinteen kaltevuus < 2° <sup>2</sup>	99,1	3635,6	244	99,122	< 2,2E-16 ***
Rinteen kaltevuus < 2° <sup>3</sup>	10,3	3625,3	243	10,254	0,001364 **
Kallioperä	21,89	3603,4	242	21,887	2,892E-06 ***

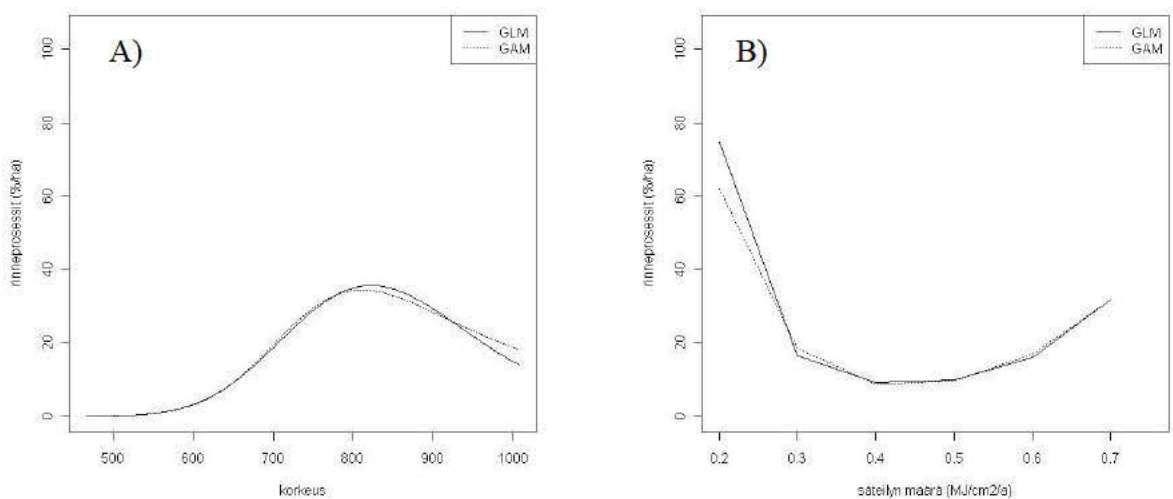
Taulukon 9 mukaan keskikorkeuden lineaarinen ja toisen asteen termi selittävät eniten vaihtelusta, yhteensä noin 41 %. Myös kaarevuus ja rinteen keskijyrkkyys selittävät melko paljon kokonaishajonnasta (kuva 40a). Hierarkkisen osituksen tulosten perusteella NDVI:llä on suurin vaikutus (19,4 %) rinneprosessien esiintymiseen (kuva 40b). Toiseksi eniten (18,7 %) vaikutti TWI. Säteilyllä oli heikko vaikutus, selittäen 2,7

% vaihtelusta. Myös keskikorkeus (16,9 %), rinteiden keskikaltevuus (15,4 %) ja maaperä (11,9 %) ovat tärkeitä selittäviä muuttujia.




Kuva 40. A) Selitetyn hajonnan osuus sekä B) hierarkkisen osituksen tulokset rinneprosessimallin perusteella.

Kuvassa 41 on esitetty rinneprosessien ennustetut vastekäyrät keskikorkeuden ja säteilyn suhteen. Kuvassa 42 on esitetty vielä rinneprosessien ennustettu vaste rinteiden keskikaltevuuteen. Alueellinen ennuste rinneprosessien esiintymisestä on esitetty liitteessä 6. GLM-malli ennusti yli 1 % rinneprosessiarvoja 7 861 ruudulle (30,2 %)

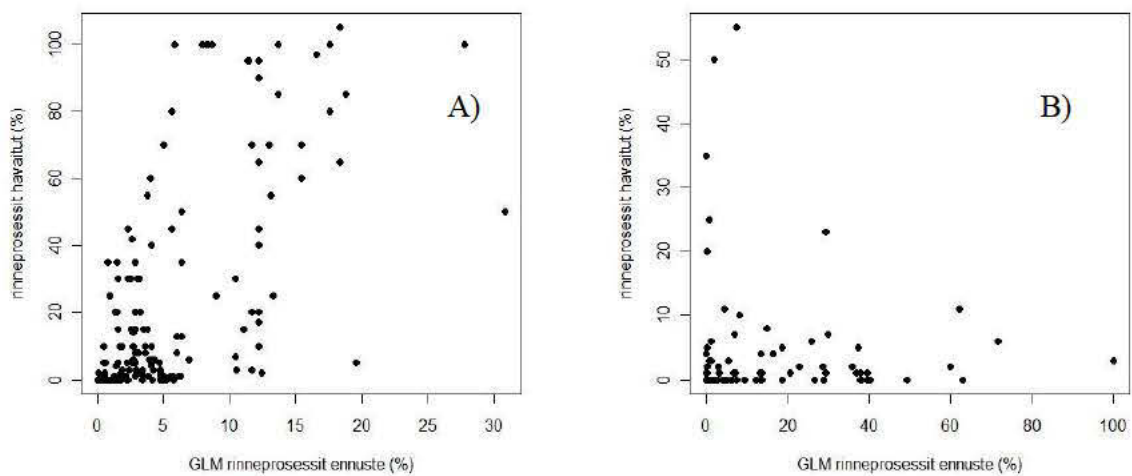


Kuva 41. Rinneprosessien ennustettu vaste A) keskikorkeuteen ja B) säteilyn määrään.



Kuva 42. Rinneprosessien ennustettu vaste rinteen keskikaltevuuteen.


Kuvasta 41a nähdään, että rinneprosessien määrä kasvaa noin korkeuteen 800 m mpy asti, jonka jälkeen molemmat menetelmät ennustivat sen määrän pienenevän todennäköisesti maaston tasaisuuden lisääntymisen johdosta. Rinneprosessien määrä on suurimmillaan säteilyn ollessa pientä ja laskee nopeasti säteilymäärän kasvaessa. Aktiivisuus lisääntyy kuitenkin uudestaan suuremmilla säteilyarvoilla. Kuvassa 42 rinneprosessien määrä kasvaa lähes lineaarisesti rinteen keskikaltevuuden suurentuessa. Spearmanin korrelaatiokerroin kalibraatioaineistolle oli 0,790 ja evaluointiaineistolle 0,754. Kuvassa 43 on esitetty havaittujen ja ennustettujen arvojen suhde.



Kuva 43. Rinneprosessien havaitut arvot GLM-ennustetta vastaan. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.



Ennustettaessa mallilla kalibraatioaineistoon arvot ovat havaittuja pienempiä. Evaluointiaineistoon sovitettaessa tilanne näyttäisi olevan päinvastoin. Mallin residuaaleissa on jälleen nähtävissä todisteita heteroskedastisuudesta (kuva 44).

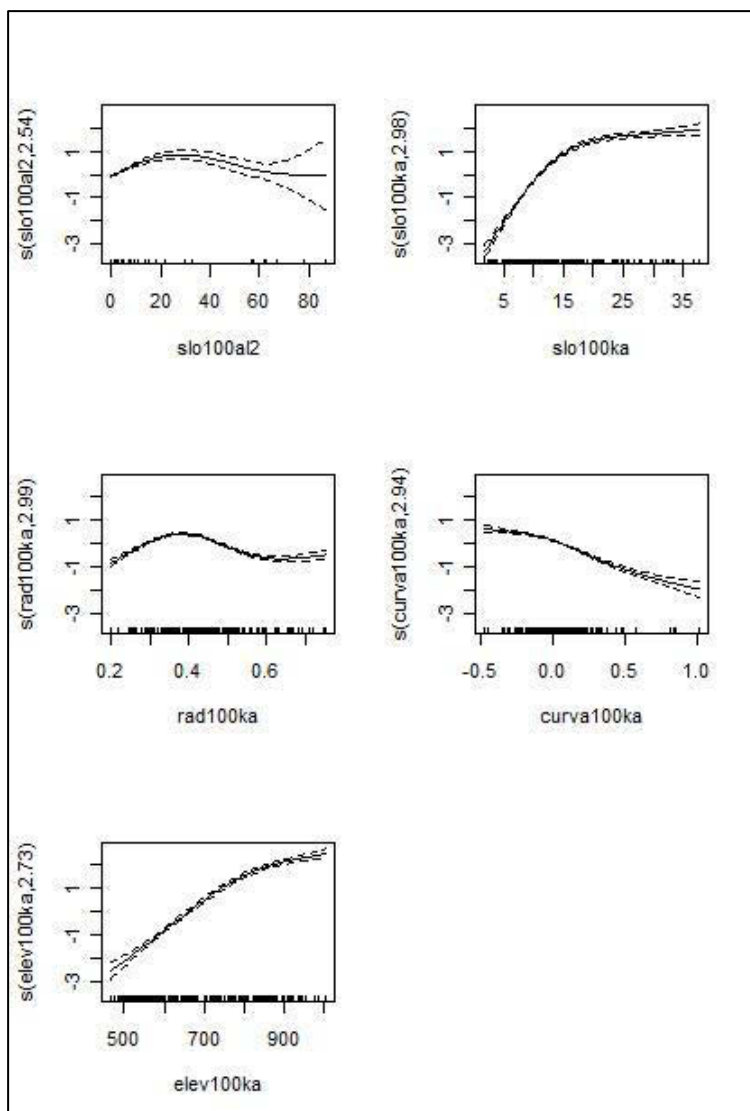


Kuva 44. Rinneprosessimallin standardoidut residuaalit kuvattuna sovitettuja arvoja vastaan.

GAM-malli ennusti yli 1 % /ha rinneprosessiarvoja 7 101 ruutuun eli 27,3 % tutkimusalueesta. Malliin tuli mukaan kaikki selittävät muuttujat. Valmis malli selitti 61,9 % rinneprosessien vaihtelusta. Spatiaalisten muuttujien lisäyksen jälkeen selitysaste oli 66,9 %, joten se parani 7,5 %. GAM mallin tulokset on esitetty taulukossa 10 ja kuvassa 45.

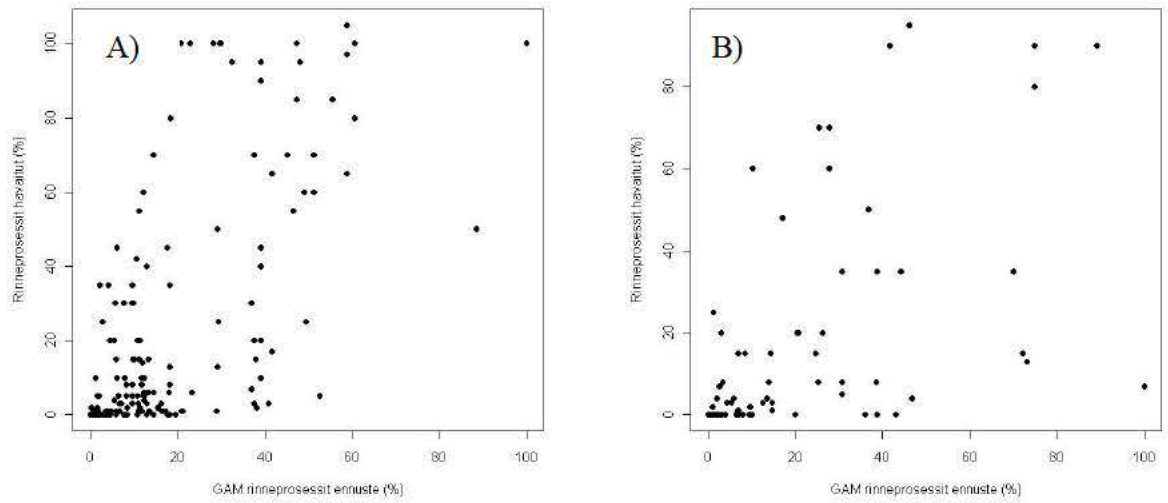
Taulukko 10. Valmiin rinneprosessimallin (GAM) tulokset.

<b>Muuttuja</b>	<i>edf</i>	<i>ref.df</i>	<i>Chi.sq</i>	<i>P</i>
Keskikorkeus	2,729	2,943	1762,500	<2E-16 ***
Rinteen keskijyrkkyys	2,976	2,999	997,900	<2E-16 ***
Rinteen kaltevuus < 2°	2,539	2,811	100,200	<2E-16 ***
Kaarevuus	2,937	2,997	598,100	<2E-16 ***
Säteily	2,991	3	243,1	<2E-16 ***

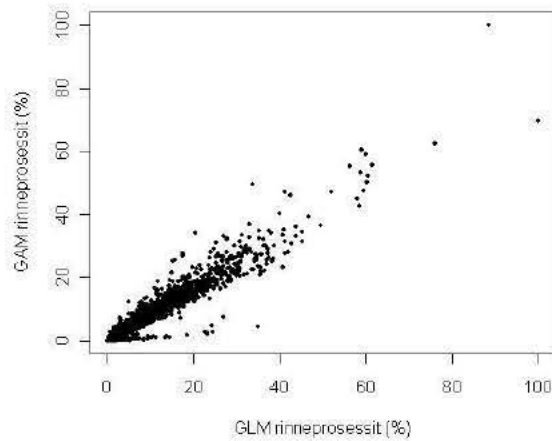


Kuva 45. GAM-mallin tulokset.

Spearmanin korrelaatiokerroin kalibraatioaineistolle oli 0,789 ja evaluointiaineistolle 0,743. Kuvassa 46 on esitetty havaittujen rinneprosessiarvojen suhde ennustettuihin. Molemmassa tapauksissa GAM antaa suurempia arvoja, erityisesti pienillä arvoilla. Suuremmilla arvoilla näyttää siltä, että malli antaa liian pieniä ennustearvoja. Ennuste rinneprosessien alueellisesta esiintymisestä on esitetty liitteessä 7. Se näyttää yhtyvän hyvin vastaavaan GLM-ennusteeseen. Ennusteiden välinen Spearmanin korrelaatio onkin 0,979. Riippuvuus on esitetty kuvassa 47 ja sen perusteella GLM ennustaa hieman pienempiä arvoja kuin GAM.



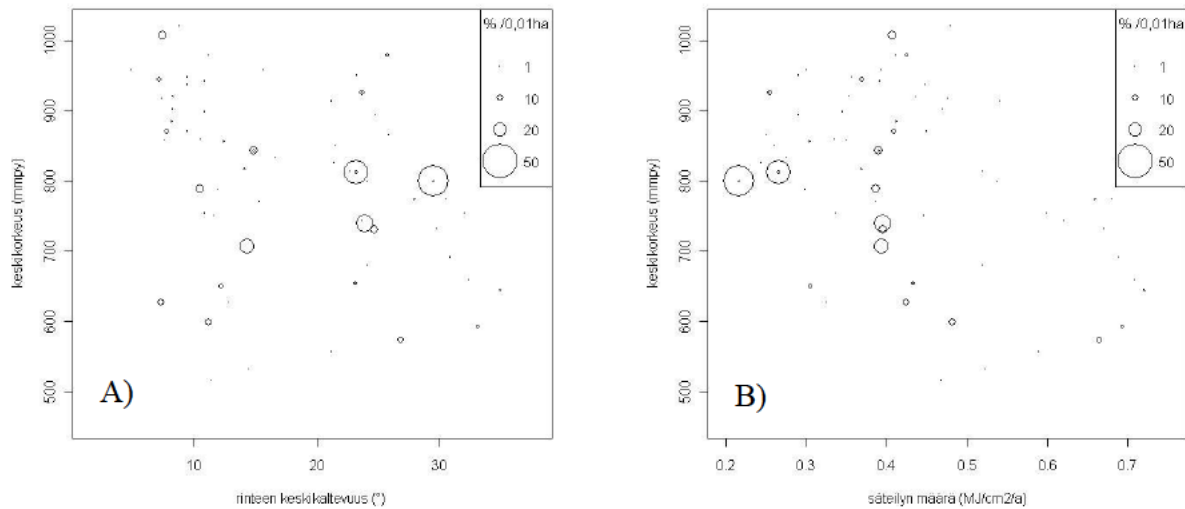
Kuva 46. Rinneprosessien havaitut arvot GAM-ennustetta vastaan. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.



Kuva 47. GLM- ja GAM-ennusteiden vertailua.

### 5.3 Rapautuminen

Kuten taulukosta 4 ja kuvasta 48 nähdään, rapautumista esiintyy melko korkeilla (keskiarvo noin 795 m mpy) ja jyrkillä alueilla (keskiarvo noin 20°). Suurimmat rapautumisarvot esiintyvät siellä, missä säteilyn määrä on vähäisintä keskiarvon ollessa 0,46 MJ/cm<sup>2</sup>/a.



Kuva 48. Rapautumisen esiintyminen suhteessa A) keskikorkeuteen ja rinteiden kaltevuuteen sekä B) keskikorkeuteen ja säteilyn määrään.

GLM-malli selitti 50,4 % rapautumisen alueellisesta vaihtelusta. Spatiaalisten muuttujien lisäämisen jälkeen malli selitti 56,7 % eli selitysaste parani 11,2 %. Valmiin GLM-mallin tulokset on esitetty taulukoissa 11 ja 12. Valmiista mallista putosivat pois seuraavat selittävät muuttujat: keskikorkeus<sup>3</sup>, kaarevuus<sup>3</sup>, kaarevuus<sup>2</sup> sekä rinteiden kaltevuus alle 2° kaikki termit.


Taulukko 11. Valmiin rapautumismallin (Poisson-GLM) selittävät muuttujat, niiden kertoimet sekä keskivirheet.

Muuttuja	Kertoimet	SE
Vakiotermi	-27,450	4,429
Keskikorkeus	0,016	0,009
Keskikorkeus <sup>2</sup>	-6,78E-06	5,97E-06
Kaarevuus	-1,204	0,260
Rinteiden keskijyrkkyys	-0,221	0,127
Rinteiden keskijyrkkyys <sup>2</sup>	0,019	0,007
Rinteiden keskijyrkkyys <sup>3</sup>	-2,83E-04	1,18E-04
Säteily	145,700	15,360
Säteily <sup>2</sup>	-318,400	34,910
Säteily <sup>3</sup>	205,300	24,930
Maaperä 2	-2,74	0,747
Maaperä 3	-11,340	469,300
Kallioperä	-0,628	0,160

Taulukko 12. Tietoa rapautumismallin (Poisson-GLM) hajonnasta sekä tilastollisista merkitsevyyksistä.

Muuttuja	Hajonta	Residuaalien hajonta	d.f.	F	Pr(>F)
Vakiotermi		1342,5	258		
Keskikorkeus	190,7	1151,8	257	190,708	< 2,2E-16 ***
Keskikorkeus <sup>2</sup>	92,0	1059,7	256	92,041	< 2,2E-16 ***
Kaarevuus	13,3	1046,4	255	13,273	0,0002692 ***
Rinteen keskijyrkkyys	51,0	995,4	254	51,011	9,186E-13 ***
Rinteen keskijyrkkyys <sup>2</sup>	48,1	947,3	253	48,124	4,000E-12 ***
Rinteen keskijyrkkyys <sup>3</sup>	6,9	940,4	252	6,931	0,0084731 **
Säteily	86,8	853,5	251	86,835	< 2,2E-16 ***
Säteily <sup>2</sup>	46,4	807,1	250	46,441	9,444E-12 ***
Säteily <sup>3</sup>	89,687	717,41	249	89,687	< 2,2E-16 ***
Maaperä	35,1	682,3	246	11,707	1,148E-07 ***
Kallioperä	16,7	665,6	245	16,650	4,496E-05 ***


Eniten mallin hajontaa selittää korkeuden lineaarinen termi (14,2 %). Hierarkkisen osituksen tulokset ovat nähtävillä kuvassa 49. Sen mukaan suurin itsenäinen vaikutus on NDVI:llä (32,6 %) ja TWI:llä (12,3 %). Maaperän vaikutus on 11,5 %, keskikorkeuden ja säteilyn vaikutus on molemmilla hieman yli kymmenen prosenttia.



Kuva 49. A) Selitetyn hajonnan osuus sekä B) hierarkkisen osituksen tulokset.

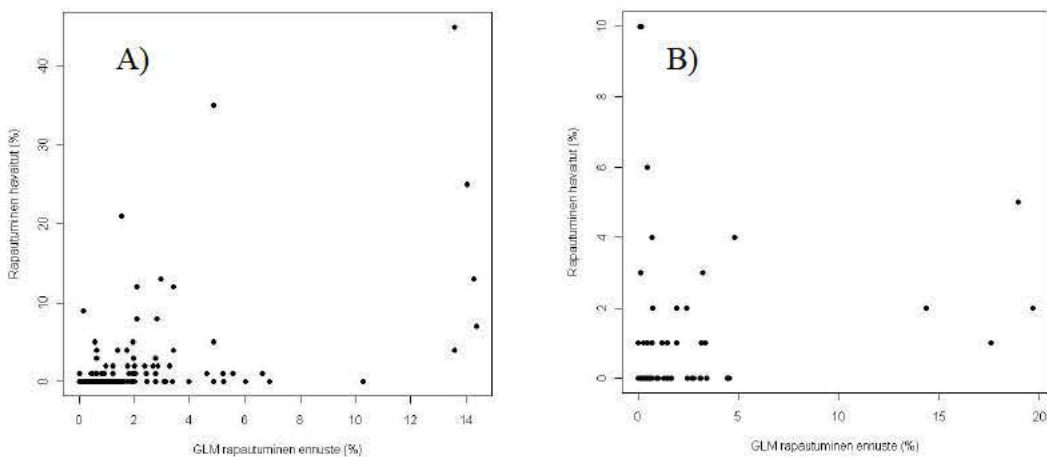
Kuvassa 50 on esitetty rapautumisen ennustetut vastekäyrät suhteessa säteilyyn. Siitä nähdään, että rapautumisen esiintyminen laskee säteilyn määrän kasvaessa saavuttaen melko vakaan tason noin 0,5 MJ/cm<sup>2</sup>/a kohdalla. GLM-malli ennusti yli 1 % rapautumisarvoja 1 309 eli viiteen prosenttiin mallinnusruuduista. Ennuste rapautumisen alueellisesta esiintymisestä on esitetty liitteessä 8. Siitä nähdään, että

suurimmat rapautumisarvot sijoittuvat korkeille alueille, jotka saavat vähän auringonsäteilyä.




Kuva 50. Rapautumisen ennustettu vaste säteilyn määrään.

Spearmanin korrelaatiokerroin kalibraatioaineistolle on 0,527 ja evaluointiaineistolle 0,390. Kuvasta 51 nähdään havaittujen rapautumisarvojen suhde ennusteisiin. Havaitut arvot ja ennusteet pysyvät melko samoina pienillä arvoilla, mutta pisteparvi hajoaa suuresti arvojen kasvaessa. Tarkasteltaessa mallin residuaaleja, huomataan varianssin suurenevan arvojen kasvaessa (kuva 52).



Kuva 51. Rapautumisen havaitut arvot GLM-ennustetta vastaan. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.

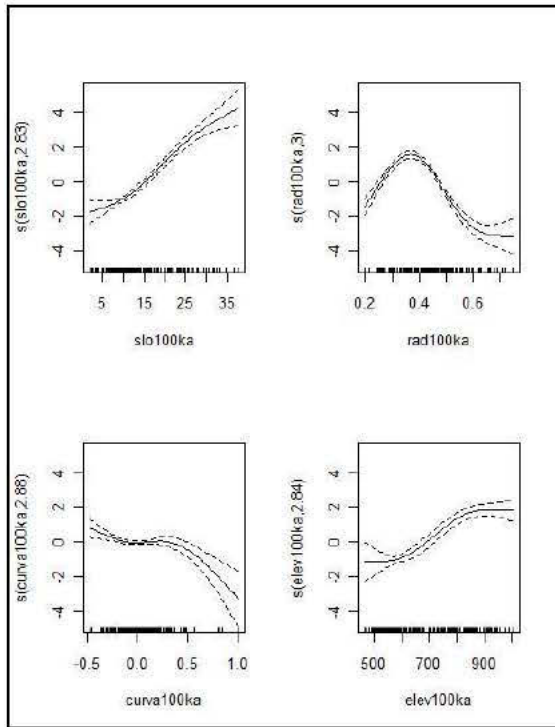


Kuva 52. Rapautumismallin standardoidut residuaalit kuvattuna sovitettuja arvoja vastaan.

GAM-malliin tulivat mukaan kaikki muut selittävät muuttujat, paitsi rinteiden kaltevuus alle 2°. Valmis rapautumismalli selitti 50,5 % aineiston vaihtelusta. Spatiaalisten muuttujien lisäyksen jälkeen selitysaste oli 57,8 %, joten se parani 12,6 %. GAM-mallin tulokset on esitetty taulukossa 13 ja kuvassa 53.


Taulukko 13. Valmiin rapautumismallin (Poisson-GAM) tulokset.

<b>Muuttuja</b>	<i>edf</i>	<i>ref.df</i>	<i>Chi.sq</i>	<i>P</i>
Rinteiden keskijyrkkyys	2,827	2,979	225,590	< 2E-16 ***
Säteily	2,997	3,000	176,790	< 2E-16 ***
Kaarevuus	2,882	2,990	23,730	2,81E-05 ***
Keskikorkeus	2,843	2,981	130,060	< 2E-16 ***




Kuva 53. GAM-mallin tulokset.

GAM-malli ennusti yli 1 % /ha rapautumisarvoja 310 ruutuun eli ainoastaan 1,2 % tutkimusalueesta. Spearmanin korrelaatiokerroin kalibraatioaineistolle oli 0,495 ja evaluointiaineistolle 0,348. Kuvasta 54 nähdään havaittujen arvojen suhde ennusteisiin. Ennuste rapautumisen alueellisesta esiintymisestä perustuen GAM-malliin on esitetty liitteessä 9. Suuret rapautumisarvot esiintyvät samoilla alueilla kuin GLM-mallissakin. Mallien välinen Spearmanin korrelaatio oli 0,758 ja suhde on esitetty kuvassa 55. Siinä nähdään, että GLM-malli ennustaa huomattavasti suurempia arvoja kuin GAM-malli.



Kuva 54. Rapautumisen havaitut arvot GAM-ennustetta vastaan. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.

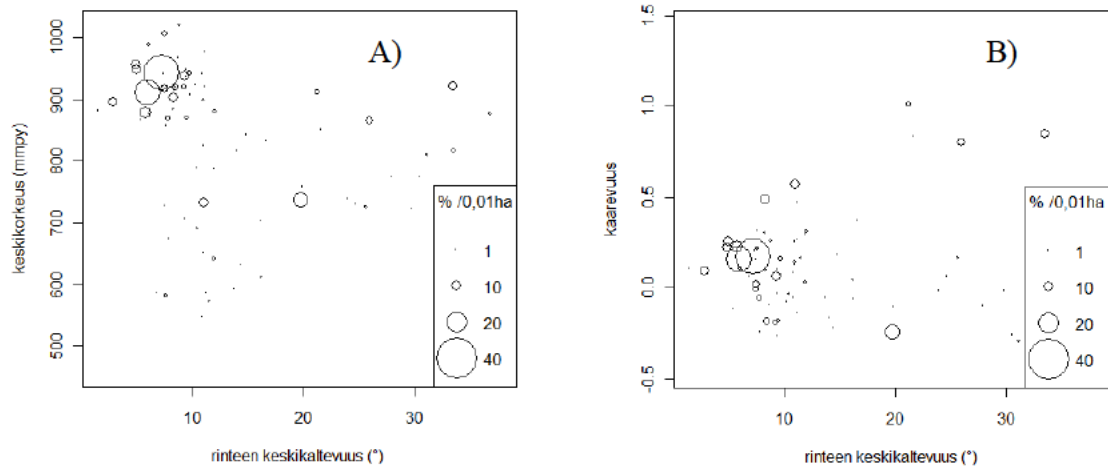




Kuva 55. GLM- ja GAM-mallien vertailua.

#### 5.4 Deflaatio

Deflaation esiintyminen liittyy voimakkaasti korkeuteen merenpinnasta (keskiarvo 818,2 m mpy, mutta sitä on myös eniten suhteellisen tasaisilla alueilla (kaarevuuden keskiarvo=0,105) (kuva 56).



Kuva 56. Deflaation esiintyminen suhteessa A) keskikorkeuteen ja rinteiden kaltevuuteen sekä B) kaarevuuteen ja rinteiden kaltevuuteen.

GLM-malli selitti 70,5 % deflaation alueellisesta vaihtelusta. Kun spatiaaliset muuttujat lisättiin malliin, selitysaste kohosi 77,2 % (8,6 % parannus). Valmiin GLM-mallin tulokset on esitetty taulukoissa 14 ja 15. Deflaatiomalliin tulivat mukaan kaikki muut

selittävät muuttujat paitsi kaarevuus<sup>3</sup> sekä rinteiden kaltevuus alle 2° toisen ja kolmannen asteen termit. Myös säteilyn kaikki termit poistettiin lopullisesta mallista.

Taulukko 14. Valmiin deflaatiomallin (Poisson-GLM) selittävät muuttujat, kertoimet sekä keskivirheet.


<b>Muuttuja</b>	<b>Kertoimet</b>	<b>SE</b>
Vakiotermi	-74,940	703,100
Keskikorkeus	0,205	0,063
Keskikorkeus <sup>2</sup>	-2,91E-04	0,000
Keskikorkeus <sup>3</sup>	1,09E-07	0,000
Kaarevuus	1,029	0,348
Kaarevuus <sup>2</sup>	0,593	0,385
Rinteiden keskijyrkkyys	-0,050	0,068
Rinteiden keskijyrkkyys <sup>2</sup>	-0,008	0,004
Rinteiden keskijyrkkyys <sup>3</sup>	3,41E-04	0,000
Rinteiden kaltevuus < 2°	0,023	0,003
Maaperä <sup>2</sup>	1,215	702,900
Maaperä <sup>3</sup>	-8,512	2423,000
Kallioperä	-0,909	0,157

Taulukko 15. Tietoa deflaatiomallin (Poisson-GLM) hajonnasta sekä tilastollisista merkitsevyyksistä.

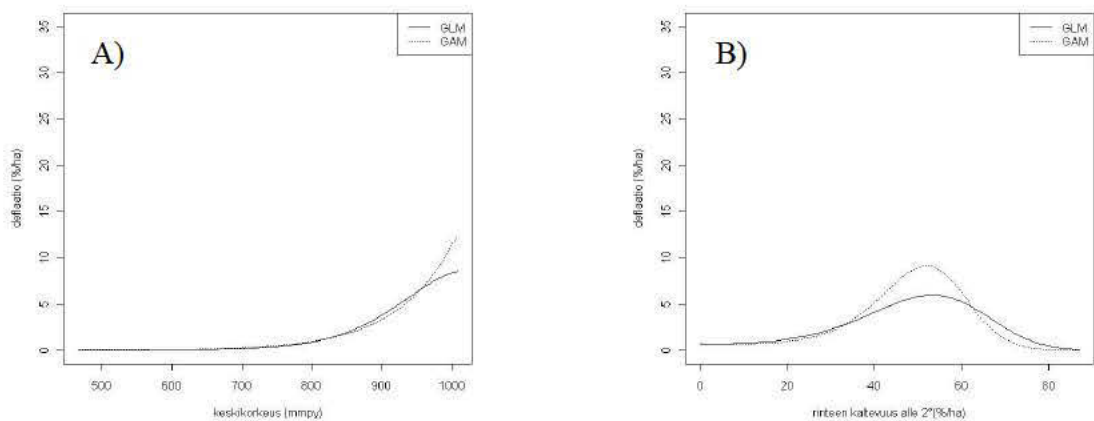
<b>Muuttuja</b>	<b>Hajonta</b>	<b>Residuaalien hajonta</b>	<b>d.f.</b>	<b>F</b>	<b>Pr(&gt;F)</b>
Vakiotermi		1015,4	256		
Keskikorkeus	515,5	499,8	255	515,54	< 2,2E-16 ***
Keskikorkeus <sup>2</sup>	0,0	499,8	254	0,00	0,963
Keskikorkeus <sup>3</sup>	6,7	493,1	253	6,73	0,009462 **
Kaarevuus	22,5	470,6	252	22,47	2,137E-06 ***
Kaarevuus <sup>2</sup>	7,9	462,7	251	7,90	0,004956 **
Rinteiden keskijyrkkyys	40,7	422,0	250	40,70	1,777E-10 ***
Rinteiden keskijyrkkyys <sup>2</sup>	20,8	401,2	249	20,83	5,024E-06 ***
Rinteiden keskijyrkkyys <sup>3</sup>	10,5	390,7	248	10,46	0,001222 **
Rinteiden kaltevuus < 2°	65,1	325,6	247	65,13	7,004E-16 ***
Maaperä	10,3	315,3	245	5,13	0,005921 **
Kallioperä	15,7	299,7	244	15,66	7,582E-05 ***

Taulukosta 15 nähdään, että keskikorkeuden lineaarinen termi selitti selvästi eniten kokonaisvaihtelusta (50,7 %). Muilla muuttujilla oli melko pieni rooli mallin selityksessä (kuva 57). Keskikorkeus<sup>2</sup> ei selittänyt yhtään mallista, mutta koska keskikorkeus<sup>3</sup> on tilastollisesti merkitsevä, on sen mukana pitäminen on perusteltua. Hierarkkisen osituksen mukaan NDVI on tärkein yksittäinen muuttuja selittäen 35,6 %

mallista. Seuraavaksi tärkeimmät muuttujat ovat keskikorkeus (33,1 %), kaarevuus (6,1%) sekä x-koordinaatti (5,6 %). Kuvassa 58 on deflaation ennustetut vastekäyrät suhteessa keskikorkeuteen ja rinteen kaltevuus alle 2°. GLM-malli ennusti yli 1 % /ha deflaatioarvoja tutkimusalueella 3 708 mallinusruntuun (14,2 %). Ennuste deflaation alueellisesta esiintymisestä GLM-malliin perustuen on esitetty liitteessä 10.



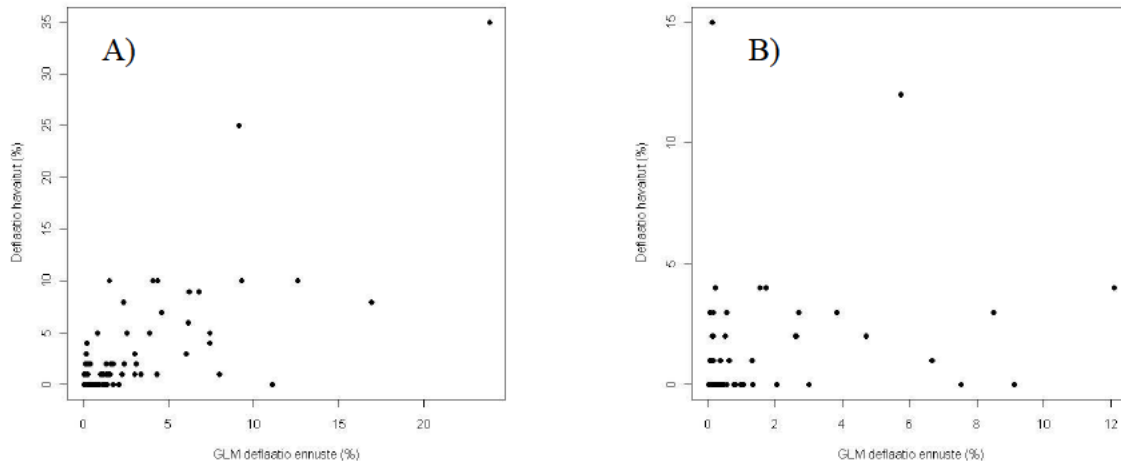
Kuva 57. A) Selitetyn hajonnan osuus ja b) hierarkkisen osituksen tulokset deflaatiomallin pohjalta.




Kuva 58. Deflaation ennustettu vaste A) keskikorkeuteen ja B) rinteen kaltevuus alle 2°.

Molemmat mallit antavat melko samanlaisia ennusteita GAM-mallin poiketessa hieman GLM:sta oikeanpuoleisessa diagrammissa (kuva 58). Spearmanin korrelaatiokerroin kalibraatioaineistolle on 0,557 ja evaluointiaineistolle 0,441. Kuvasta 59 nähdään

havaittujen deflaatioarvojen suhde ennusteisiin. Jälleen on havaittavissa suurta vaihtelua arvojen välillä erityisesti evaluointiaineiston kohdalla. Mallin residuaaleissa (kuva 60) näkyy merkkejä heteroskedastisuudesta.



Kuva 59. Deflaation havaitut arvot GLM-ennustetta vastaan. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.

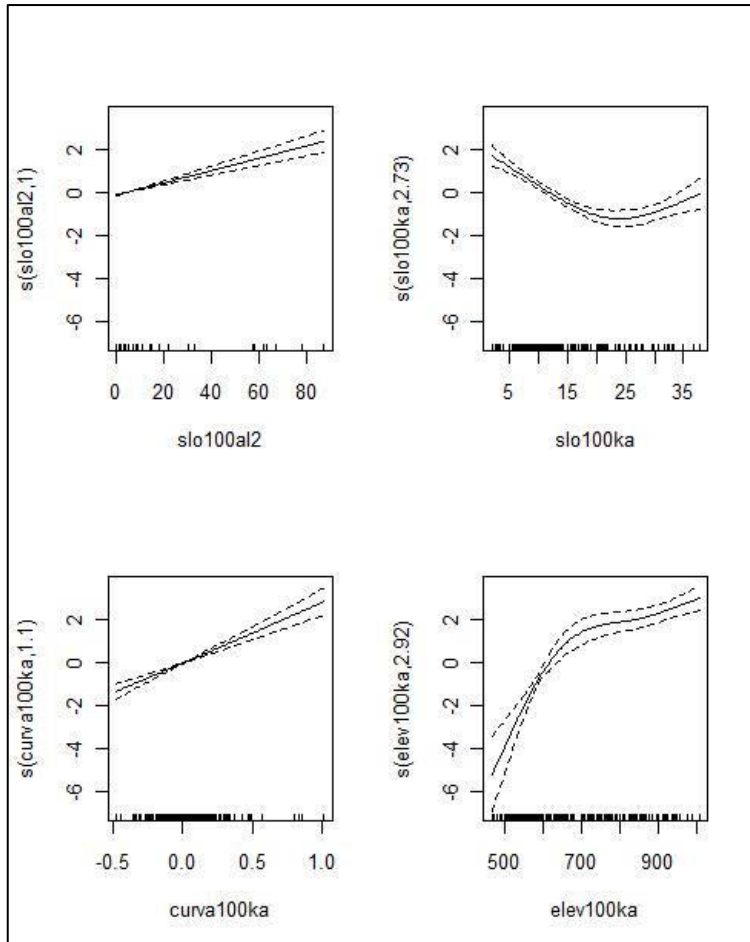


Kuva 60. Deflaatiomallin (GLM) standardoidut residuaalit.

GAM-malli selitti 68,5 % deflaation esiintymisestä. Spatiaalisten muuttujien lisäämisen jälkeen selitysaste oli 78,0 % eli se parani 12,2 %. GAM-mallin tulokset on esitetty taulukossa 16 ja kuvassa 61. Valmiissa mallissa oli mukana kaikki muut selittävät muuttujat, paitsi säteily. Rinteen kaltevuus alle 2° on mallissa mukana lineaarisena terminä tasoitusfunktion saadessa arvon yksi.

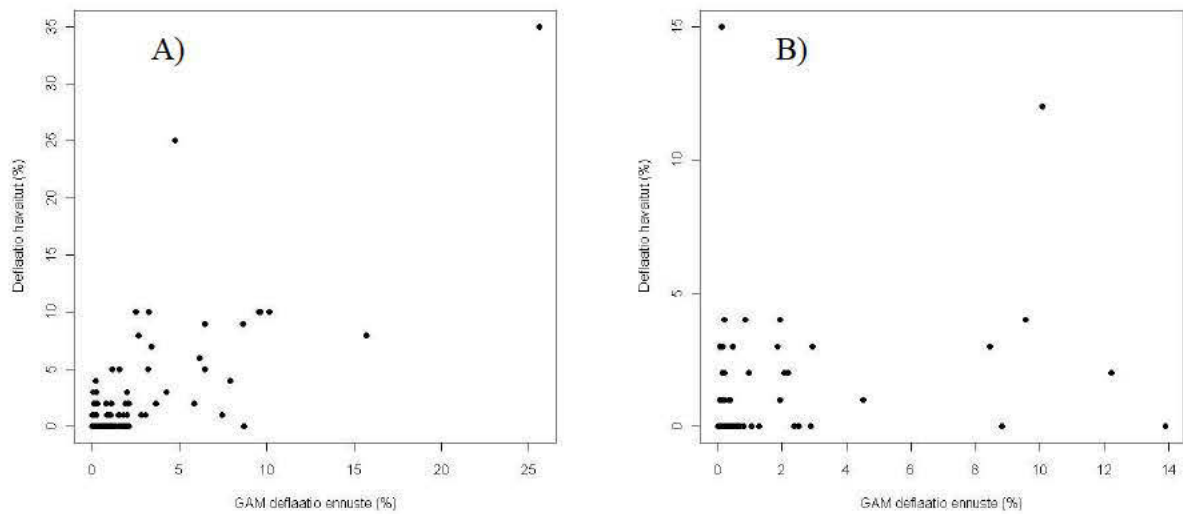
Taulukko 16. Deflaatiomallin (Poisson-GAM) tulokset.

<b>Muuttuja</b>	<i>edf</i>	<i>ref.df</i>	<i>Chi.sq</i>	<i>P</i>
Rinteen kaltevuus < 2°	1,000	1,000	88,110	< 2E-16 ***
Rinteen keskijyrkkyys	2,728	2,945	69,260	5,59E-15 ***
Kaarevuus	1,104	1,197	90,530	< 2E-16 ***
Keskikorkeus	2,924	2,994	131,310	< 2E-16 ***




Kuva 61. GAM-mallin tulokset.

GAM-malli ennusti yli 1% /ha deflaatioarvoja 6 567 eli 25,2 % mallinnusruuduista. Liitteessä 11 on esitetty deflaation alueellisen esiintymisen ennuste perustuen GAM-malliin. Malli ennustaa suuria deflaatioarvoja korkeiden tunturien huipuille ja suhteellisen tasaisille alueille. Spearmanin korrelaatiokerroin kalibraatioaineistolle 0,535 ja evaluointiaineistolle 0,451. Havaittujen deflaatioarvojen suhdetta ennustettuihin on tarkasteltu kuvassa 62.



Kuva 62. Havaittujen deflaatioarvojen suhde ennustettuihin arvoihin. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.

GLM- ja GAM-malleja on vertailtu kuvassa 63. Siitä on nähtävissä, että GAM-malli ennustaa systemaattisesti suurempia deflaatioarvoja kuin GLM-malli. Mallien välinen Spearmanin korrelaatiokerroin on 0,925.

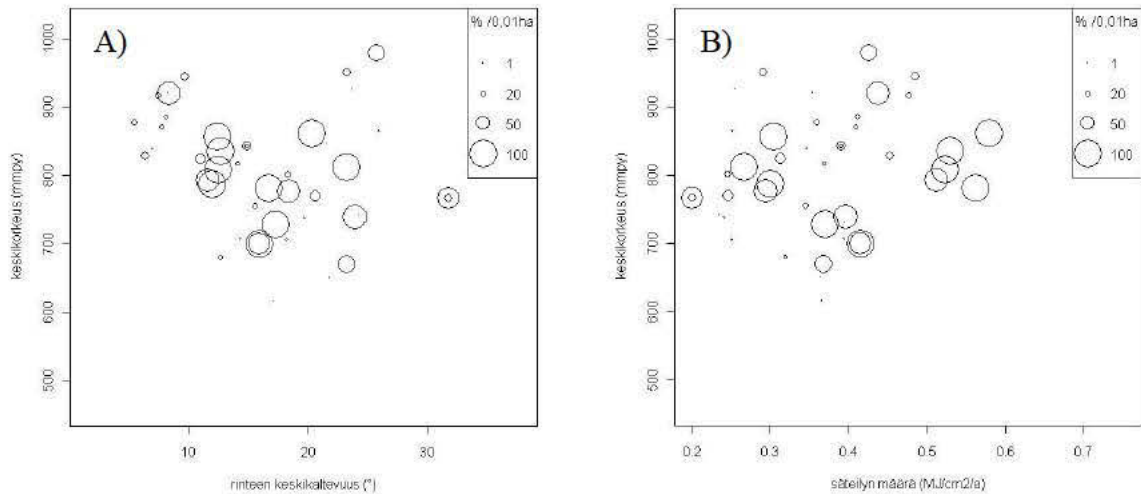


Kuva 63. GLM- ja GAM-mallien vertailua.

## 5.5 Nivaatio

Kuvassa 64 on esitetty nivaation esiintyminen suhteessa eri ympäristömuuttujiin. Siitä ja taulukosta 4 nähdään, että nivaatiota esiintyy keskimäärin korkealla ( $k_a=803,9$  m

mpy) sekä suhteellisen jyrkässä rinteessä ( $ka=17,3^\circ$ ). Nivaatiota esiintyy säteilyn määrään nähden laajalla alueella, kuitenkin hieman enemmän alhaisen säteilyn alueilla ( $ka=0,35 \text{ MJ/cm}^2/\text{a}$ ).



Kuva 64. Nivaation esiintyminen suhteessa A) keskikorkeuteen ja rinteän kaltevuuteen sekä B) keskikorkeuteen ja säteilyn määrään.

GLM-malli selitti 63,5 % nivaation esiintymisestä. Kun spatiaaliset muuttujat lisätään, selitysaste kohoaa 68,3 prosenttiin. Näin ollen parannusta on 7,1 %. GLM-mallin tulokset on esitetty taulukoissa 17 ja 18. Valmiiseen nivaatiomalliin tulivat mukaan kaikki muut selittävät muuttujat paitsi kaarevuus<sup>3</sup> ja rinteän kaltevuus alle  $2^\circ$ .

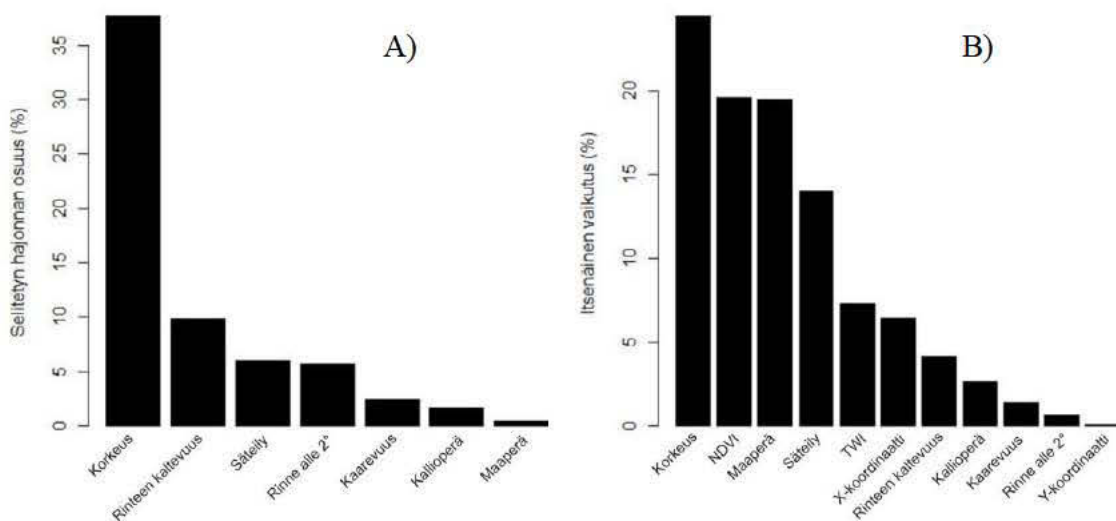
Taulukko 17. Nivaatiomallin (GLM) selittävät muuttujat, niiden kertoimet sekä keskivirheet.

Muuttuja	Kertoimet	SE
Vakiotermi	0,111	20,390
Keskikorkeus	-0,163	0,079
Keskikorkeus <sup>2</sup>	3,59E-04	1,007E-04
Keskikorkeus <sup>3</sup>	-2,11E-07	4,285E-08
Kaarevuus	-1,400	0,164
Kaarevuus <sup>2</sup>	-2,882	0,483
Rinteän keskijyrkkyys	1,441	0,100
Rinteän keskijyrkkyys <sup>2</sup>	-0,061	0,005
Rinteän keskijyrkkyys <sup>3</sup>	7,99E-04	8,540E-05
Säteily	-2,890	10,040
Säteily <sup>2</sup>	47,850	24,150
Säteily <sup>3</sup>	-72,56	18,870
Rinteän kaltevuus < 2°	0,207	0,009
Rinteän kaltevuus < 2° <sup>2</sup>	-0,003	1,673E-04
Kallioperä	0,731	0,065
Maaperä 2	-1,156	0,152
Maaperä 3	-6,148	284,700

Taulukko 18. Tietoa nivaatiomallin (GLM) hajonnasta sekä tilastollisista merkitsevyyksistä.

Muuttuja	Hajonta	Residuaalien hajonta	d.f.	F	Pr(>F)
Vakiotermi		8493,3	256		
Keskikorkeus	1317,8	7175,6	255	1317,775	< 2,2e-16 ***
Keskikorkeus <sup>2</sup>	1877,0	5298,6	254	876,948	< 2,2e-16 ***
Keskikorkeus <sup>3</sup>	7,1	5291,5	253	7,133	0,007566 **
Kaarevuus	79,2	5212,3	252	79,160	< 2,2e-16 ***
Kaarevuus <sup>2</sup>	122,4	5089,9	251	122,407	< 2,2e-16 ***
Rinteen keskijyrkkyys	94,1	4995,8	250	94,129	< 2,2e-16 ***
Rinteen keskijyrkkyys <sup>2</sup>	715,6	4280,2	249	715,633	< 2,2e-16 ***
Rinteen keskijyrkkyys <sup>3</sup>	22,9	4257,3	248	22,870	1,734e-06 ***
Säteily	217,8	4039,5	247	217,813	< 2,2e-16 ***
Säteily <sup>2</sup>	228,2	3811,2	246	228,233	< 2,2e-16 ***
Säteily <sup>3</sup>	62,3	3749,0	245	62,281	2,978e-15 ***
Rinteen kaltevuus < 2°	264,2	3484,8	244	264,208	< 2,2e-16 ***
Rinteen kaltevuus < 2° <sup>2</sup>	217,8	3266,9	243	217,810	< 2,2e-16 ***
Maaperä	29,3	3237,6	241	14,662	4,291e-07 ***
Kallioperä	134,9	3102,7	240	134,870	< 2,2e-16 ***

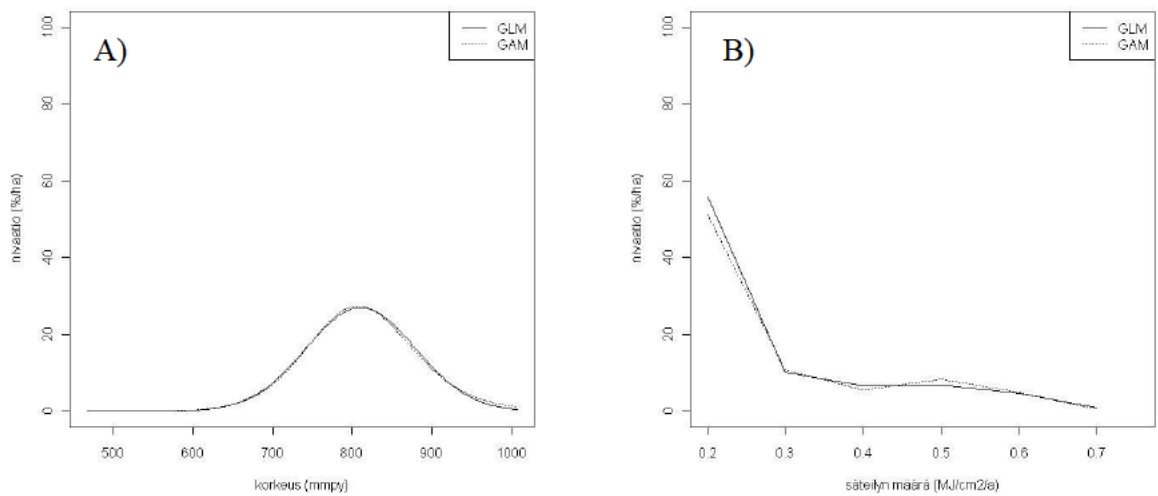
Taulukosta 18 nähdään, että keskikorkeuden toisen asteen termi selitti eniten kokonaisvaihtelusta (22,1 %). Yhteensä keskikorkeus kaikkine termeineen selitti 37,7 % mallista (kuva 65). Myös rinteen keskijyrkkyys<sup>2</sup> selitti suhteellisen paljon kokonaisvaihtelusta (8,4 %). Hierarkkisen osituksen tulosten perusteella keskikorkeus (28,6 %), NDVI (19,6 %) sekä maaperä (19,4 %) ovat nivaation esiintymisen kannalta tärkeimmät muuttujat. Myös säteilyllä oli suuri itsenäinen vaikutus (14,0 %). X-koordinaatin vaikutus ilmiön esiintymiseen oli 6,4 %.



Kuva 65. A) Selitetyn hajonnan osuus sekä B) hierarkkisen osituksen tulokset perustuen nivaatiomalliin.

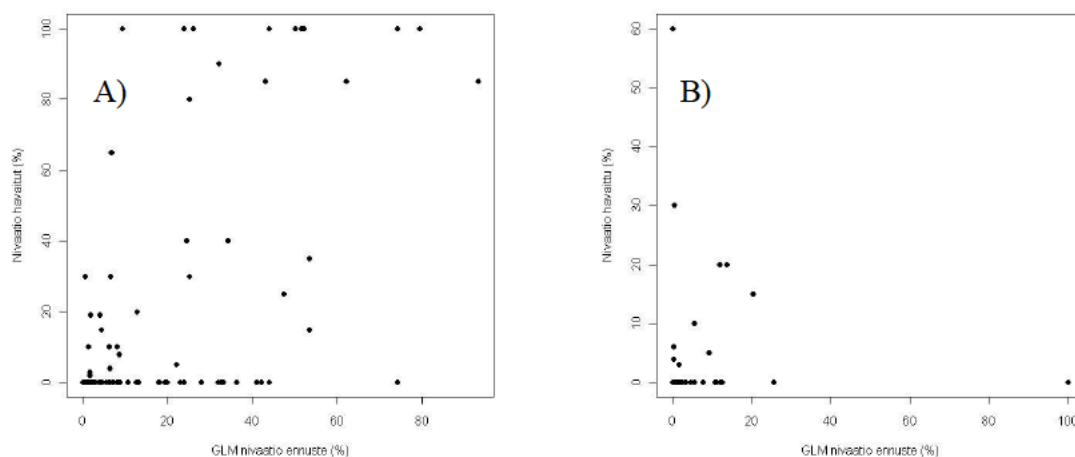


Kuvassa 66 on nivaation ennustetut vasteet korkeuden ja säteilyn suhteen. Eniten nivaatiota esiintyy mallin mukaan noin 800 metrin korkeudella, jonka jälkeen arvot lähtevät laskuun todennäköisesti rinteiden kaltevuuden pienenemisen johdosta. Säteilyn suhteen nivaatiota esiintyy eniten pienen säteilyn alueella. Säteilyn määrän kasvaessa nivaatioarvot laskevat nopeasti noin  $0,3 \text{ MJ/cm}^2/\text{a}$  asti, jonka jälkeen lasku on melko hidasta. GLM ennusti yli 1% /ha nivaatioarvoja 626:n eli 2,4 % mallinnusruuduista. GLM-ennuste nivaation alueellisesta esiintymisestä on esitetty liitteessä 12. Siitä nähdään, että malli ennustaa nivaatiota korkeille alueille, jotka saavat vähän säteilyä.




Kuva 66. Nivaation ennustetut vastekäyrät suhteessa A) keskikorkeuteen ja B) säteilyyn.

Spearmanin korrelaatiokerroin kalibraatioainestolle on 0,507 ja evaluointiaineistolle 0,331. Kuvassa 67 on havaittujen nivaatioarvojen suhde ennusteisiin. Mallin residuaaleja on tarkasteltu kuvassa 68. Etenkin pienillä ennustearvoilla virhe on pieni, mutta arvojen kasvaessa myös residuaalit kasvavat.



Kuva 67 Nivaation havaitut arvot GLM-ennustetta vastaan. A) Ennuste on sovitettu kalibraatio- ja B) evaluointiaineistoon.

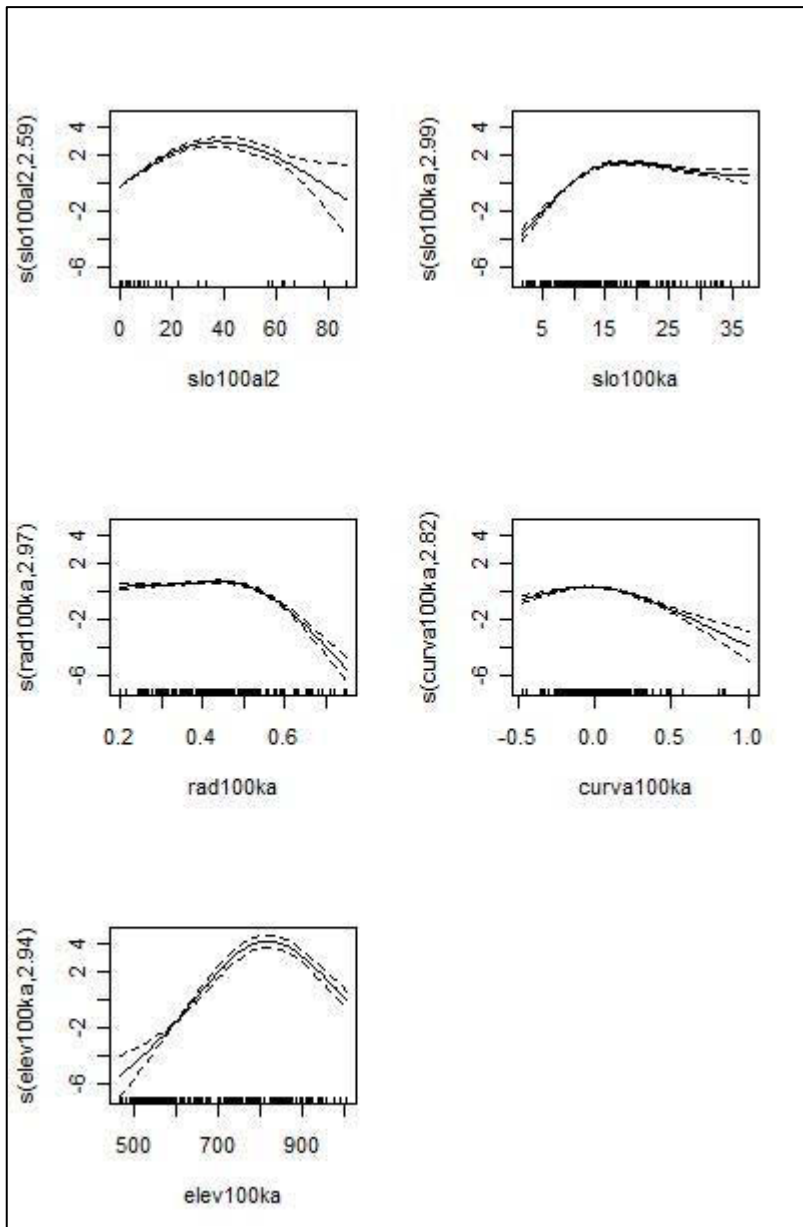


Kuva 68. Nivaatiomallin standardoidut residuaalit suhteessa ennustettuihin arvoihin.

GAM-malli selittää 62,1 % nivaation esiintymisestä. Spatiaalisten muuttujien kanssa selitysaste on 69,7 % eli se paranee 10,9 %. Valmiissa GAM-mallissa ovat kaikki selittävät muuttujat mukana. Mallin tulokset on esitetty taulukossa 19 ja kuvassa 69.

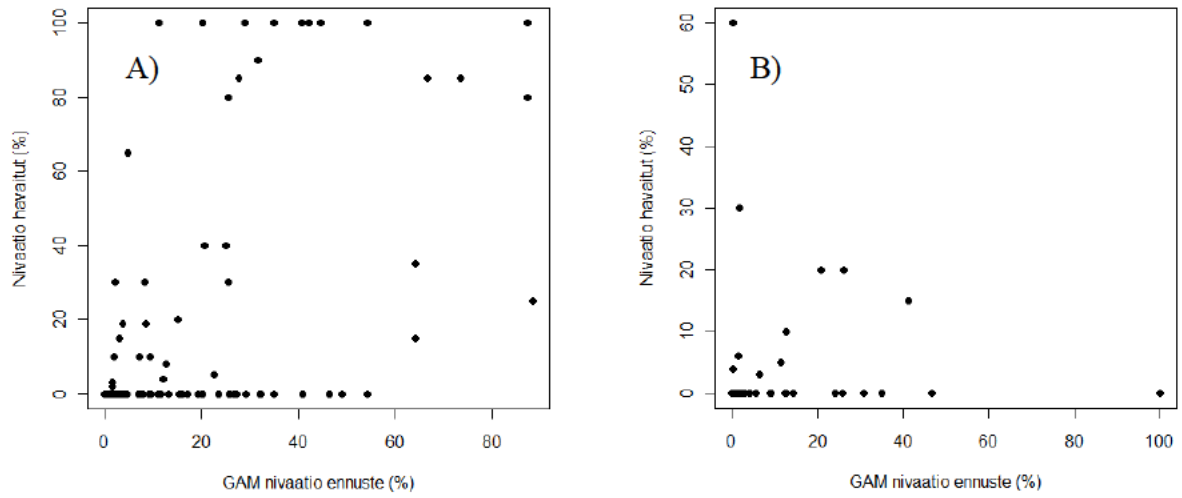
Taulukko 19. Valmiin nivaatiomallin (Poisson-GAM) tulokset.

Muuttuja	<i>edf</i>	<i>ref.df</i>	<i>Chi.sq</i>	<i>P</i>
Keskikorkeus	2,937	2,997	993,600	<2E-16 ***
Rinteen keskijyrkkyys	2,986	3,000	459,900	<2E-16 ***
Rinteen kaltevuus < 2°	2,587	2,840	414,600	<2E-16 ***
Kaarevuus	2,825	2,978	196,500	<2E-16 ***
Säteily	2,974	2,999	281,9	<2E-16 ***




Kuva 69. GAM-mallin tulokset.

GAM-malli ennustaa yli 1 % /ha nivaatioarvoja 2 063 eli 7,9 % mallinnusruduista. Nivaation ennustettu alueellinen esiintyminen GAM-malliin perustuen on esitetty liitteessä 13. Spearmanin korrelaatiokerroin kalibraatioaineistolle on 0,510 ja evaluointiaineistolle 0,325. Kuvassa 70 on esitetty havaittujen nivaatioarvojen suhde GAM-ennusteisiin. GLM-malliin verrattuna GAM-malli ennusti nivaation esiintymistä myös esimerkiksi Ailakkavaaran etelärinteille. Muuten mallit antavat melko yhteneväisiä ennusteita, mistä kertoo myös korkea Spearmanin korrelaatiokerroin 0,965. Mallien ennustamia arvoja voi vertailla kuvan 71 perusteella.




Kuva 70. Havaitut nivaatioarvot suhteessa GAM-ennusteisiin. A) Malli on sovitettu kalibraatio- ja B) evaluointiaineistoon.



Kuva 71. GLM- ja GAM-mallien vertailua.

## 5.6 Fluviaaliprosessit

Fluviaaliprosesseja esiintyy melko alhaisilla korkeuksilla ( $k_a=634\text{m mpy}$ ). Esiintymisalueilla on myös keskimäärin pienempi rinteenkalltevuus ( $k_a=12,9^\circ$ ) kuin alueilla, missä fluviaaliprosesseja ei esiinny ( $k_a=14,6^\circ$ ). Kuvasta 72 nähdään, että nämä prosessit liittyvät negatiivisiin kaarevuus arvoihin ( $k_a=-0,03$ ). Tämä tarkoittaa, että maasto on kuperaa.



Kuva 72. Fluviaaliprosessien esiintyminen suhteessa keskikorkeuteen ja kaarevuuteen.

GLM-malli selitti 66,0 % fluviaaliprosessien esiintymisestä. Spatiaalisten muuttujien lisäämisen jälkeen selitysaste oli 77,4 % eli parannusta tapahtui 14,7 %. Valmiin GLM-mallin tulokset on esitetty taulukoissa 20 ja 21. Fluviaaliprosessimalliin tulivat mukaan kaikki muut muuttujat, paitsi maa- ja kallioperä.

Taulukko 20. Valmiin fluviaaliprosessimallin (Poisson-GLM) selittävät muuttujat, niiden kertoimet sekä keskivirheet.

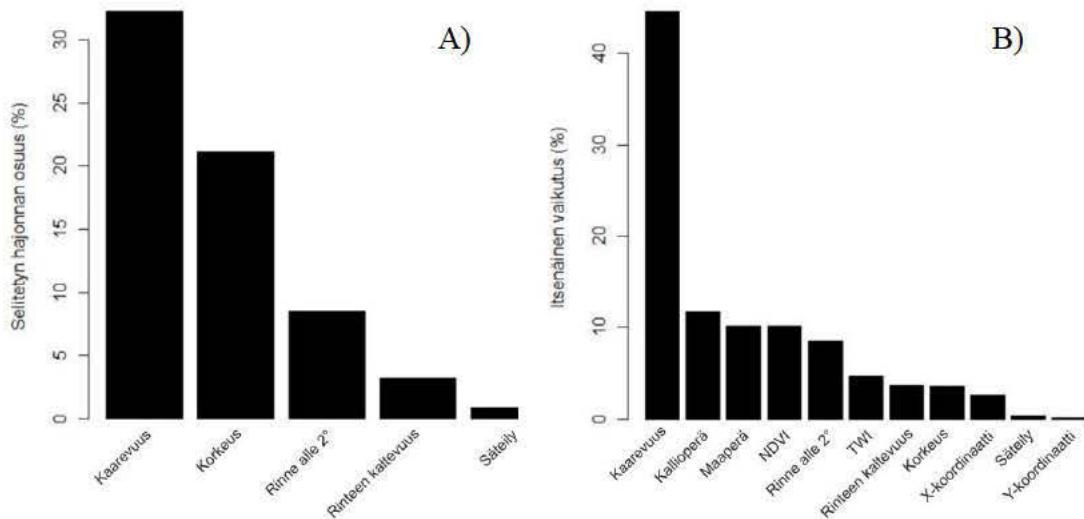
<b>Muuttuja</b>	<b>Kertoimet</b>	<b>SE</b>
Vakiotermi	-32,840	35,15
Keskikorkeus	0,177	0,1644
Keskikorkeus <sup>2</sup>	-1,66E-04	2,56E-04
Keskikorkeus <sup>3</sup>	2,76E-08	1,32E-07
Kaarevuus	-1,122	0,6376
Kaarevuus <sup>2</sup>	0,624	2,993
Kaarevuus <sup>3</sup>	-25,34	7,158
Rinteen keskijyrkkyys	-0,676	0,07489
Rinteen keskijyrkkyys <sup>2</sup>	0,037	0,005485
Rinteen keskijyrkkyys <sup>3</sup>	-6,70E-04	1,15E-04
Säteily	-99,140	27,86
Säteily <sup>2</sup>	207,7	61,55
Säteily <sup>3</sup>	-136,700	43,82
Rinteen kaltevuus < 2°	-19,170	343,7
Rinteen kaltevuus < 2° <sup>2</sup>	2,104	37,15
Rinteen kaltevuus < 2° <sup>3</sup>	-0,05774	1,019

Taulukosta 21 nähdään, että kaarevuuden lineaarinen termi oli tärkein yksittäinen muuttuja selittäen noin 27 % koko mallista (kuva 68). Myös keskikorkeus<sup>2</sup> oli merkittävä muuttuja mallissa selittäen noin 15 % fluviaaliprosessien esiintymisestä.

Taulukko 21. Tietoa fluviaaliprosessimallin (Poisson-GLM) hajonnasta sekä tilastollisista merkitsevyyksistä.


<b>Muuttuja</b>	<b>Hajonta</b>	<b>Residuaalien hajonta</b>	<b>d.f.</b>	<b>F</b>	<b>Pr(&gt;F)</b>
Vakiotermi		2788,1	258		
Keskikorkeus	136,9	2651,1	257	136,94	< 2,2E-16 ***
Keskikorkeus <sup>2</sup>	420,4	2230,7	256	420,41	< 2,2E-16 ***
Keskikorkeus <sup>3</sup>	31,7	2199,0	255	31,70	1,804E-08 ***
Kaarevuus	744,9	1454,1	254	744,91	< 2,2E-16 ***
Kaarevuus <sup>2</sup>	76,7	1377,5	253	76,65	< 2,2E-16 ***
Kaarevuus <sup>3</sup>	77,3	1300,1	252	77,32	< 2,2E-16 ***
Rinteen keskijyrkkyys	63,7	1236,4	251	63,69	1,454E-15 ***
Rinteen keskijyrkkyys <sup>2</sup>	7,2	1229,2	250	7,24	0,007124 **
Rinteen keskijyrkkyys <sup>3</sup>	18,2	1211,0	249	18,18	2,010E-05 ***
Säteily	0,1	1210,9	248	0,08	0,783
Säteily <sup>2</sup>	8,9	1202,1	247	8,86	0,002921 **
Säteily <sup>3</sup>	15,7	1186,4	246	15,68	7,489E-05 ***
Rinteen kaltevuus < 2°	162,0	1024,4	245	162,00	< 2,2E-16 ***
Rinteen kaltevuus < 2° <sup>2</sup>	2,5	1021,9	244	2,49	0,114812
Rinteen kaltevuus < 2° <sup>3</sup>	73,1	948,8	243	73,10	< 2,2E-16 ***

Hierarkkisen osituksen tulokset on esitetty kuvassa 73b. Sen mukaan selvästi tärkein yksittäinen muuttuja oli kaarevuus, jonka itsenäinen vaikutus oli 44,6 %. Seuraavaksi suurin itsenäinen vaikutus oli kallioperällä (11,7 %), maaperällä (10,2 %) ja NDVI:llä (10,2 %). Kosteusindeksin vaikutus oli 4,6 %.




Kuva 73. A) Selitetyn hajonnan osuus sekä B) hierarkkisen osituksen tulokset fluviaaliprosessimallin perusteella.

Fluviaaliprosessien esiintyminen riippuu suuresti maaston kaarevuudesta. Kuten kuvasta 74 nähdään, fluviaaliprosessiarvot laskevat hyvin nopeasti siirryttäessä kaarevuusarvoissa negatiivisista kohti nollaa eli tasamaata. GLM-malli ennusti fluviaaliprosesseja ( $\geq 1$  %/0,01 ha) vain seitsemään ruutuun tutkimusalueella (0,07 %). Ennuste fluviaaliprosessien alueellisesta esiintymisestä nähdään liitteessä 14.

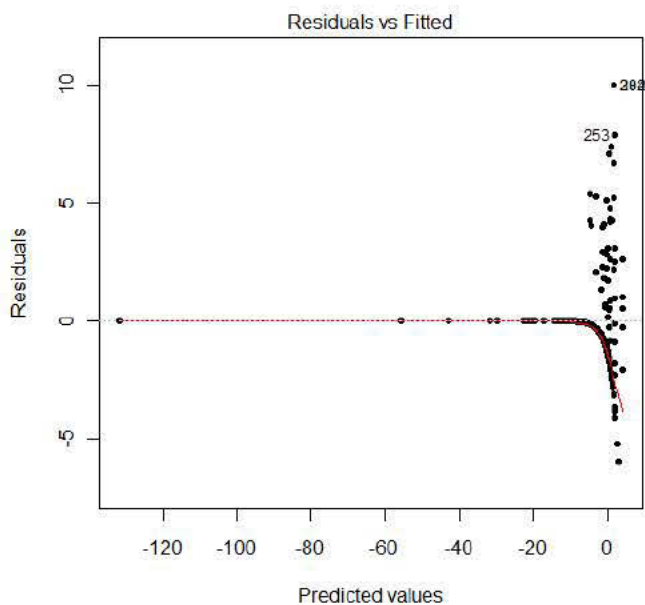


Kuva 74. Fluviaaliprosessien ennustettu vaste maaston kaarevuuteen.

Spearmanin korrelaatiokerroin kalibraatioaineistolle on 0,386 ja evaluointiaineistolle 0,319. Kuvassa 75 on esitetty havaittujen fluviaaliprosessien arvojen suhde ennusteisiin. Mallivirheessä on erittäin suurta vaihtelua suurimpien arvojen kohdalla (kuva 76).



Kuva 75. Fluviaaliprosessien havaitut arvot suhteessa GLM-ennustetta vastaan. A) Ennuste on tehty kalibraatio- ja B) evaluointiaineistoon.




Kuva 76. Fluviaaliprosessimallin standardoidut residuaalit.



Valmiissa GAM-mallissa ovat mukana kaikki muut selittävät muuttujat, paitsi rinteen kaltevuus alle 2°. GAM-malli selitti 59,2 % fluviaaliprosessien esiintymisestä. Kun spatiaaliset muuttujat otettiin mukaan, mallin selitysaste parani 14,6 prosenttia 69,3 prosenttiin. GAM-mallin tulokset on esitetty taulukossa 22 ja kuvassa 77.

Taulukko 22. Valmiin fluviaaliprosessimallin (GAM) tulokset.

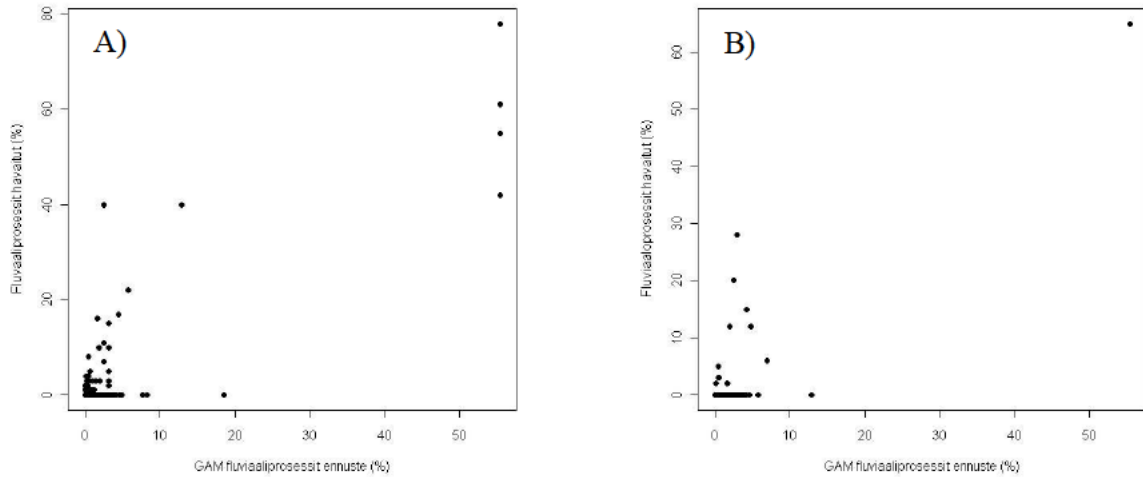
<b>Muuttuja</b>	<i>edf</i>	<i>ref.df</i>	<i>Chi.sq</i>	<i>P</i>
Rinteen keskijyrkkyys	2,975	2,999	119,490	< 2E-16 ***
Säteily	2,970	2,999	31,840	5,64E-07 ***
Kaarevuus	2,959	2,998	460,420	< 2E-16 ***
Keskikorkeus	2,545	2,829	114,240	< 2E-16 ***




Kuva 77. GAM-mallin tulokset.

Ennuste fluviaaliprosessien alueellisesta esiintymisestä perustuen GAM-malliin on esitetty liitteessä 15. GAM-malli ennusti yli 1 % /ha fluviaaliprosessi-arvoja 1 448 eli 5,6 % mallinnusruuduista tutkimusalueella. Se tuo huomattavasti paremmin vaihtelua esiin kuin GLM-ennuste. Spearmanin korrelaatiokerroin kalibraatioaineistolle on 0,267 ja

evaluointiaineistolle 0,258. Havaittujen arvojen suhde ennusteisiin on esitetty kuvassa 78. Mallien välinen Spearmanin korrelaatiokerroin on 0,270 ja mallit on esitetty toisiaan vastaan kuvassa 79. Siitä nähdään, miten GLM-malli ennusti vain muutaman yli 1 % arvon, kun taas GAM-malli ennusti arvoja tasaisemmin.



Kuva 78. Fluviaaliprosessien havaitut arvot GAM-ennustetta vastaan. A) Malli on ennustettu kalibraatio- ja B) evaluointiaineistoon.



Kuva 79. GLM- ja GAM-mallien vertailua.

Taulukossa 23 on esitetty vielä yhteenveto GLM- ja GAM-mallien suorituksista. Mallien antamien ennusteiden väliset korrelaatiokertoimet on koottu taulukkoon 24.

Taulukko 23. Yhteenvedo kaikkien mallien selitetyn hajonnan osuuksista ( $D^2$ ) sekä havaintojen ja ennusteiden välisistä Spearmanin korrelaatiokertoimista.  $D^2$  XY on mallin selitysaste spatiaalisten muuttujien lisäyksen jälkeen.

Malli	$D^2$	$D^2$ XY	$D^2$ muutos (%)	$R_s$ (kal)	$R_s$ (eval)
GLM kryoturbaatio	0,462	0,531	13,0	0,530	0,516
GAM kryoturbaatio	0,448	0,509	12,0	0,550	0,519
GLM rinneprosessit	0,622	0,668	6,9	0,790	0,754
GAM rinneprosessit	0,619	0,669	7,5	0,789	0,743
GLM rapautuminen	0,504	0,567	11,2	0,527	0,390
GAM rapautuminen	0,505	0,578	12,6	0,495	0,348
GLM deflaatio	0,705	0,772	8,6	0,557	0,441
GAM deflaatio	0,685	0,780	12,2	0,535	0,451
GLM nivaatio	0,635	0,683	7,1	0,507	0,311
GAM nivaatio	0,621	0,697	10,9	0,510	0,325
GLM fluviaaliprosessit	0,660	0,774	14,7	0,386	0,319
GAM fluviaaliprosessit	0,592	0,693	14,6	0,267	0,258

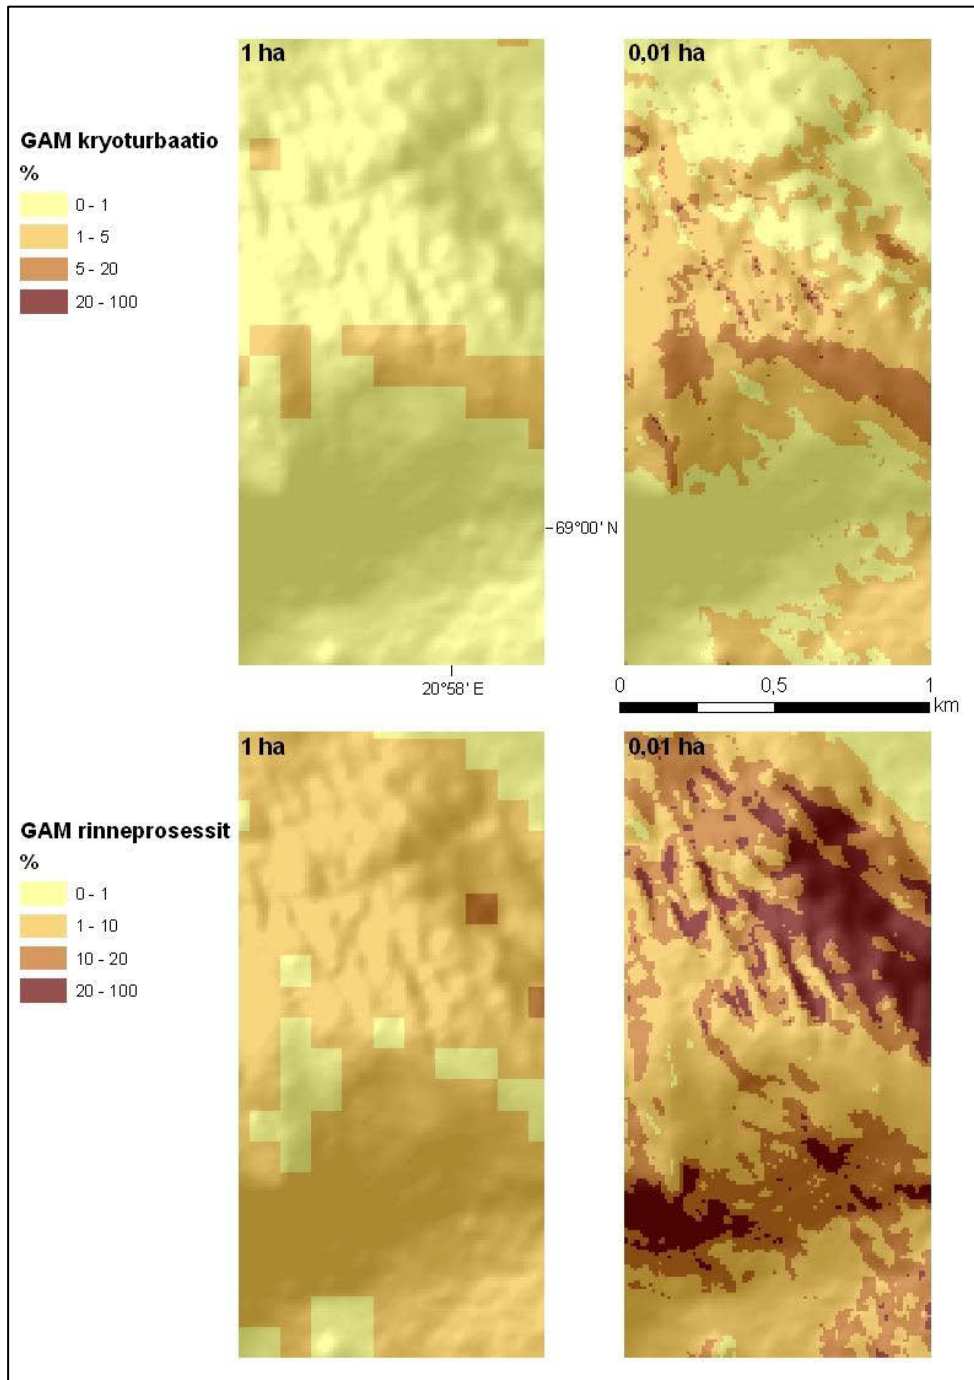
Taulukko 24. GLM- ja GAM-ennusteiden väliset Spearmanin korrelaatiokertoimet.

Periglasiaalinen Ilmiö $R_s$ (GLM vs GAM)	
Kryoturbaatio	0,951
Rinneprosessit	0,979
Rapautuminen	0,758
Deflaatio	0,925
Nivaatio	0,965
Fluviaaliprosessit	0,270

## 5.7 Mallinnusresoluution vaikutus

Molemmassa Ailakkavaaran GAM-malleissa oli mukana kaikki neljä sivulla 48 mainittua selittävää muuttujaa. Alkuperäinen kryoturbaatiomalli (GAM) selitti 44,8% kryoturbaation esiintymisestä sekä ennusti yli 1 % arvoja yhden hehtaarin resoluutiolla Ailakkavaaralla 21/231 ruudulle (noin 9 % alasta). Ailakkavaaran tutkimusalueelle ennustettu GAM-malli selitti 49,5 % vaihtelusta sekä ennusti yli 1 % kryoturbaatioarvoja 0,01 hehtaarin resoluutiolla 10 727 ruudulle (107 ha, noin 54 % koko alasta). Kuten kuvasta 80 nähdään, hienommalla resoluutiolla tulee enemmän vaihtelua esille sekä ennustetut arvot ovat monin paikoin korkeampia. Suurimmat kryoturbaatioarvot keskittyvät molempien ennusteiden mukaan Ailakkavaaran huipun tasaisille alueille. Ailakkavaaralle ennustettu malli selitti 60,9 % rinneprosessien esiintymisestä, kun alkuperäinen malli selitti 61,9 %. Alkuperäinen rinneprosessimalli

(GAM) ennusti yli 1 % arvoja yhden hehtaarin resoluutiolla noin 185 ruudulle (noin 80 % alasta). Ailakkavaaran tutkimusalueelle ennustettu GAM-malli ennusti yli % rinneprosessiarvoja 0,01 hehtaarin resoluutiolla 19 346 ruudulle (193 ha, noin 97 % koko alasta). Kuten kryoturbaation tapauksessa, myös tässä ennuste 0,01 hehtaarin resoluutioon tuo esille enemmän vaihtelua ilmiön esiintymiseen sekä suurempia ennustearvoja. Malli ennustaa 0,01 hehtaarin mallinnusruuduille hyvin suuria rinneprosessiarvoja jyrkimmille rinteille.



Kuva 80. Mallinnusresoluution vaikutus kryoturbaatio- ja rinneprosessiennusteeseen.

## 6. Tulosten tarkastelu

### 6.1 Periglasiialiset ilmiöt

Kryoturbaatiota esiintyy tutkimusalueella melko korkealla, keskimäärin noin 737 m mpy sekä suhteellisen tasaisella maalla ( $\alpha=12,6^\circ$ ). Yli 50 % / ha kryoturbaatioarvot esiintyvät keskimäärin 913 m mpy. Keskihajonta on kuitenkin hyvin suuri sekä korkeuden, että rinteenkalltevuuden suhteen. Molemmat käytetyt mallinnusmenetelmät (GLM ja GAM) selittivät lähes yhtä hyvin ilmiötä sekä antoivat hyvin samankaltaisia ennusteita kryoturbaation esiintymisestä suhteessa keskikorkeuteen ja maaston kaarevuuteen. Molemmat mallit ennustivat ilmiön määrän voimakkaamman kasvun noin 800 m mpy jälkeen alenevan lämpötilan johdosta, joka vaikuttaa taas kasvillisuuden esiintymiseen ja lumen jakaantumiseen. Maasto on myös tasaisempaa tuntureiden huipuilla, jonka johdosta suuremmat kryoturbaatioarvot on ennustettu 900–1000 m mpy. Kirjallisuuden mukaan kryoturbaatiota esiintyy pääosin tasaisilla tai lievästi viettävillä rinteillä, missä hienojakoinen maa-aines pidättää riittävästi kosteutta ilman, että pintavettä pääsee muodostumaan (Schunke & Zoltai 1988: 235; French 2007: 148). Tämän johdosta kryoturbaation vaste kaarevuuteen on pienimmillään sen ollessa aivan nollan tuntumassa.

Perustuen selitetyn hajonnan osuuteen, kryoturbaation alueellista esiintymistä selittää selvästi eniten keskikorkeus. Kaarevuuden kolmannen asteen termillä ja rinteenkalltevuudella on myös pieni osansa mallin vaihtelun selityksessä. Hierarkkisen osituksen perusteella keskikorkeus on edelleen tärkein yksittäinen muuttuja. Seuraavaksi tärkein muuttuja on NDVI. Koska se korreloi hyvin voimakkaasti keskikorkeuden kanssa ( $R_s = -0,882$ ), pudotettiin se pois lopullisista malleista. Tämän voimakkaan riippuvuuden ansiosta sen vaikutus tulee huomioitua GLM- ja GAM-malleissa. Kasvillisuus vaikuttaa muun muassa lumen jakautumiseen, kosteusoloihin ja etenkin paikallisella tasolla se muokkaa maaperän rakennetta vaikuttaen kryoturbaation esiintymiseen (Zeng et al. 2007: 379). Kasvillisuuden ja topografisten muuttujien merkitys kryoturbaation esiintymiselle on myös todettu Hjortin ja Luodon tutkimuksessa (2009: 330). TWI on toinen muuttuja, joka puuttui varsinaisista malleista. Sen merkitys kryoturbaation esiintymiselle on kuitenkin suuri. Kuten jo aiemmin tässä

kappaleessa on todettu, kosteusolot ovat hyvin tärkeä tekijä kryoturbaation esiintymisessä. Kryoturbaatiota esiintyy todennäköisimmin siellä, missä säteily määrä on alhaisempaa. Tähän viittaa myös kryoturbaation ja säteilyn välinen negatiivinen korrelaatio ( $R_s = -0,17$ ), vaikka tasaisilla ja korkeilla alueilla on harvemmin suuria eroja säteily määrässä. Maaperän merkitys on tunnetusti tärkeä kryoturbaation muodostumisessa, vaikka se ei lopullisessa GLM-mallissa ollutkaan mukana selittävänä muuttujana (esim. Hjort & Luoto 2008: 745). Hierarkkisessa osituksessakin se on vasta kuudenneksi tärkein muuttuja. Kallioperä on todennäköisesti toiminut ilmiötä rajaavana tekijänä mallissa, vaikka kryoturbaation ja kallioperän välisen korrelaatiokertoimen mukaan niillä ei ole mitään tilastollista yhteyttä toisiinsa ( $R_s = 0,02$ ). GLM-malli ennusti kryoturbaatiota tutkimusalueelle niin pieniä arvoja, että lopullisessa luokituksessa kartalla kryoturbaatiota esiintyy vain muutamalla ruudulla (liite 4). Tämä on outoa kolmesta syystä: 1) havaintoaineisto sisältää huomattavan paljon melko suuriakin kryoturbaatioarvoja, 2) mallin selitysaste on melko hyvä ja 3) GLM-ennusteen ja havaintoaineiston väliset Spearmanin korrelaatiokertoimet ovat kohtalaisia ( $R_{eval} = 0,516$ ) sekä käytännössä identtiset GAM:n kanssa (taulukko 23). Mallinnukseen liittyviä ongelmia käsitellään tarkemmin kappaleessa 6.2.

Sekä GLM- että GAM-mallit selittivät kryoturbaation esiintymisestä hieman alle puolet. Joustavampi GAM-ennuste onnistui tuomaan esille suurempia kryoturbaatioarvoja tutkimusalueella, vaikka nekin vaikuttavat pieniltä todellisuuteen verrattuna. GAM-ennuste onnistui löytämään kryoturbaatiota esimerkiksi lähes koko Ailakkavaaran tasaiselta lakialueelta, mikä todellisuudessaakin on kryoturbaation lähes kokonaan peittämää aluetta. Ennusteiden välinen hyvin korkea Spearmanin järjestyskorrelaatiokerroin ( $R_s = 0,951$ ) ei kerro mitään ennustearvojen vastaavuuksista. Sen avulla voidaan toki tutkia ennusteiden välistä systemaattisuutta. Molempien mallien selitysasteen kohoaminen yli kymmenen prosenttia spatiaalisten muuttujien lisäämisen jälkeen on selkeä merkki trendin olemassaolosta (Legendre 1993: 1671). Tämä itä-länsi suuntainen trendi on nähtävissä myös siitä, että x-koordinaatin vaikutus hierarkkisessa osituksessa on hieman alle neljä prosenttia. Trendin merkitystä on käsitelty enemmän seuraavassa kappaleessa.

Rinneprosessien esiintyminen tutkimusalueella liittyy erityisesti keskikorkeuteen ja rinteiden kaltevuuteen, jotka korreloivat voimakkaasti tärkeiden rinneprosessien selittävien muuttujien, kuten kasvillisuuden, sulamis-jäätymissykliä määrän, roudan

syvyyden ja kosteusolojen kanssa (Matsuoka 2005b: 57). Suurimmat havaintoarvot esiintyvät korkeuden ja rinteiden kaltevuuden ollessa suurina (taulukko 4). Molemmat mallit selittävät ilmiön esiintymistä hyvin (yli 60 %), GLM-malli hieman GAM-mallia paremmin. Mallit myös ennustivat jälleen hyvin samanlaisia vastekäyriä. Suurimmat rinneprosessiarvot on ennustettu keskikorkeuden ollessa noin 800 m mpy ja säteilyn määrän ollessa pientä. Alhainen säteily sallii roudan tunkeutumisen syvemmälle sekä vaikuttaa alueen kosteusoloihin (Hjort 2006: 117). Toisaalta säteilyn määrän ylittäessä 0,5 MJ/cm<sup>2</sup>/a rinneprosessiaktiivisuus lähtee uudelleen kohoamaan. Suurempi säteily lisää mekaanista rapautumista, maanvieremiä lumen sulamisen johdosta sekä solifluktiota lisääntyneen kosteuden ansiosta (French 2007: 218). Selitetyn hajonnan perusteella tärkeimpiä selittäviä muuttujia ovat keskikorkeus, rinteiden keskikaltevuus ja kaarevuus. Hierarkkinen ositus nostaa esiin malleista puuttuvat NDVI:n ja TWI:n, joilla on suurin itsenäinen vaikutus rinneprosessien esiintymiseen. Vaikka rinneprosesseilla oli voimakas vaste säteilyyn, on sen merkitys sekä selitetyn hajonnan, että hierarkkisen osituksen osalta vähäinen. Ongelmana on se, että tutkimuksessa rinneprosesseilla tarkoitetaan sekä nopeita että hitaita rinneprosesseja. Tällöin vaste säteilyyn voisi olla tärkeämpi nopeille massaliikunnoille, jolloin esimerkiksi alhainen säteily määrä voisi voimistaa mekaanista rapautumista (Hall 1999). Samasta syystä kallioperä on kuudenneksi tärkein muuttuja hierarkkisen osituksen mukaan, sillä kivilajeilla on tunnetusti suuri merkitys rapautumisprosesseihin (Hall et al. 2002: 594–595; French 2007: 63). Jälleen kerran maaperä ei ole mukana valmiissa GLM-mallissa, vaikka suurin liike tapahtuu juuri hienojakoisessa routimiselle alttiissa maaperässä kuten moreenissa (Matsuoka 2001a: 120). Tämän on tuonut esiin hierarkkinen ositus, jonka mukaan maaperällä on melko suuri, noin 12 % vaikutus rinneprosesseihin.

Molemmat mallit antoivat lähes identtiset alueelliset ennusteet ilmiön esiintymisestä. Ennusteet ovat hyvin realistisia, sillä suurimmat arvot on ennustettu esimerkiksi Saanan jyrkimmille rinteille. Pienempiä arvoja on ennustettu Ailakkavaaran ylärinteille, missä todellisuudessa on hyvin paljon solifluktiota havaittavissa, mutta pienempialaisena. Kun verrataan ennustettuja arvoja havaintoihin, huomataan että Spearmanin korrelaatiokertoimet molemmilla malleilla ovat suurina ( $R_{s( eval )} > 0,74$ ) osoittaen ennusteiden onnistumisen. Myös erot korrelaatioissa kalibraatio- ja evaluointiaineiston kesken olivat pieniä (esim. GLM,  $R_{s( kal )} = 0,790$  ja  $R_{s( eval )} = 0,754$ ) ja viittaavat toimivaan malliin (Hjort 2006: 117). Mallien ennusteiden välinen Spearmanin

korrelaatiokerroin on 0,979 ja kuvasta 45 nähdään, että ennustearvojen samankaltaisuus on suuri. Aineistossa on huomattavissa selkeä trendi, mikä on nähtävissä myös mallin residuaaleista. Se ei kuitenkaan ole yhtä voimakas kuin kryoturbaation tapauksessa.

Rapautumisprosessien esiintyminen tutkimusalueella liittyy GLM-mallin selitetyn hajonnan mukaan eniten keskikorkeuteen ja säteilyn määrään. Korkeuden myötä lämpötilaerot kasvavat, joka mahdollistaa etenkin voimakkaamman mekaanisen rapautumisen (French 2007: 65). GLM- ja GAM-mallit selittivät rapautumisprosesseja lähes täysin saman verran (noin 50 %). Molemmat mallit ennustivat suurempia rapautumisarvoja säteilyn ollessa pientä ( $< 0,4\text{MJ}/\text{cm}^2/\text{a}$ ). Tämä selittyy sillä, että vähäinen säteilyn määrä tarkoittaa alhaisempia lämpötiloja, jolloin veden faasimuutos kiven raoissa ja huokosissa on yleisempää (Matsuoka 2001b: 300). Toisaalta säteilyn ollessa suurta, kallio altistuu lämpöstressille jolla on myös kiviainesta rapauttava vaikutus (Hall 1999: 48). Hierarkkisen osituksen perusteella selvästi tärkein muuttuja on hieman yllättäen NDVI. Vaikka kasvillisuudella onkin kiviainesta rapauttava vaikutus (Viles et al. 2008: 1422) tulee NDVI:n suuri rooli todennäköisesti rajaavana tekijänä. Tällöin alueilla, missä on paljon kasvillisuutta, esiintyy vähän rapautumista. Jälleen varsinaisista malleista puuttunut TWI on toiseksi tärkein muuttuja hierarkkisen osituksen perusteella. Tämä ei ole yllätys, sillä kosteus on yksi tärkeä kiven rapautumista säätelevä tekijä (esim. French 2007: 63). Säteilystä on myös melko suuri vaikutus. Tämä nähdään molempien mallien ennusteista, sillä suurimmat rapautumisarvot on ennustettu tunturien pohjois- ja itärinteille, jotka vastaanottavat vähiten suoraa auringonsäteilyä. Maaperän kolmanneksi suurin rooli selittyy sillä, että yksi käytetyistä maalajiluokista oli louhikko- ja kalliomaat. Vaikka kivilajin vaikutus rapautumisprosesseihin on suuri (esim. Hall et al. 2002), voi kallioperän vasta kahdeksas sija hierarkkisessa osituksessa selittyä sillä, että tutkimuksessa käytettyjä kivilajiluokkia on vain kaksi ja ne vaihtelevat tutkimusalueella melko vähän. Rinteen keskikaltevuudella on kuudenneksi suurin itsenäinen vaikutus rapautumisprosessien esiintymiseen. Se vaikuttaa esimerkiksi alueen kosteusoloihin sekä säteilymäärään ja siten mekaaniseen rapautumisalttuteen (Lautridou 1988: 36).

GLM-malli ennustaa yli 1 % /ha rapautumisarvoja hieman laajemmalle alueelle kuin GAM-malli, jolle säteily on selvästi tärkein muuttuja. Tämä näkyy siinä, miten suurimmat arvot ennustetaan alueille, jotka saavat vähiten säteilyä. GLM-malli antaa todenmukaisemman ennusteen antamalla arvoja esimerkiksi Ailakkavaaran



pohjoisrinteellä, mutta ei niin selkeästi rinteen ekspositiosta riippuen. Tämä voi johtua siitä, että GAM-malli ei voi käyttää faktoreita selittävinä muuttujina, jolloin maa- ja kallioperän vaikutus ovat jääneet pois mallista. GLM-ennusteet vastasivat kuitenkin hieman paremmin havaittuja arvoja, vaikkakin Spearmanin korrelaatiokerroin evaluointiaineiston kanssa oli heikko molemmilla malleilla (GLM  $R_s < 0,390$ ). Kun GLM-mallilla ennustettiin kalibraatioaineistoon, kohosi korrelaatiokerroin huomattavasti ( $R_s=0,527$ ). Vastaavat kertoimet GAM-mallissa ovat 0,348 ja 0,495. Tämä huomattava ero kalibraatio- ja evaluointiaineiston välillä saattaa johtua puuttuvista kausaalitekijöistä mallissa sekä olla merkki spatiaalisesta autokorrelaatiosta (Hjort 2006: 117). GLM- ja GAM-mallien väliset ennusteet hajoavat hieman, mistä kertoo Spearmanin korrelaatiokerroin 0,758. GAM-malli ennustaa aluksi suurempia arvoja GLM-mallin ennusteiden ollessa lähellä nollaa, mutta muilla arvoilla GLM-malli antaa systemaattisesti suurempia ennustearvoja kuin GAM-malli, johtuen mahdollisesti kategorisista muuttujista. Trendirakenne on nähtävissä residuaaleista sekä hierarkkisen osituksen tuloksesta, jossa x-koordinaatin itsenäinen vaikutus on hieman yli viiden prosentin luokkaa. Trendin olemassaoloa tukee myös mallien selitysasteiden huomattava, yli kymmenen prosentin kohoaminen spatiaalisten muuttujien lisäyksen myötä.

Deflaation esiintyminen tutkimusalueella liittyy voimakkaasti korkeuteen merenpinnasta. Korkeuden myötä kasvillisuus vähenee, jolloin tuulen toiminta on tehokkaampaa (Seppälä 2004a: 36). Korkeimmat deflaatioarvot ovat keskimäärin noin 880 metrin korkeudella (taulukko 4). Molemmat mallit selittävät hyvin deflaation esiintymistä, GLM:n selitysasteen (70,5 %) ollessa hieman korkeampi kuin GAM-mallin (68,5 %). GLM-mallin selitetyn hajonnan mukaan keskikorkeuden lineaarinen termi selittää selvästi eniten deflaation esiintymisestä. GAM-mallissa deflaatioarvot kasvavat voimakkaasti keskikorkeuden suhteen, vaikka tasoitusfunktion arvo (2,9) viittaa monimutkaisempaan suhteeseen. Rinteen kaltevuus alle  $2^\circ$  saa tasoitusfunktion arvoksi 1, jolloin se on mukana lineaarisena terminä. Tämä viittaa muuttujan merkityksellisyyteen selittäjänä muuttujana ja riippuvuuden selkeydestä. Myös kaarevuus on mukana lähes lineaarisena. Kasvillisuuden ja korkeuden merkitys näkyy myös hierarkkisen osituksen tuloksissa kasvillisuuden ollessa tärkein yksittäinen muuttuja. X-koordinaatti on neljänneksi tärkein muuttuja antaen vihjettä trendin olemassaolosta.

Molemmat mallinnusmenetelmät antavat hyvin samanlaisen alueellisen ennusteen deflaation alueellisesta esiintymisestä. Suurimmat ennustearvot sijoittuvat tunturien tasaisille huipuille, joissa kasvillisuus on hyvin matalaa. Mallien välinen Spearmanin korrelaatiokerroin on 0,925 ja GAM-malli ennustaa systemaattisesti suurempia deflaatioarvoja kuin GLM-malli. Tätä voisi mahdollisesti selittää GLM-mallin negatiiviset kertoimet faktorimuuttujilla. Kun ennusteita verrattiin havaittuihin arvoihin, suoriutuu GAM ( $R_{s(\text{eval})} = 0,451$ ) hieman paremmin kuin GLM ( $R_{s(\text{eval})} = 0,441$ ) erojen ollessa silti minimaalisia. Mallien ennustekyky on melko vaatimaton. Kalibraatioaineistoon ennustettaessa Spearmanin korrelaatiokertoimet kohoavat hieman (esim. GLM,  $R_{s(\text{kal})} = 0,557$ ). Kun spatiaaliset muuttujat lisättiin malleihin nousivat selitysasteet selvästi. Tämä yhdessä residuaalien ja x-koordinaatin merkityksellisyyden kanssa hierarkkisessa osituksessa viittaavat selvästi heteroskedastisuuteen.

Myös nivaation alueellinen esiintyminen linkittyy vahvasti korkeuteen merenpinnasta ja kasvillisuuteen. Korkeus aiheuttaa matalat lämpötilat, jolloin lumenviipymäalueiden säilyminen on mahdollista. GLM-malli selittää hieman enemmän (63,5 %) nivaation esiintymisestä kuin GAM-malli (62,1 %). Korkeuden merkitys näkyy sekä GLM-mallin että hierarkkisen osituksen tuloksista. Koska nivaatio on prosessina riippuvainen lumesta, on kasvillisuudella tärkeä merkitys lumen jakaantumisesta (Christiansen 1996; French 2007: 238–239). Rinteen keskikaltevuus on selitetyn hajonnan perusteella toiseksi tärkein selittäjä, selittäen kuitenkin vain hieman yli 8 % mallista. Nivaatiota esiintyy havaintoaineiston perusteella melko kaltevilla rinteillä keskiarvon ollessa noin 17°. Maaperällä on hierarkkisen osituksen mukaan lähes yhtä suuri itsenäinen vaikutus kuin kasvillisuudellakin. On mahdollista, että nivaatiota esiintyy yleisimmin hienojakoisessa ja konsolidoitumattomassa maaperässä esimerkiksi moreenissa, jolloin sulava lumenviipymä kuljettaa materiaalia alarinteeseen syventäen samalla nivaatiomuodostumaa (Seppälä 2005b: 69).

Ehkä hieman yllättäen kaarevuudella on vähäinen rooli sekä GLM-mallissa että hierarkkisessa osituksessa, vaikka lumenviipymien voisi ajatella syntyvän juuri topografisiin painanteisiin minne tuulet kinostavat lunta. Säteily on tärkeä selittävä muuttuja ja sen merkitys tulee selkeästi esille vastekäyrästä. On selvää, että säteily vaikuttaa lämpötilaan, joten nivaatiota esiintyy enemmän siellä missä säteily on vähäisempää. Näin ollen rinteen ekspositio määrittää osaltaan nivaation esiintymistä (French 2007: 239). Hierarkkisen osituksen mukaan kallioperällä on pieni merkitys,

vaikka Frenchin (2007: 224) mukaan kallioperällä on tärkeä rooli nivaation synnyssä ja kehityksessä. Tämä voi johtua siitä, kuten aiemminkin on todettu, että kallioperä vaihtelee alueella vähän ja mallinnuksessa käytettyjä faktoritasoja oli vain kaksi. X-koordinaatin melko suuri merkitys hierarkkisessa osituksessa voi viitata Kilpisjärven alueella vaikuttavaan voimakkaaseen mereisyys-mantereisuus gradienttiin, jolloin lämpötila ja sademäärä kasvavat länteen päin mentäessä (Mikkola & Sepponen 1986; Eurola et al. 2003). Toisaalta mereisyyden voimistuessa lämpötilat nousevat ja lumenviipymät sulavat helpommin.

Molemmat mallinnusmenetelmät antavat samansuuntaisia alueellisia ennusteita. GAM-malli ennustaa nivaatioarvoja hieman laajemmalle alueelle kuin GLM-malli. Molemmissa ennusteissa näkyy selvästi säteilyn vaikutus, sillä suurimmat nivaatioarvot esiintyvät tunturien koillis- ja itärinteillä. GAM-malli ennustaa lumenviipymiä myös esimerkiksi Ailakkavaaran etelärinteelle, mikä vastaa hyvin kentällä tehtyjä havaintoja. Kun ennusteita verrataan evaluointiaineistoon, huomataan että Spearmanin korrelaatiokertoimet ovat matalia (GLM,  $R_{s(eval)} = 0,311$  ja GAM,  $R_{s(eval)} = 0,325$ ) viitaten mallien huonoon ennustekykyyneen. Ennustettaessa kalibraatioaineistoon, korrelaatiot nousevat molemmilla malleilla yli 0,5:n. Kuten aiemmin on todettu, tämä voi olla merkki puuttuvista selittävistä tekijöistä mallissa (Hjort 2006: 117). Malliennusteiden välinen hajontakuvio näyttää melko tasapainoiselta ja ennusteiden välinen Spearmanin korrelaatio onkin 0,965. Kun malleihin lisättiin spatiaaliset muuttujat, nousivat selitysasteet jälleen GAM-mallin tapauksessa jopa 10 %. Kun vielä tutkitaan GLM-mallin residuaaleja sekä hierarkkisen osituksen tuloksia on selvää, että ilmiön esiintymiseen vaikuttaa maantieteellinen trendi.

Fluviaaliprosessit tutkimusalueella esiintyvät keskimäärin alhaisilla korkeuksilla. Suuret arvot liittyvät kuperaan maastoon, jotka ilmenevät negatiivisina kaarevuusarvoina. Kaarevuuden lineaarinen termi on paras yksittäinen muuttuja perustuen selitetyn hajonnan määrään. Myös hierarkkisessa osituksessa sen rooli on selvästi suurin ja se näkyy vastekäyrän muodossa. Tämä ei liene yllätys, sillä vesi kerääntyy kuperiin maastonmuotoihin, jolloin siitä aiheutuvat prosessit ovat tehokkaimpia näillä alueilla. Tulosten tulkitsemista vaikeuttaa se, että tutkimuksessa fluviaaliprosesseilla tarkoitetaan sekä eroosio- että akkumulaatiomuotoja. Toinen GLM-mallissa suhteellisen merkittävä muuttuja on keskikorkeus ja etenkin sen toisen asteen termi. Fluviaaliprosessien kontekstissa vaikutus on negatiivinen eli arvot ovat

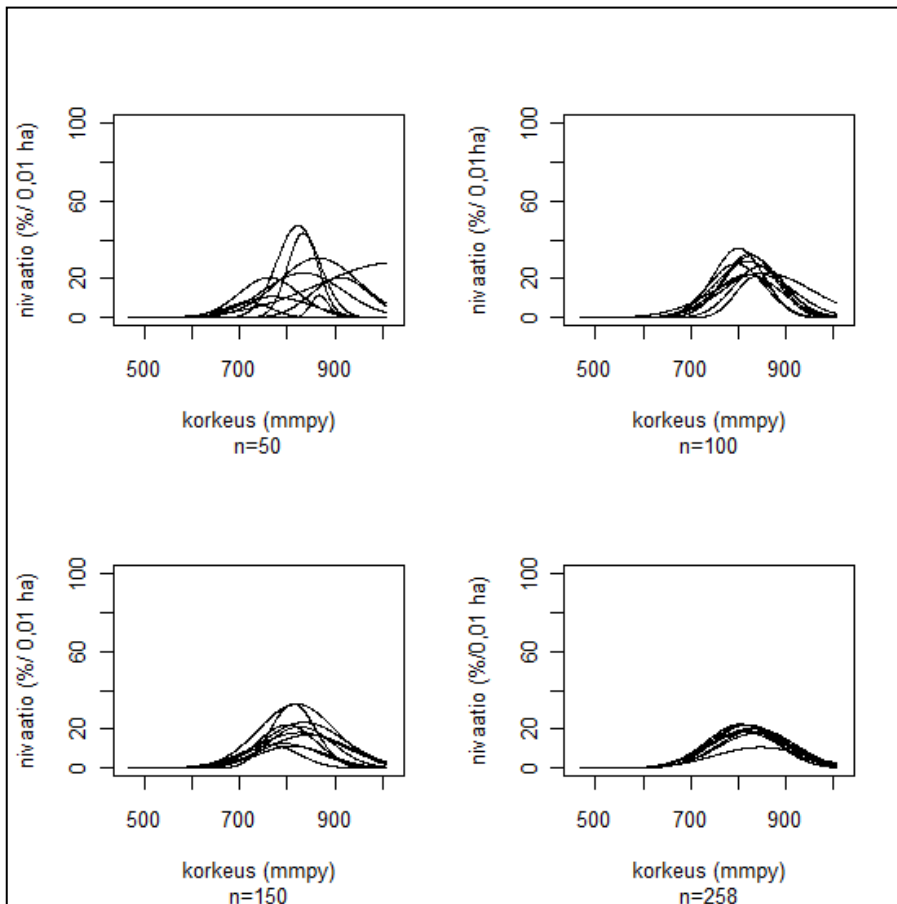
suurempia alhaisilla korkeuksilla. Hierarkkisessa osituksessa kallioperän merkitys on toiseksi tärkein. Tämä liittyy todennäköisesti jo aiempaan maisemankehitykseen, jolloin esimerkiksi viime jääkauden synnyttävät muodot ohjaavat osaltaan fluviaaliprosesseja. Maaperällä ja kasvillisuudella on molemmilla noin kymmenen prosentin itsenäinen vaikutus fluviaaliprosessien esiintymiseen. Maalaji vaikuttaa alueen kosteusoloihin esimerkiksi perkolaation johdosta (Clark 1988: 420). Hienompi aines kulkeutuu myös helpommin pintavalunnan mukana. Ennustetut fluviaaliprosessiarvot esimerkiksi Ailakkavaaran pohjoispuolen alarinteillä saattavat liittyä siihen, että ylempänä rinteillä olevat sulavat lumenviipymät kerrostavat hienoa materiaalia alarinteeseen (McCann et al. 1977: 74–78; Thorn 1979; Orwin et al. 2010: 160–161). Kasvillisuus vaikuttaa ainakin kolmella eri tavalla: sillä on maaperää sitova vaikutus, jolloin fluviaalieroosio on vähäisempää. Sillä on myös merkittävä rooli lumen jakaantumisessa ja pintavalunnassa. Lumen määrällä taas on suuri vaikutus esimerkiksi loppukevään tulvapiikkiin (Clark 1988: 422; French 2007: 254–255). Ennustekartoissa esiintyvät arvot ovat korkeilla ja jyrkillä alueilla fluviaalieroosiota sekä matalilla ja tasaisemmillä alueilla sedimentaatiomuotoja.

Hierarkkisen osituksen perusteella myös rinteiden kaltevuus alle 2°-muuttujalla on suhteellisen tärkeä rooli. Tämä liittyy todennäköisesti juuri akkumulaatiomuotojen esiintymiseen. GLM-malli epäonnistui täysin alueellisessa ennusteessa antaen arvoja vain hyvin pienille alueille. Tämä on yllätys, sillä GLM-malli selitti 66 % fluviaaliprosessien esiintymisestä. GAM-malli, jonka ennustekartta on selvästi realistisempi, selitti vähemmän, noin 59 % ilmiön esiintymisestä. Kun molempien mallien ennusteita verrataan havaittuihin arvoihin huomataan, että korrelaatiokertoimet ovat hyvin vaatimattomia (GLM,  $R_{s(eval)} = 0,319$  ja GAM,  $R_{s(eval)} = 0,258$ ) viitaten huonoon ennustuskykyyn. Tämänkin perusteella GLM-malli vaikuttaisi onnistuneemmalta. Ennustettaessa kalibraatioaineistoon korrelaatiot kohoavat korkeintaan vain muutamia kymmenyksiä. Mallien välisessä hajontakuvassa näkyy selvästi miten GLM-malli ennusti lähes ainoastaan hyvin pieniä arvoja. Myös ennusteiden välinen korrelaatio ( $R_s = 0,270$ ) kertoo osaltaan mallien onnistumisen eroista. Sen sijaan mielenkiintoista on se, että molempien mallien selitysasteet kohoavat lähes 15 % spatiaalisten muuttujien lisäyksen jälkeen. Tämä viittaa voimakkaaseen trendiin, jonka myös hierarkkinen ositus poimii esiin tosin hieman aikaisempaa lievempänä. Trendi liittyy mahdollisesti aikaisemminkin mainittuun mereisyys-

mantereisuus gradienttiin, jolloin länsi-luoteeseen mentäessä sademäärät ja täten myös lumen määrä lisääntyy. Tällä on luonnollisesti suora vaikutus fluviaaliprosessien aktiivisuuteen.

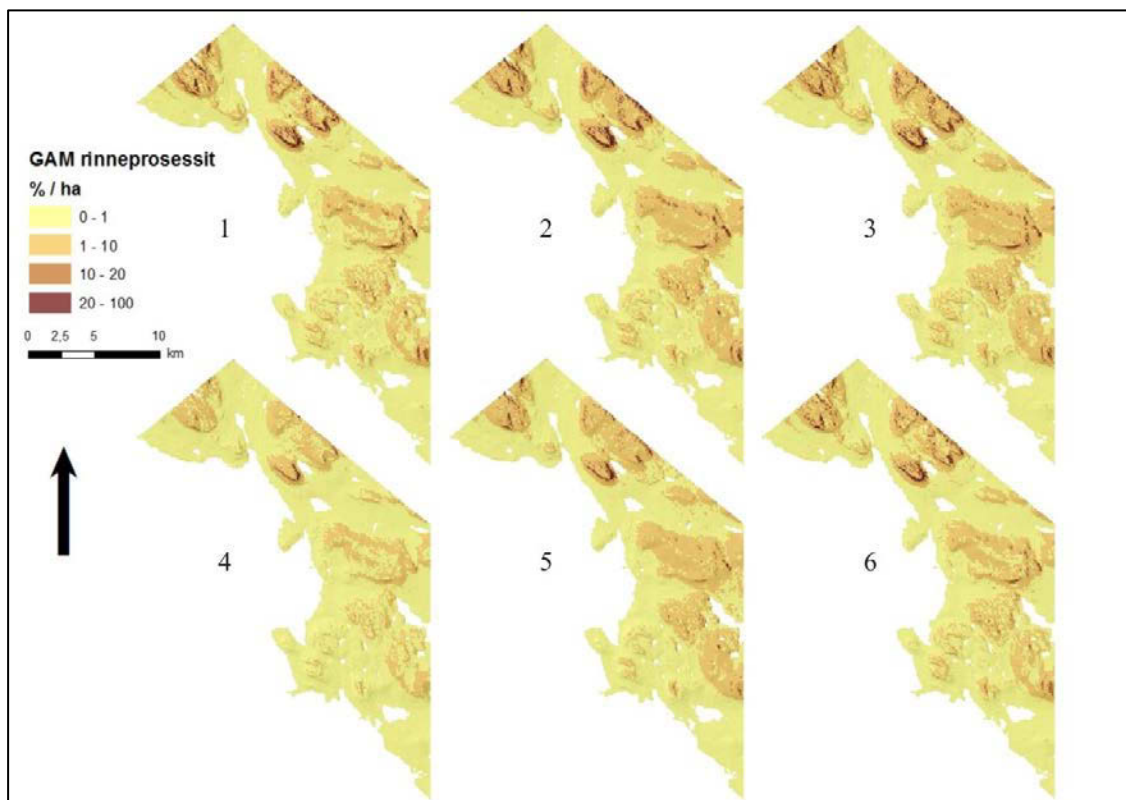
## 6.2 Tulosten luotettavuus ja metodologiset kysymykset

Tutkimuksen aineisto koostui 369 havainnosta, jotka jaettiin sattumanvaraisesti kalibraatio- (70 %) ja evaluointiaineistoksi (30 %). Näin ollen GLM- ja GAM-mallien kalibraatiossa käytettiin hyväksi 258 havaintoa. Hjort & Marmion (2008) ovat tutkineet havaintoaineiston koon vaikutusta geomorfologisiin malleihin. Heidän mukaansa vakaan mallin saa rakennettua noin 200 havainnolla. Kuvassa 81 on esitetty havaintoaineiston koon (n) vaikutusta nivaatiomalliin (GLM), jossa selittävänä muuttujana on keskikorkeus ja sen korkeamman asteen termit. Havaintoaineistosta on otettu sattumanvaraisesti 10 otosta erikokoisilla havaintomäärillä. Siitä huomataan, että havaintoaineiston ollessa 150 malli alkaa jo vakautua, mutta vasta 258 havainnolla saavutetaan suhteellisen vakaa malli.




Kuva 81. Havaintoaineiston koon vaikutus nivaatiomalliin.

Kuten huomataan, 258 havainnollakaan malli ei ole täysin vakaa, vaan se sisältää aina jonkin verran vaihtelua, joka aiheutuu tutkittavan ilmiön stokastisesta luonteesta ja muista epävarmuustekijöistä. Näitä tuovat malleihin esimerkiksi mittausvirheet, havaintoaineiston liian pieni koko, multikollinearisuus, spatiaalinen autokorrelaatio sekä puuttuvat selittävät muuttujat (Heikkinen et al. 2006: 761). Selittävien muuttujien välisillä korrelaatioilla voi olla vakavat seuraukset tilastollisessa mallinnuksessa (Graham 2003: 2814). Tällöin jokin todellisuudessa tärkeä muuttuja saattaa tipahtaa pois mallista, koska jokin toinen muuttuja, jolla ei ole todellista kausaalisuhdetta tutkittavaan ilmiöön, korreloi sen kanssa (MacNally 2002: 1398). Malleihin ja ennusteisiin liittyvät stokastisuus ja epävarmuus tulevat hyvin esille kuvasta 82, jossa on esitetty kuusi GAM-rinneprosessimallia. Jokaisessa mallissa kalibraatioaineisto (n=258) on otettu uudestaan sattumanvaraisesti koko havaintoaineistosta (n=369). Kuvasta nähdään, miten rinneprosessien esiintyminen vaihtelee suurestikin esimerkiksi ennusteiden kolme ja neljä välillä. Kuvassa 83 on esitetty kuuden alla olevan ennusteen Spearmanin korrelaatiokertoimet evaluointiaineistoa vastaan.



Kuva 82. Kuusi GAM-rinneprosessiennustetta perustuen jokainen omaan satunnaiseen otokseensa (n=258) havaintoaineistosta.



Kuva 83. Kuuden GAM-ennusteen (edellinen sivu) Spearmanin korrelaatiokertoimet evaluointiaineistolle.

Kaikki kuusi mallia ennustavat rinneprosesseja hyvin Spearmanin korrelaatioiden vaihdellen vain hieman havaittuja arvoja vastaan. Suurin ero evaluointiaineiston perusteella on ennusteilla kaksi ja kuusi.

Eräs epävarmuutta ja mahdollisesti virheitä malleihin tuova seikka on se, että havaintoaineistoa on ollut kentällä keräämässä kolme eri henkilöä. Visuaaliseen havainnointiin perustuva aineiston keruu on aina subjektiivista, jolloin tulokset saattavat erota eri tutkijoiden kesken.

Ehkä tärkein selittävien ympäristömuuttujien lähde on digitaalinen korkeusmalli, josta pystytään laskemaan monia topografisia muuttujia (Guisan & Zimmermann 2000: 156–157). DEM sisältää aina systemaattisia ja ei-systemaattisia interpoloinnista johtuvia virheitä, jotka kertautuvat johdannaisten (esimerkiksi rinteiden kaltevuuden) laskemisessa (Oksanen & Sarjakoski 2005). Mallinnuksessa esiintyvää epävarmuutta voidaan vähentää käyttämällä niin sanottuja konsensus metodeja, jolloin liitetään yhteen useamman mallinnusmenetelmän tuottama ennuste (Marmion et al. 2009). Tätä menetelmää on käyttänyt esimerkiksi Thuiller (2004) tutkiessaan globaalimuutoksen aiheuttamaa kasvien levinneisyyden muutosta ja siihen liittyvää epävarmuutta. Muita selittäviä tekijöistä aiheutuvia virhelähteitä ovat esimerkiksi väärä mittakaava tutkittavaan ilmiöön nähden, sijaintitarkkuus, mittaustarkkuus sekä selittävien muuttujien mahdollisesta interpoloinnista aiheutuvat virheet (Walsh et al. 1998: 193; Guisan & Zimmermann 2000: 151). Edellä mainitut seikat huomioon ottaen

tutkimuksen tuloksia voidaan pitää kohtalaisen luotettavina siitäkkin huolimatta, että mallien selitysaste ja kyky ennustaa periglasiaalisia ilmiöitä vaihteli melko paljon. Tutkimuksessa on seurattu tarkasti uudessa kirjallisuudessa käytettyjä menetelmiä ilmiöiden tutkimiseen.

Tutkimuksessa käytettävät mallinnusmenetelmät selittivät ja ennustivat periglasiaalisia ilmiöitä käytännössä yhtä hyvin, mikä voidaan todeta muun muassa ennustetuista vastekäyristä sekä taulukosta 23. Lähes kaikissa malleissa GLM-mallin selitetyn hajonnan osuus oli GAM-mallia suurempi. Mallien samankaltainen kyky ennustaa geomorfologisia prosesseja on havaittu myös muissa tutkimuksissa (Luoto & Hjort 2005; Marmion et al. 2008). Vain GLM-ennusteet kryoturbaation ja fluviaaliprosessien tapauksissa jäivät selvästi GAM-ennusteita huonommaksi. Tällöinkin GLM-malli selitti enemmän mallin hajonnasta kuin GAM-malli. Fluviaaliprosessien tapauksessa havaitut arvot ja GLM-ennusteet vastasivat toisiaan paremmin kuin vastaavat GAM-mallilla. Jostain syystä ennustearvot olivat niin pieniä, että käytetyn luokittelun kanssa ilmiötä ei esiinny kuin muutamassa paikassa. Eräs mahdollisuus on, että mallin kalibraatiossa olisi valittu väärä virhejakaumaoletus. Malleissa on selvää ylihajontaa (engl. over dispersion), mikä tarkoittaa, että residuaalien hajonta on suurempi kuin vapausasteiden määrä. Tällöin sopivampi virheoletus voisi olla esimerkiksi ”quasi-poisson” (Crawley 2007: 522-523). Joidenkin muiden ilmiöiden tapauksessa (esimerkiksi rapautuminen) ennustearvot ovat joko pieniä tai niitä on ennustettu pienille alueille. Tällöin herää kysymys, olisiko vastemuuttajat kannattanut mallintaa binomiaalisesti logistisen regression avulla Poisson regression sijaan? Tuloksena olisi ollut alueellinen esitys vastemuuttujan esiintymisen todennäköisyydestä välillä 0-1. GAM-malleja on kritisoitu siitä, että ne tuottavat liian monimutkaisia malleja, vaikka sama hajonta olisi selitettävissä teorialtaan yksinkertaisemmalla GLM-mallilla (Yee & Mitchell 1991). Parkin ja Vlekin (2002: 138) mukaan GLM peittoaa hienostuneempia tilastollisia menetelmiä juuri pelkästään yksinkertaisemman rakenteensa vuoksi.

Mallinnusresoluution vaikutusta tutkittiin vertailemalla koko tutkimusalueelle yhden hehtaarin resoluutiolla ennustettua GAM-mallia ja ainoastaan Ailakkavaaralle 0,01 hehtaarin resoluutiolla ennustettua mallia keskenään. Mallinnettavat ilmiöt olivat kryoturbaatio ja rinneprosessit. Pienemmän mallinnusresoluution vaikutus näkyy selvästi molempien ilmiöiden kohdalla: se tuo ennusteeseen enemmän realistisia



yksityiskohtia ja vaihtelua joka voidaan paikantaa paremmin. Esimerkiksi rinneprosessiennusteessa nähdään, miten suurimmat arvot keskittyvät juuri jyrkimmille alueille (kuva 80). Näin pienellä tutkimusalueella yhden hehtaarin mallinnusresoluutio on liian karkea hävittäen huomattavan määrän informaatiota ilmiön esiintymisestä (Luoto & Hjort 2006: 291). Pienempi mallinnusresoluutio sopii paremmin, mutta saattaa kiihdyttää spatiaalista autokorrelaatiota, mikä näkyy kartoissa polkumaisina rakenteina vasteen esiintymisessä. Toki nämä rakenteet johtuvat myös Ailakkavaaralla vallitsevista maaperä ja topografisista olosuhteista (Legendre et al. 2002; Luoto & Hjort 2006: 287).

Spatiaalinen autokorrelaatio on hyvin yleinen tilastollinen ominaisuus maantieteellisissä muuttujissa. Se tarkoittaa, että ilmiöön tai ympäristömuuttujan arvoon jossakin paikassa vaikuttaa sen lähellä olevat arvot (Legendre 1993: 1615). Voidaan siis sanoa, että toisiaan lähellä olevat arvot ovat samankaltaisempia kuin kauempana olevat arvot. Spatiaalinen autokorrelaatio vaikeuttaa tutkittavan ilmiön ja selittävän muuttujan välisen suhteen selittämistä, sillä tilastolliset testit eivät kykene käsittelemään voimakasta alueellista rakennetta aineistossa (Legendre & Fortin 1989: 109; Legendre et al. 2002: 602). Tämä on ongelma, sillä regressiotekniikat olettavat havaintojen olevan itsenäisesti jakautuneita (McGullagh & Nelder 1989: 21; Guisan & Zimmermann 2000: 177). Positiivinen autokorrelaatio vaikuttaa korrelaatiokertoimien luottamusväleihin, jolloin jokin muuttuja todetaan testissä tilastollisesti merkitseväksi, vaikka se ei sitä todellisuudessa olisikaan (Legendre 1993: 1660). Spatiaalinen autokorrelaatio voidaan kvantifioida käyttämällä esimerkiksi Moranin indeksiä tai semivariogrammimallinnusta (Moran 1950; Goovaerts 1999). Se voidaan myös ottaa huomioon tutkimuksessa lisäämällä se yhdeksi muuttujaksi malliin (Hjort 2006; Luoto & Hjort 2006; Marmion et al. 2009). Autokovariantti voi kuitenkin tiputtaa pois joitakin tärkeitä selittäviä muuttujia, sillä myös ne ovat usein spatiaalisesti autokorreloituneita (Hjort 2006: 120).

Toinen tärkeä oletus tilastollisilla testeillä on stationaarisuus, eli aineiston tilastolliset ominaisuudet (keskiarvo ja varianssi) säilyvät samanlaisina koko tutkimusalueella (Legendre & Fortin 1989: 121). Spatiaalinen riippuvuus eli trendi tarkoittaa, että vastemuuttujan arvot ovat alueellisesti rakentuneet jonkin toisen (esimerkiksi fyysikaalisen) muuttujan johdosta. Suuren mittakaavan trendirakenteet tulisikin poistaa (esimerkiksi trendipinta-analyysillä) ennen kuin voidaan tutkia pienemmän tason alueellisia rakenteita (Legendre et al. 2002: 602–603). On tärkeää

kokeilla, voiko spatiaalisen muuttujan lisäämisellä parantaa mallin selitystasetta. Jos selitystasetta kohottaa, on aineistossa alueellista rakennetta (Legendre 1993: 1671). Tässä tutkimuksessa maantieteellinen trendi näkyi jokaisen tutkittavan ilmiön kohdalla mallin selitystasteen kohotessa spatiaalisten muuttujien lisäämisen jälkeen. Hierarkkisen osituksen jälkeen paljastui, että merkittävä spatiaalinen muuttuja on x-koordinaatti viitaten itä-länsi suuntaiseen trendiin. Mikkola ja Sepponen (1986) ovatkin todenneet, että Kilpisjärven alueella vallitsee voimakas mantereisuus-mereisyys gradientti, mikä näkyy x-koordinaatin itsenäisessä vaikutuksessa. Y-koordinaatin vaikutus oli kaikissa malleissa hyvin vähäinen, mikä johtuu todennäköisesti tutkimusalueen pienestä koosta.

Tutkimuksen yhtenä tavoitteena oli selvittää, miten pistemäisestä havaintoaineistosta saadaan alueellisesti kattavaa informaatiota. Jotta prosessi-ympäristösuhdetta pystytään kuvaamaan mahdollisimman tarkasti, on varmistuttava, että havaintoaineisto on kerätty koko ympäristögradientilta, jossa ilmiötä esiintyy (Heikkinen et al. 2006: 767–768). Näin ollen havaintojen ei tarvitse olla alueellisesti tasaisesti jakautuneita, kunhan kaikki mahdolliset olosuhteet tulee otettua huomioon. Kuten aikaisemmin todettu, noin 200 havaintoa riittää vankan tilastollisen mallin rakentamiseen. Mallien antamat ennusteet tutkittavien ilmiöiden esiintymisestä ovat pääosin realistisia ja vastaavat ilmiöiden todellista levinneisyyskuvaa melko hyvin. Alueellisesti kattavaa tietoa voidaan tuottaa myös eri interpolointimenetelmillä. Kriging on paljon käytetty geostatistinen ja lineaarinen interpolointi-menetelmä, joka ottaa huomioon spatiaalisen autokorrelaation ennustaessaan arvoja puuttuville alueille. Se, kuten muutkin interpolointimenetelmät, ovat kuitenkin liian riippuvaisia havaintoaineiston tasaisesta alueellisesta jakautumisesta (Goovaerts 2000: 114, 117). Ennusteet eivät ole yhtä realistisia kuin GLM- ja GAM-mallien, jotka hyödyntävät selittäviä ympäristömuuttujia (Miller & Franklin 2002: 244). Periglasiaalisten prosessien ja ympäristötekijöiden välinen suhde on usein niin monimutkainen, ettei niitä pysty menestyksellä mallintamaan lineaariseen suhteeseen perustuvalla menetelmällä.

Mallien selittämä hajonnan osuus vaihteli noin 45–70 %, mikä tarkoittaa että suuri osa mallin hajonnasta jäi selittämättä. Tämä voi johtua esimerkiksi riittämättömistä selittävästä muuttujista tai puuttuvista kausaalitekijöistä (Hjort 2006: 123). Kun GLM-malleihin lisättiin toisen ja kolmannen asteen termit, nousi selittävien muuttujien määrä malleissa melko korkeaksi. Tämä tekee mallista usein hyvin paikallisen. Muun muassa selittävien muuttujien suuren määrän johdosta mahdollisia yhteisvaikutuksia eli

interaktioita ei tutkittu. Käyräviivaisen suhteen tutkiminen oli perusteltua, sillä monissa GLM-malleissa korkeamman asteen termeillä oli suuri merkitys mallin hajontaa selitettäessä (esimerkiksi nivaatiomalli). Tämä tekee kuitenkin mallien tulosten tulkitsemisen usein vaikeaksi (Guisan & Zimmermann 2000: 166). Muutamassa tapauksessa kolmannen asteen termi oli tärkein tietyn selittävän muuttujan yksittäinen termi. Tämä yhdessä GAM-mallien tuloksien kanssa kertovat siitä, että periglasiialisten ilmiöiden prosessi-ympäristösuhde on usein hyvin monimutkainen (Hjort & Luoto 2010).

Myös muita kehittyneitä tilastollisia mallinnustekniikoita on ryhdytty soveltamaan geomorfologisessa tutkimuksessa (Luoto & Hjort 2005; Marmion et al. 2008). MARS (Multiple Adaptive Regression Splines) on joustava ei-parametrinen regressiomethodi, joka yhdistää klassisen lineaarisen regression ja matemaattiset splinit luodakseen paikallisen mallin, jossa vasteen ja selittävän muuttujan välinen suhde voi olla lineaarinen tai ei-lineaarinen (Friedman 1991; Leathwick 2006; Marmion et al. 2008: 2245). MARS valitsee automaattisesti tasoituksen määrän jokaiselle selittävälle muuttujalle sekä niiden välisen interaktion tason (Moisen & Frescino 2002: 215). ANN (Artificial Neural Networks) on ei-lineaarinen itse-järjestäytyvä mallinnusrakenne, joka jäljittelee ihmisaivojen biologista hermojärjestelmää. Se koostuu toisiinsa liittyneistä prosessiyksiköistä (neuroneista), jotka ovat sijoittuneet eri tasoihin. Neuronien väliset yhteydet kuvataan painokertoimina ja niillä on omat sääntönsä laskutoimitusten suorittamiseen (Ermini et al. 2005: 332; Luoto & Hjort 2005: 302). ANN:n käyttö mallinnustekniikkana geomorfologiassa on lisääntynyt (Ermini et al. 2005; Hjort & Marmion 2008). CTA (Classification Tree Analysis) tarjoaa vaihtoehdon regressiotekniikoille ja sillä ei ole mitään *a priori* oletuksia vasteen ja selittävän muuttujan välisestä suhteesta. Sillä on puumainen rakenne, jonka jokaisessa haarassa tapahtuu binaaripäätös (oikein/väärin) koskien aina yhtä ympäristömuuttujaa kerrallaan. Geomorfologisessa tutkimuksessa CTA-mallinnusmenetelmää on käytetty vähän (Luoto & Hjort 2005: 302; Marmion et al. 2008: 2245).

## 7. Yhteenveto

Tutkimusalueella Kilpisjärvellä esiintyy monia erilaisia periglasiaalisia prosesseja; runsaslukuisimpia ovat erilaiset rinneprosessi- sekä kryoturbaatiomuodot. Niiden alueellinen esiintyminen vaihtelee alueella, vaikka osa ilmiöistä keskittyykin samoille alueille pääosin metsärajan yläpuolelle.

Vastatakseni tutkimuksen johdannossa esitettiin tutkimuskysymyksiin: 1) maisematasolla esiintyviä periglasiaalisia ilmiötä Poisson-virheoletukseen perustuvat mallit kykenivät pääosin selittämään hyvin ja ennustamaan kohtalaisesti. Ennusteet vastasivat *a priori* olettamuksia prosessien esiintymisestä sekä kentällä tehtyjä havaintoja melko hyvin. 2) Tilastollisen mallinnuksen ja hierarkkisen osituksen perusteella voidaan todeta, että tutkimusalueen periglasiaalisiin ilmiöiden esiintymisiin vaikuttivat juuri alan peruskirjallisuudessa ja aikaisemmissa tutkimuksissa mainitut tekijät. Tärkein yksittäinen muuttuja, joka vaikutti lähes kaikkien ilmiöiden esiintymiseen, oli keskikorkeus. Se korreloi voimakkaasti muiden muuttujien, esimerkiksi kasvillisuuden kanssa, joka on toinen hyvin tärkeä periglasiaalisia prosesseja selittävä tekijä. Yhteenveto ilmiöiden esiintymiseen vaikuttavista tekijöistä on esitetty kuvassa 84. 3) Mallinnusmenetelmien väliset erot olivat todella pienet ja tutkimuksen perusteella voidaan todeta molempien menetelmien soveltuvan hyvin geomorfologisten prosessien alueelliseen mallintamiseen. GLM-mallit selittivät ilmiöitä monessa tapauksessa hieman paremmin, mutta GAM-mallit tuottivat usein realistisempia ennustekarttoja.

4) Mallinnusresoluution vaikutus ennusteeseen oli selvä. Liian karkea resoluutio hävittää tärkeää informaatiota ilmiön esiintymisestä hienomman erotuskyvyn tuodessa paremmin esille alueellista vaihtelua sekä usein myös suurempia ennustearvoja. Toisaalta liian hieno mallinnusresoluutio altistaa alueellisten aineistojen tyypillisille ominaisuuksille, jotka saattavat vaikuttaa tilastollisiin analyyseihin hyvin haitallisesti. 5) Pistemäinen aineisto voidaan muuttaa melko luotettavasti alueellisesti kattavaksi tilastollisen mallinnuksen avulla. Havaintoaineiston kattavuus ympäristögradientilla sekä sen riittävä koko ovat tällöin avainasemassa. Periglasiaalisten ilmiöiden esiintymiseen vaikuttavat usein monet eri tekijät, joten tilastollisten monimuuttujamenetelmien käyttö on erittäin perusteltua muuttujien välisten monimutkaisten riippuvuussuhteiden selvittämiseksi.

Alueellista rakennetta ilmiöiden esiintymiseen toi spatiaalisen autokorrelaation lisäksi tutkimusalueen sijainti ilmastollisessa vaihteittumisvyöhykkeessä. Toisen ja kolmannen asteen termien lisääminen GLM-malleihin sekä GAM:n käyttö mahdollisti monimutkaisten prosessi-ympäristösuhteiden tutkimisen. Tutkimuksesta voidaan myös havaita digitaalisen korkeusmallin merkitys tämän päivän geomorfologiselle tutkimukselle selittävien ympäristömuuttujien lähteenä.

Paikkatietojärjestelmät, kaukokartoitusmenetelmät sekä tilastollinen mallinnus tarjoavat monia mahdollisuuksia tutkia periglasiaalisia ilmiöitä kustannustehokkaasti ja luotettavasti laajoillakin alueilla. Tämä on erityisen ajankohtaista nyt, sillä ennustettu ilmaston lämpeneminen on suurinta juuri subarktisilla alueilla. Tulevaisuudessa yksi tärkeä tutkimuskohde tulee olemaan periglasiaalisten ympäristöjen ja ilmiöiden vaste ilmastonmuutokseen ja sen aiheuttamiin muutoksiin geomorfologisten prosessien sekä eliöiden levinneisyyskuvissa.

	Keskikorkeus	Rinteen kaltevuus	Säteily	Kaatevuus	Rinne alle 2°	Maaperä	Kallioperä	NDVI	TWI	X-koordinaatti	Y-koordinaatti
Kryoturbaatio	●	●	●			○	○	●	○	○	
Rinneprosessit	●	●	○	○	○	○	○	●	●	○	
Rapautuminen	●	●	●			●	○	●	●	○	
Deflaatio	●	○		○	○	○		●		○	
Nivaatio	●	○	●	○	○	●	○	●	○	○	
Fluviaaliprosessit	○	○		●	○	○	○	○	○	○	

Kuva 84. Selittävien ympäristömuuttujien merkitys periglasiaalisen ilmiön esiintymiseen subarktisessa ympäristössä maisematasolla. Muuttujien suhteellinen tärkeys on määritelty GLM-mallien selitetyn hajonnan sekä hierarkkisen osituksen tulosten perusteella. Suuri musta ympyrä = erittäin tärkeä muuttuja, harmaa suuri ympyrä = tärkeä/melko tärkeä muuttuja, pieni valkoinen ympyrä = jonkin verran tärkeä muuttuja.

## 8. Kirjallisuus

- ACGR (Associate Committee on Geotechnical Research) (1988). Glossary of permafrost and related ground ice terms. Permafrost Subcommittee, National Research Council of Canada, Ottawa, *technical memorandum* 142, 156 s.
- Akaike, H. (1974). A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control* 19, 716-723.
- André, M. (2003). Do periglacial landscapes evolve under periglacial conditions? *Geomorphology* 52, 149-164.
- Anisimov, O., D. Vaughan, T. Callaghan, C. Furgal, H. Marchant, T. Prowse, H. Vilhjálmsson & J. Walsh (2007). Polar regions (Arctic and Antarctic). *Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*, M. Parry, O. Canziani, J. Palutikof, P. van der Linden & C. Hanson, Eds., Cambridge University Press, Cambridge, 653-685.
- Araújo, M. & M. Luoto (2007). The importance of biotic interactions for modeling species distribution under climate change. *Global Ecology and Biogeography* 16, 743-753.
- Atkinson, P., H. Jiskoot, R. Massari & T. Murray (1998). Generalized linear modelling in geomorphology. *Earth Surface Processes and Landforms* 23, 1185-1195.
- Austin, M. (2002). Spatial prediction of species distribution: an interface between ecological theory and statistical modelling. *Ecological Modelling* 157, 101-118.
- Austin, M. (2007). Species distribution models and ecological theory: a critical assessment and some possible new approaches. *Ecological Modelling* 200, 1-19.
- Ballantyne, C. & J. Matthews (1982). The Development of Sorted Circles on Recently Deglaciated Terrain, Jotunheimen, Norway. *Arctic and Alpine Research* 14, 341-354.
- Ballantyne, C. & D. Benn (1994). Paraglacial Slope Adjustment and Resedimentation Following Recent Glacier Retreat. *Arctic and Alpine Research* 26, 255-269.

- Bateman, M. & J. Murton (2006). The chronostratigraphy of Late Pleistocene glacial and periglacial aeolian activity in the Tuktoyaktuk Coastlands, NWT, Canada. *Quaternary Science Reviews* 25, 2552-2568.
- Beven, K. & M. Kirkby (1979). A physically based, variable contributing area model of basin hydrology. *Hydrological Sciences Bulletin* 24, 43-69.
- Bockheim, J. & C. Tarnocai (1998). Recognition of cryoturbation for classifying permafrost-affected soils. *Geoderma* 81, 281-293.
- Brenning, A., M. Grasser & D. Friend (2007). Statistical estimation and generalized additive modeling of rock glacier distribution in the San Juan Mountains, Colorado, United States. *Journal of Geophysical Research* 112, doi:10.1029/2006JF000528.
- Brenning, A. & G. Azócar (2010). Statistical Analysis of Topographic and Climatic Controls and Multispectral Signatures of Rock Glaciers in the Dry Andes, Chile 27°-33°S). *Permafrost and Periglacial Processes* 21, 54-66.
- Carrara, A. & R. Pike (2008). GIS technology and models for assessing landslide hazard and risk. *Geomorphology* 94, 257-260.
- Chevan, A. & M. Sutherland (1991). Hierarchical Partitioning. *The American Statistician* 45, 90-96.
- Christiansen, H. (1996). Effects of Nivation on Periglacial Landscape Evolution in Western Jutland, Denmark. *Permafrost and Periglacial Processes* 7, 111-138.
- Clark, M. (1988). Periglacial Hydrology. Teoksessa Clark, M. (toim). *Advances in Periglacial Geomorphology*, 415-462. John Wiley & Sons, Chichester.
- Collett, D. (2003). Modelling Binary Data. 2 pain. *Texts in Statistical Science*. Chapman & Hall, New York. 387 s.
- Corenblit, D. & J. Steiger (2009). Vegetation as a major conductor of geomorphic changes on the Earth surface: toward evolutionary geomorphology. *Earth Surface Processes and Landforms* 34, 891-896.
- Crawley, M. (2007). *The R book*. 942 s. John Wiley & Sons, Chichester.
- Daanen, R., D. Misra, H. Epstein, D. Walker & V. Romanovsky (2008). Simulating nonsorted circle development in arctic tundra ecosystems. *Journal of Geophysical Research* 113, doi:10.1029/2008JG000682.
- Dai, F. & C. Lee (2002). Landslide characteristics and slope instability modeling using

- GIS, Lantau Island, Hong Kong. *Geomorphology* 42, 213–228.
- Davis, N. (2001). *Permafrost. A Guide to Frozen ground in Transition*. University of Alaska Press, Fairbanks. 351 s.
- Drebs, A., A. Nordlund, P. Karlsson, J. Helminen & P. Rissanen (2002). Tilastoja Suomen ilmastosta 1971-2000. *Ilmastotilastoja Suomesta* 2002, 1. Ilmatieteen laitos.
- Ermini, L., F. Catani & N. Casagli (2005). Artificial Neural Networks applied to landslide susceptibility assessment. *Geomorphology* 66, 327–343.
- Eronen, M. (2004). Kilpisjärven seudun synty. Teoksessa Järvinen, A. & S. Lahti (toim). *Suurtuntureiden luonto*, 49–64. Palmenia kustannus, Helsinki.
- Etzelmüller, B., R. Ødegård, I. Berthling & J. Sollid (2001). Terrain Parameters and Remote Sensing Data in the Analysis of Permafrost Distribution and Periglacial Processes: Principles and Examples from Southern Norway. *Permafrost and Periglacial Processes* 12, 79-92.
- Etzemüller, B., E. Heggem, N. Sharhuu, R. Fraunfelder, A. Kääb. & C. Goulden (2006). Mountain permafrost distribution modelling using a multi-criteria approach in the Hövsgöl area, northern Mongolia. *Permafrost and periglacial processes* 17, 91-104.
- Eurola, S., S. Huttunen & P. Welling (2003). Enontekiön suuruntureiden (68°45'–69°17' N; 20°45'–22°E) paljakkakasvillisuus. *Kilpisjärvi notes* 17, 4-27. Kilpisjärven biologinen asema.
- French, H. (1988). Active layer processes. Teoksessa Clark, M. (toim). *Advances in Periglacial Geomorphology*, 151-177. John Wiley & Sons, Chichester.
- French, H. (2000). Does Lozinski's Periglacial Realms Exist Today? A Discussion Relevant to Modern Usage of the Term 'Periglacial'. *Permafrost and Periglacial Processes* 11, 35-42.
- French, H. & M. Demitroff (2001). Cold-Climatic Origin of the Enclosed Depressions and wetlands ('Spungs') of the Pine Barrens, Southern New Jersey, USA. *Permafrost and Periglacial Processes* 12, 337-350.
- French, H. (2007). *The Periglacial Environment*. 3 Pain. 458 s. John Wiley & Sons, Chichester.



- Fronzek, S., M. Luoto & T. Carter (2006). Potential effect of climate change on the distribution of palsa mires in subarctic Fennoscandia. *Climate Research* 32, 1-12.
- Garmin (2011). eTrex Venture.  
<http://www8.garmin.com/products/etrexVenture/spec.html> >.
- Goovaerts, P. (1999). Geostatistics in soil science: state-of-the-art and perspectives. *Geoderma* 89, 1-45.
- Goovaerts, P. (2000). Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. *Journal of Hydrology* 228, 113-129.
- GTK (2010a). *Digitaalinen maaperäaineisto*. Geologian tutkimuskeskus, Espoo.
- GTK (2010b). *Digitaalinen kallioperäaineisto*. Geologian tutkimuskeskus, Espoo.
- Graham, M. (2003). Confronting Multicollinearity in Ecological Multiple Regression. *Ecology* 84, 2809-2815.
- Guisan, A. & N. Zimmermann (2000). Predictive habitat distribution models in ecology. *Ecological modelling* 135, 147-186.
- Guisan, A., T. Edwards & T. Hastie (2002). Generalized linear and generalized additive models in studies of species distributions: setting the scene. *Ecological Modelling* 157, 89-100.
- Guisan, A. & U. Hofer (2003). Predicting reptile distribution at the mesoscale: relation to climate and topography. *Journal of Biogeography* 30, 1233-1243.
- Guzzetti, F., A. Carrara, M. Cardinali & P. Reichenbach (1999). Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, Central Italy. *Geomorphology* 31, 181-216.
- Hall, K. (1999). The role of thermal stress fatigue in the breakdown of rocks in cold regions. *Geomorphology* 31, 47-63.
- Hall, K., C. Thorn, N. Matsuoka & A. Prick (2002). Weathering in cold regions: some thoughts and perspectives. *Progress in Physical Geography* 26, 577-603.
- Harris, S. (1994). Climatic Zonality of Periglacial Landforms in Mountain Areas. *Arctic* 47, 184-192.
- Harris, C., M. Davies & B. Etzelmüller (2001a). The Assessment of Potential Geotechnical Hazards Associated with Mountain Permafrost in a Warming Global Climate. *Permafrost and Periglacial Processes* 12, 145-156.

- Harris, C., B. Rea & M. Davies (2001b). Scaled Physical Modelling of Mass Movement Processes on Thawing Slopes. *Permafrost and Periglacial Processes* 12, 125-135.
- Harris, C., J. Smith, M. Davies & B. Rea (2008). An investigation of periglacial slope stability in relation to soil properties based on physical modelling in geotechnical centrifuge. *Geomorphology* 93, 437-459.
- Hastie, T. & R. Tibshirani (1990). Generalized Additive Models. *Monographs on Statistics and Applied Probability* 43. Chapman & Hall, New York. 335 s.
- Heikkinen, R., M. Luoto, M. Kuussaari & J. Pöyry (2005). New insights into butterfly-environment relationship using partitioning methods. *Proceedings of the Royal Society B* 272, 2203-2210.
- Heikkinen, R., M. Luoto, M. Araújo, R. Virkkala, W. Thuiller & M. Sykes (2006). Methods and uncertainties in bioclimatic envelope modelling under climate change. *Progress in Physical Geography* 30, 751-777.
- Hjort, J. (2006). Environmental factors affecting the occurrence of periglacial landforms in Finnish Lapland: a numerical approach. *Geowissenschaft*. 162 s.
- Hjort, J., M. Luoto & M. Seppälä (2007). Landscape Scale Determinants of Periglacial Features in Subarctic Finland: A Grid-based modeling Approach. *Permafrost and Periglacial Processes* 18, 115-127.
- Hjort, J. & M. Marmion (2008). Effects of sample size on the accuracy of geomorphological models. *Geomorphology* 102, 341-350.
- Hjort, J. & M. Luoto (2008). Can abundance of geomorphological features be predicted using presence-absence data? *Earth Surface Processes and Landforms* 33, 741-750.
- Hjort, J. & M. Luoto (2009). Interaction of geomorphic and ecologic features across altitudinal zones in a subarctic landscape. *Geomorphology* 112, 324-333.
- Hjort, J., B. Etzemüller & J. Tolgensbakk (2010). Effect of Scale and Data Source in Periglacial Distribution Modelling in a High Arctic Environment, Western Svalbard. *Permafrost and Periglacial Processes* 21, 345-354.
- Hjort, J. & M. Luoto (2010). Novel theoretical insights into geomorphic process-environment relationship using simulated response curves. *Earth Surface Processes and Landforms*. DOI: 10.1002/esp.2048.
- Hooke, R. (2000). On the history of humans as geomorphic agents. *Geology* 28, 843-

- Huggett, R. (2007). *Fundamentals of geomorphology*. 2 Pain. 458 s. Routledge, Oxon.
- Hugelius, G., P. Kuhry, C. Tarnocai & T. Virtanen (2010). Soil Organic Carbon pools in a Periglacial Landscape: a Case Study from the Central Canadian Arctic. *Permafrost and Periglacial Processes* 21, 16-29.
- Jaesche, P., H. Veit & B. Huwe (2003). Snow Cover and Soil Moisture Controls on Solifluction in an Area of Seasonal Frost, Eastern Alps. *Permafrost and Periglacial Processes* 14, 399-410.
- Johansson, P. (2005). Mannerjäätikön toiminta ja se virtaussuunnat. *Teoksessa* Johansson, P. & Kujansuu, R. (toim.): *Pohjois-Suomen maaperä. Maaperäkarttojen 1:400 000 selitys*. Geologian tutkimuskeskus, Espoo.
- Johnston, C., D. Ghioca, M. Tulbure, B. Bedford, M. Bourdaghs, C. Frieswyk, L. Vaccaro & J. Zedler (2008). Partitioning Vegetation Response to Anthropogenic Stress to Develop Multi-taxa Wetland Indicators. *Ecological Applications* 18, 983-1001.
- Jylhä, K., H. Tuomenvirta & K. Ruosteenoja (2004). Climate change projections for Finland during the 21<sup>st</sup> century. *Boreal Environment Research* 9, 127-152.
- Kauppila, T & V. Salonen (1997). The effect of Holocene treeline fluctuations on the sediment chemistry of Lake Kilpisjärvi, Finland. *Journal of Paleolimnology* 18, 145-163.
- Kneisel, C., C. Rothenbühler, F. Keller. & W. Haeberli (2007). Hazard Assessment of Potential Periglacial Debris Flows based on GIS-based Spatial Modelling and Geophysical Field Surveys: A Case Study in the Swiss Alps. *Permafrost and Periglacial Processes* 18, 259-268.
- Kuhry, P., E. Dorrepaal, G. Hugelius, E. Schuur & C. Tarnocai (2010). Potential Remobilization of Belowground Permafrost Carbon under Future Global Warming. *Permafrost and Periglacial Processes* 21, 208–214.
- Kujansuu, R. (2005a). Kallioperä ja sen vaikutukset korkokuvaan. *Teoksessa* Johansson, P. & Kujansuu, R. (toim.): *Pohjois-Suomen maaperä. Maaperäkarttojen 1:400 000 selitys*. Geologian tutkimuskeskus, Espoo.
- Kujansuu, R. (2005b). Savi- ja silttikerrostumat. *Teoksessa* Johansson, P. & Kujansuu, R. (toim.): *Pohjois-Suomen maaperä. Maaperäkarttojen 1:400 000 selitys*. Geologian tutkimuskeskus, Espoo.

- Kullman, L. (2010). A Richer, Greener and Smaller Alpine World: Review and Projection of Warming-Induced Plant Cover Change in the Swedish Scandes. *Ambio* 39, 159-169.
- Laine, K. (2004). Pohjoisuus leimaa kasvillisuutta. Teoksessa Järvinen, A. & S. Lahti (toim). *Suurtuntureiden luonto*, 77–96. Palmenia kustannus, Helsinki.
- Laitakari, I. (1998). Peruskallion myöhäiset kehitysvaiheet: miljardi rauhallista vuotta. Teoksessa Lehtinen, M. Nurmi, P. & Rämö, T. (toim.): *Suomen kallioperä-3000 vuosimiljoonaa*. 310-324. Suomen geologinen seura, Jyväskylä.
- Lautridou, J. (1988). Recent advances in Cryogenic Weathering. Teoksessa Clark, M. (toim). *Advances in Periglacial Geomorphology*, 33-47. John Wiley & Sons, Chichester.
- Leathwick, J., J. Elith & T. Hastie (2006). Comparative performance of generalized additive models and multivariate adaptive regression splines for statistical modeling of species distributions. *Ecological Modelling* 199, 188-196.
- Legendre, P. & M. Fortin (1989). Spatial pattern and ecological analysis. *Vegetatio* 80, 107-138.
- Legendre, P. (1993). Spatial Autocorrelation: Trouble or New Paradigm? *Ecology* 74, 1659-1673.
- Legendre, P., M. Dale, M. Fortin, J. Gurevitch, M. Hohn & D. Myers (2002). The consequences of spatial structure for the design and analysis of ecological field surveys. *Ecography* 25, 601-615.
- Lemke, P., J. Ren, R. Alley, I. Allison, J. Carrasco, G. Flato, Y. Fujii, G. Kaser, P. Mote, R. Thomas & T. Zhang, 2007: Observations: Changes in Snow, Ice and Frozen Ground. In: *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change* [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K. Averyt, M. Tignor & H. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
- Lenoir, J., J. Gégout, P. Marquet, P. Ruffray & H. Brisse (2008). A Significant Upward Shift in Plant Species Optimum Elevation During 20<sup>th</sup> Century. *Science* 320, 1768–1771.

- Lewis, W. (1939). Snow-Patch Erosion in Ireland. *The Geographical Journal* 94, 153-161.
- Lewkowicz, A. (1988). Slope processes. Teoksessa Clark, M. (toim). *Advances in Periglacial Geomorphology*, 325-368. John Wiley & Sons, Chichester.
- Luoto, M. & M. Seppälä (2002). Characteristics of earth hummocks (Pounus) with and without permafrost in Finnish Lapland. *Geografiska Annaler* 84 A 2, 127-136.
- Luoto, M. & M. Seppälä (2003). Thermokarst Ponds as Indicators of the Former Distribution of Palsas in Finnish Lapland. *Permafrost and Periglacial Processes* 14, 19-27.
- Luoto, M. & J. Hjort (2004). Generalized Linear Modelling in Periglacial Studies: Terrain Parameters and Patterned Ground. *Permafrost and Periglacial Processes* 15, 327-338.
- Luoto, M., Fronzek, S. & F. Zuidhoff (2004). Spatial Modelling of Palsa Mires in Relation to Climate in Northern Europe. *Earth Surface Processes and Landforms* 29, 1373-1387.
- Luoto, M. & J. Hjort (2005). Evaluation of current statistical approaches for predictive geomorphological mapping. *Geomorphology* 67, 299-315.
- Luoto, M. & J. Hjort (2006). Scale matters- A multi-resolution study of the determinants of patterned ground activity in subarctic Finland. *Geomorphology* 80, 282-294.
- Maanmittauslaitos (2011). Maastotietokanta. 15.2.2011. <<http://www.csc.fi/tutkimus/alat/geotieteet/paikkatieto/paituli>>.
- Maantieteen laitos (2011). Tutkimusretki periglasiaaliseen ympäristöön. 31.3.2011. <<http://www.helsinki.fi/maantiede/labrat/56296/s2004/>>.
- MacNally, R. (2002). Multiple regression and inference in ecology and conservation biology: further comments on identifying important predictor variables. *Biodiversity and Conservation* 11, 1397-1401.
- Mann, D. (2003). On Patterned Ground. *Science* 299, 354-355.
- Marmion, M., J. Hjort, W. Thuiller & M. Luoto (2008). A comparison of predictive methods in modelling the distribution of periglacial landforms in Finnish Lapland. *Earth surface processes and landforms* 33, 2241-2254.

- Marmion, M., J. Hjort, W. Thuiller & M. Luoto (2009). Statistical consensus methods for improving predictive geomorphology maps. *Computers & Geosciences* 35, 615-625.
- Marmion, M., M. Luoto, R. Heikkinen & W. Thuiller (2009). The performance of state-of-the-art modeling techniques depends on geographical distribution of species. *Ecological Modelling* 220, 3512-3520.
- Matthews, J., R. Shakesby, M. Berrisford & L. McEwen (1998). Periglacial Patterned Ground on the Styggedalsbreen Glacier Foreland, Jotunheimen, Southern Norway: Micro-Topographic, Paraglacial and Geocological Controls. *Permafrost and Periglacial Processes* 9, 147-166.
- Matsuoka, N. & H. Sakai (1999). Rockfall activity from an alpine cliff during thawing periods. *Geomorphology* 28, 309-328.
- Matsuoka, N. (2001a). Solifluction rates, processes and landforms: a global review. *Earth-Science Reviews* 55, 107-134.
- Matsuoka, N. (2001b). Microgelivation versus Macrogelivation: Towards Bridging the Gap between Laboratory and Field Frost weathering. *Permafrost and Periglacial Processes* 12, 299-313.
- Matsuoka, N. (2005a). Morphometric Analysis of Solifluction Lobes and Rock Glaciers in the Swiss Alps. *Permafrost and Periglacial Processes* 16, 99-113.
- Matsuoka, N. (2005b). Temporal and spatial variations in periglacial soil movements on alpine crest slopes. *Earth Surface Processes and Landforms* 30, 41-58.
- McCann, S., P. Howarth & J. Cogley (1971). Fluvial processes in periglacial environment. *Transaction of the Institute of British Geographers* 55, 69-82.
- McCullagh, P. & J. Nelder (1989). Generalized linear models. 2 pain. *Monographs on Statistics and Applied Probability* 37. Chapman & Hall, New York. 511 s.
- McCune, B. & D. Keon (2002). Equations for potential annual direct incident radiation and heat load. *Journal of Vegetation Science* 13, 603-606.
- Mikkola, K. & P. Sepponen (1986). Kasvupaikkatekijöiden ja kasvillisuuden suhteet Luoteis-Enontekiön tunturikoivikossa. *Folia Forestalia* 674, 30 s.
- Miller, J. & J. Franklin (2002). Modelling the distribution of four vegetation alliances using generalized linear models and classification trees with spatial dependence. *Ecological Modelling* 157, 227-247.

- Moisen, G. & T. Frescino (2002). Comparing five modeling techniques for predicting forest characteristics. *Ecological Modelling* 157, 209-225.
- Mol, J., J. Vandenberghe & C. Kasse (2000). River response to variations of periglacial climate in mid-latitude Europe. *Geomorphology* 33, 131-148.
- Moore, I. (1991). Digital terrain modeling: a review of hydrological, geomorphological, and biological applications. *Hydrological Processes* 5, 3-30.
- Moran, P. (1950). Notes on Continuous Stochastic Phenomena. *Biometrika Trust* 37, 17-23.
- Naylor, L., H. Viles & N. Carter (2002). Biogeomorphology revisited: looking towards the future. *Geomorphology* 47, 3-14.
- Nelson, F., O. Anisimov & N. Shiklomanov (2002). Climate Change and Hazard Zonation in the Circum-Arctic Permafrost Regions. *Natural Hazards* 26, 203-225.
- Oksanen, J. & T. Sarjakoski (2005). Error propagation of DEM-based surface derivatives. *Computers & Geosciences* 31, 1015-1027.
- Oliver, I., R. MacNally & A. York (2000). Identifying performance indicators of the effects of forest management on ground-active arthropod biodiversity using hierarchical partitioning and partial canonical correspondence analysis. *Forest Ecology and Management* 139, 21-40.
- Orwin, J., S. Lamoureux, J. Warburton & A. Beylich (2010). A Framework for Characterizing Fluvial Sediment Fluxes from Source to Sink in Cold Environments. *Geografiska Annaler* 92 A 2, 155-176.
- Pearce, J. & S. Ferrier (2000). Evaluating the predictive performance of habitat models developed using logistic regression. *Ecological Modelling* 133, 225-245.
- Phillips, J. (2003). Sources of nonlinearity and complexity in geomorphic systems. *Progress in Physical Geography* 27, 1-23.
- Phillips, J. (2009). Changes, perturbations, and responses in geomorphic systems. *Progress in Physical Geography* 33, 17-30.
- Pike, R. & S. Wilson (1971). Elevation-Relief Ratio, Hypsometric Integral, and Geomorphic Area-Altitude Analysis. *Geological Society of America Bulletin* 82, 1079-1084.
- R Development Core Team (2009). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna Austria. <

<http://www.R-project.org>>.

- Ridefelt, H., B. Etzelmüller & J. Boelhouwers (2010). Spatial Analysis of Solifluction Landforms and Process Rates in the Abisko Mountains, Northern Sweden. *Permafrost and Periglacial Processes* 21, 214–255.
- Schunke, E & S. Zoltai (1988). Earth hummocks (Thufur). Teoksessa Clark, M. (toim). *Advances in Periglacial Geomorphology*, 231-245. John Wiley & Sons, Chichester.
- Seppälä, M. (1976). Seasonal thawing of a palsa at Enontekiö, Finnish Lapland, in 1974. *Biuletyn Peryglacjalny* 26, 1-26.
- Seppälä, M. (1982). An experimental study of the formation of palsas. Teoksessa French, H. (toim). *4<sup>th</sup> Canadian Permafrost Conference, Proceedings*, 36-42. National Research Council of Canada, Ottawa.
- Seppälä, M. (1983). Present-day periglacial phenomena in northern Finland. *Helsingin yliopiston maantieteen laitoksen julkaisuja A* 125, 231–243.
- Seppälä, M. (1988). Palsas and Related Forms. Teoksessa Clark, M. (toim). *Advances in periglacial geomorphology*, 247-278. John Wiley & Sons, Chichester.
- Seppälä, M. (1995). Deflation and redeposition of sand dunes in Finnish Lapland. *Quaternary Science Reviews* 14, 799-809.
- Seppälä, M. (1997). Introduction to the periglacial environment in Finland. *Bulletin of the Geological Society of Finland* 69, 73-86.
- Seppälä, M. (1998). New Permafrost Formed in Peat Hummocks (Pounus), Finnish Lapland. *Permafrost and Periglacial Processes* 9, 367-373.
- Seppälä, M. (2003). Surface abrasion of palsas by wind action in Finnish Lapland. *Geomorphology* 52, 141-148.
- Seppälä, M. (2004a). *Wind as a Geomorphic Agent in Cold Climates*. Cambridge University Press. 358 s.
- Seppälä, M. (2004b). Kilpisjärven alueen maanpinnan muodoista. Teoksessa Järvinen, A. & S. Lahti (toim). *Suurtuntureiden luonto*, 65–76. Palmenia kustannus, Helsinki.
- Seppälä, M. (2005a). Frost heave on earth hummocks (*pounus*) in Finnish Lapland. *Norsk Geografisk Tidsskrift-Norwegian Journal of Geography* 59, 171-176.
- Seppälä, M. (2005b). Periglacial Environment. Teoksessa Seppälä, M. (toim). *The Physical Geography of Fennoscandia*, 349-364. Oxford University Press,



Oxford.

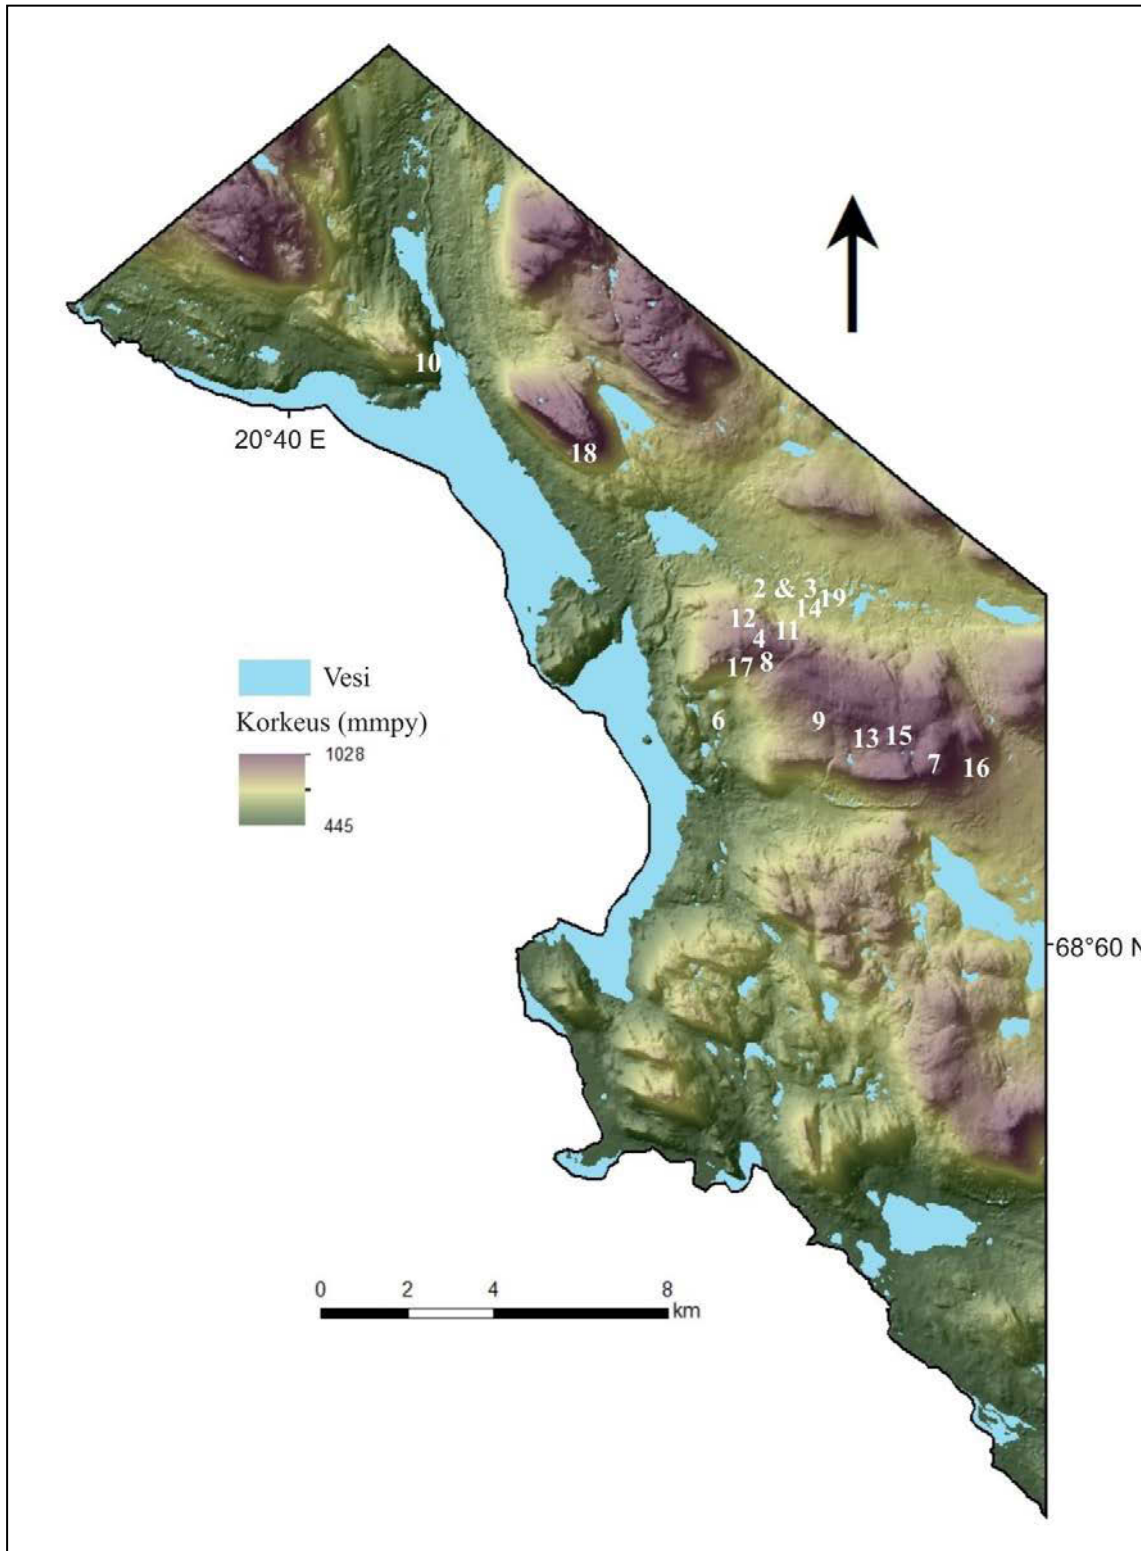
- Sormunen, H., R. Virtanen. & M. Luoto (2010). Inclusion of local environmental conditions alters high-latitude vegetation change predictions based on bioclimatic models. *Polar Biology*. DOI: 10.1007/s00300-010-0945-2.
- Stallins, J. (2006). Geomorphology and ecology: unifying themes for complex systems in biogeomorphology. *Geomorphology* 77, 207-216.
- Suomen kartasto, vihko 121–122. Maanpinnan muodot.* (1986). Alalammi, Pertti (toim.) Maanmittauslaitos, Helsinki.
- Suomen kartasto, vihko 131. Ilmasto.* (1987). Alalammi, Pertti (toim.)
- Suomen kartasto, vihko 123-126. Geologia.* (1990). Alalammi, Pertti (toim.) Maanmittauslaitos, Helsinki.
- Söderman, G. (1980). Slope processes in cold environments of Northern Finland. *Helsingin yliopiston maantieteen laitoksen julkaisuja A* 121, 83–152.
- Sørensen, R., U. Zinko & J. Seibert (2005). On the calculation of the topographic wetness index: evaluation of different methods based on field observations. *Hydrology and Earth System Sciences Discussions* 2, 1807-1834.
- Thorn, C. (1979). Ground temperatures and surficial transport in colluvium during snowpatch meltout; Colorado front range. *Arctic and Alpine Research* 11, 41-52.
- Thorn, C. (1988). Nivation: A Geomorphic Chimera. Teoksessa Clark, M. (toim.) *Advances in periglacial geomorphology*, 3-31. John Wiley & Sons, Chichester.
- Thuiller, W. (2004). Patterns and uncertainties of species' range shifts under climate change. *Global Change Biology* 10, 2020-2027.
- Tikkanen, M. (2005). Climate. Teoksessa Seppälä, M. (toim.): *The Physical Geography of Fennoscandia*. 97–112. Oxford University Press, Oxford.
- Tilastoja Suomen ilmastosta 1961–1990.* Liite Suomen meteorologiseen vuosikirjaan. Ilmatieteenlaitos, Helsinki.
- Tucker, C. (1979). Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. *Remote Sensing of Environment* 8, 127-150.
- Tucker, G. & G. Hancock (2010). Modelling landscape evolution. *Earth Surface Processes and Landforms* 35, 28-50.
- Turner, M., R. O'Neill, R. Gardner & B. Milne (1989). Effects of changing spatial scale

- on the analysis of landscape pattern. *Landscape Ecology* 3, 153-162.
- Vandenberghe, J. (1988). Cryoturbations. Teoksessa Clark, M. (toim). *Advances in Periglacial Geomorphology*, 179-198. John Wiley & Sons, Chichester.
- Van Houwenlingen, J. & S. Le Cessie (1990). Predictive value of statistical models. *Statistics in Medicine* 9, 1303-1325.
- Viles, H., L. Naylor, N. Carter & D. Chaput (2008). Biogeomorphological disturbance regimes: progress in linking ecological and geomorphological systems. *Earth Surface Processes* 33, 1419-1435.
- Virtanen, R., M. Luoto, T. Rämä, K. Mikkola, J. Hjort, J. Grytnes, H. John & B. Birks (2010). Recent vegetation changes at the high-latitude tree line ecotone are controlled by geomorphological disturbance, productivity and diversity. *Global Ecology and Biogeography* 19, 810-821.
- Vliet-Lanoë, B. & M. Seppälä (2002). Stratigraphy, age and formation of peaty earth hummocks (Pounus), Finnish Lapland. *The Holocene* 12, 187-199.
- Walsh S., D. Butler & G. Malanson (1998). An overview of scale, pattern, process relationships in geomorphology: a remote sensing and GIS perspective. *Geomorphology* 21, 183-205.
- Walsh, C. & R. MacNally (2003). Hierarchical Partitioning. <<http://cran.r-project.org/>>.
- Washburn, A. (1956). Classification of patterned ground and review of suggested origins. *Geological Society of America Bulletin* 67, 823-866.
- Washburn, A. (1979). *Geocryology- A survey of periglacial processes and environments*. Arnold, London. 406 s.
- Washburn, A. (1997). Plugs and plug circles: a basic form of patterned ground, Cornwallis Island, Arctic Canada- origin and implications. Geological Society of America, *memoir* 190, 87 s.
- Washburn, A. (1999). A High Arctic Frost Creep/Gelifluction Slope, 1981-89: Resolute Bay, Cornwallis Island, Northwest Territories, Canada. *Permafrost and Periglacial Processes* 10, 163-186.
- Wilcock, P. & R. Iversom (toim) (2003). Prediction in geomorphology. *Geophysical monograph series* 135. 256 s. Washington, D.C, American Geophysical Union.
- Williams, P. & M. Smith (1989). The Frozen Earth. Fundamentals of geocryology. *Studies In Polar Research*. Gambridge University Press, Gambridge. 306 s.

- Willison, J. (2001). ArcGis 9. ArcGis Spatial Analyst Tutorial. 20.01.2011. <[http://webhelp.esri.com/arcgisdesktop/9.3/pdf/Spatial\\_Analyst\\_Tutorial.pdf](http://webhelp.esri.com/arcgisdesktop/9.3/pdf/Spatial_Analyst_Tutorial.pdf)>.
- Wood, S. & N. Augustin (2002). GAMs with integrated model selection using penalized regression splines and applications to environmental modeling. *Ecological Modelling* 157, 157-177.
- Wood, S. (2004). Stable and Efficient Multiple Smoothing Parameter Estimation for Generalized Additive Models. *Journal of the American Statistical Association* 99, 673-686.
- Yee, T. & N. Mitchell (1991). Generalized Additive Models in Plant Ecology. *Journal of Vegetation Science* 2, 587-602.
- Zeng, Y., G. Malanson & D. Butler (2007). Geomorphological limits to self-organization of alpine forest-tundra ecotone vegetation. *Geomorphology* 91, 378-392.
- Zhang, L., J. Gove & L. Heath (2005). Spatial residual analysis of six modeling techniques. *Ecological Modelling* 186, 154-177.

## 9. Liitteet

Liite 1. Periglaciaalisten ilmiöiden valokuvauspaikat tutkimusalueella kuvanumeroin.



Liite 2. Kaikki alkuperäiset selittävät ympäristömuuttujat.

Korkeuden keskiarvo
Korkeuden maksimiarvo
Korkeuden minimiarvo
Korkeuden vaihteluväli
Korkeuden keskihajonta
Rinteen keskikaltevuuden keskiarvo
Rinteen maksimikaltevuus
Rinteen kaltevuuden keskihajonta
Rinteen kaltevuus alle 2° %/ ha
Kaarevuus
Korkeus-reliefisuhde
NDVI-kasvillisuusindeksin keskiarvo
NDSI-maaperäindeksin keskiarvo
Topografinen kosteusindeksin keskiarvo
Maaperä
Kallioperä
Säteilyn määrän keskiarvo
Rinteen avautumissuunta

Liite 3. Esimerkkejä mallinnuksessa käytetyistä R-komennoista.

*Havainto aineiston jakaminen kalibraatio (70 %) - ja evaluointi- (30 %) aineistoihin:*

```
sel258 <- sample(1:369, 258)
data_kal <- rdata[sel258, ] ## kalibraatioaineisto
data_eva <- rdata[-sel258, ] ## evaluointiaineisto
```

*Poisson GLM-mallin kalibraatio ja ennustaminen nivaation tapauksessa:*

```
fmaopera <- factor(maopera)
fkalliopera <- factor(kalliopera)
glm_niva <- glm(niva ~ elev100ka + I(elev100ka^2) + I(elev100ka^3) + curva100ka +
I(curva100ka^2) + slo100ka + I(slo100ka^2) + I(slo100ka^3) + rad100ka +
I(rad100ka^2) + I(rad100ka^3) + slo100a12 + I(slo100a12^2) + fmaopera + fkalliopera,
family = "poisson")
pred_glm_niva <- predict.glm(glm_niva, selittavat, type = "response")
```

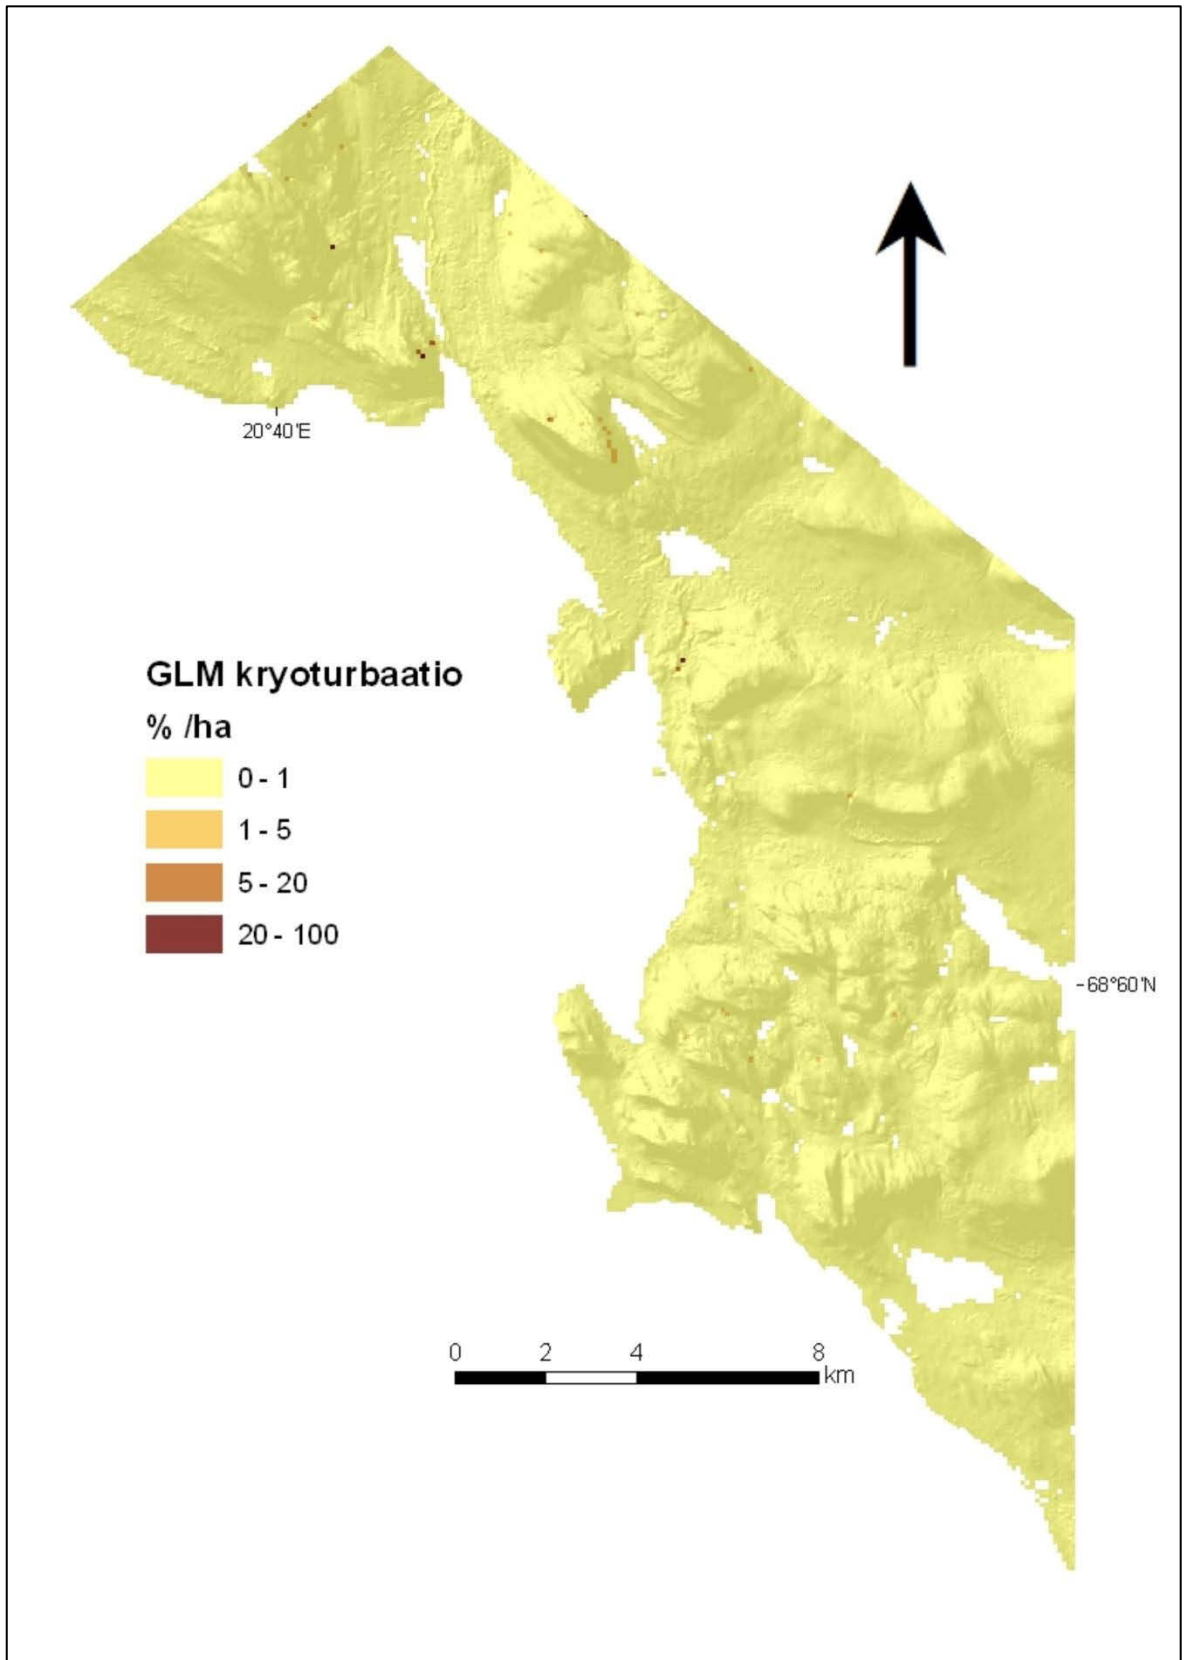
*Poisson GAM-mallin kalibraatio ja ennustaminen rinneprosessien tapauksessa:*

```
library(mgcv)
gamslopep <- gam(slopep~s(slo100a12, k=4) + s(slo100ka, k=4) + s(rad100ka, k=4) +
s(curva100ka, k=4) + s(elev100ka, k=4), family="poisson")
pred_gam_slopep <- predict.gam(gamslopep, selittavat, type = "response")
```

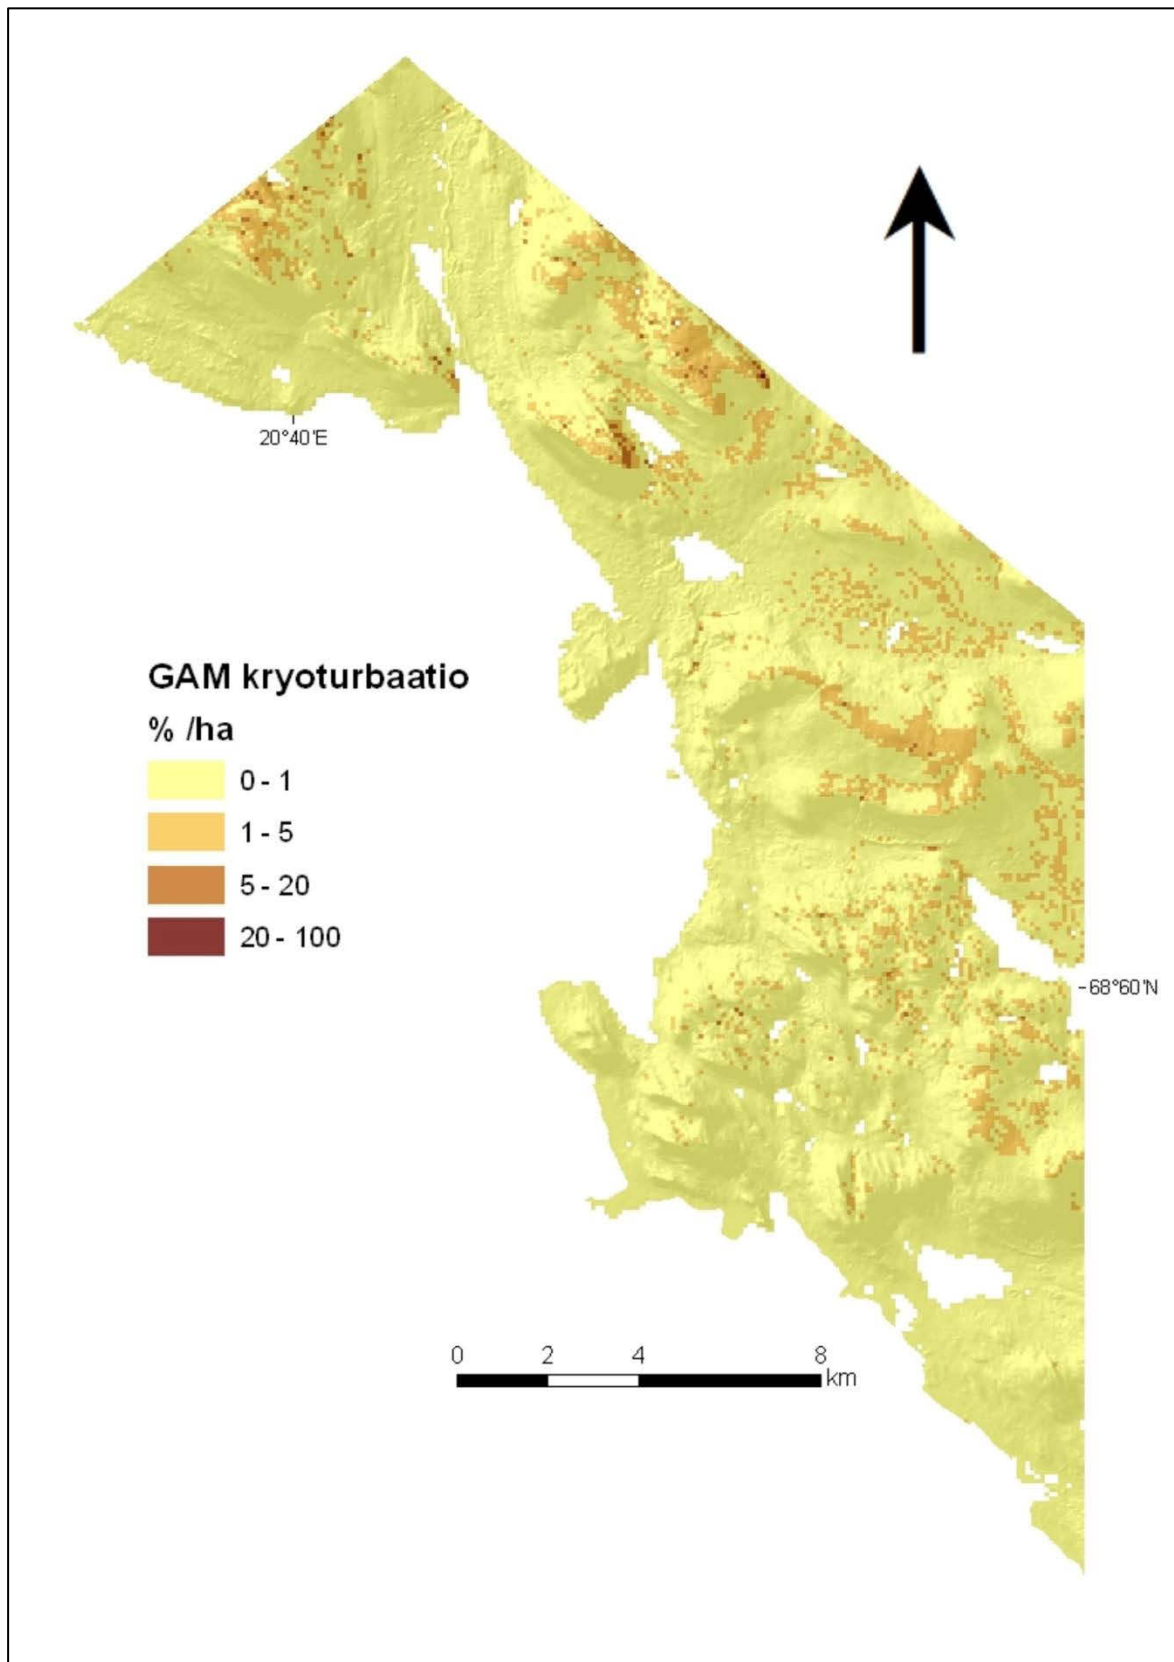
*Hierarkkisen osituksen tekeminen rapautumisen tapauksessa:*

```
library(gtools)
library(hier.part)
hp <- data.frame(elev100ka, slo100ka, slo100a12, curva100ka, rad100ka, maopera,
kalliopera, twi100_ka, ndvi100ka, x, y)
hier.part(weath, hp, fam = "poisson", gof = "logLik")
```

Liite 4. Ennustettu kryoturbaation alueellinen esiintyminen perustuen GLM-malliin.

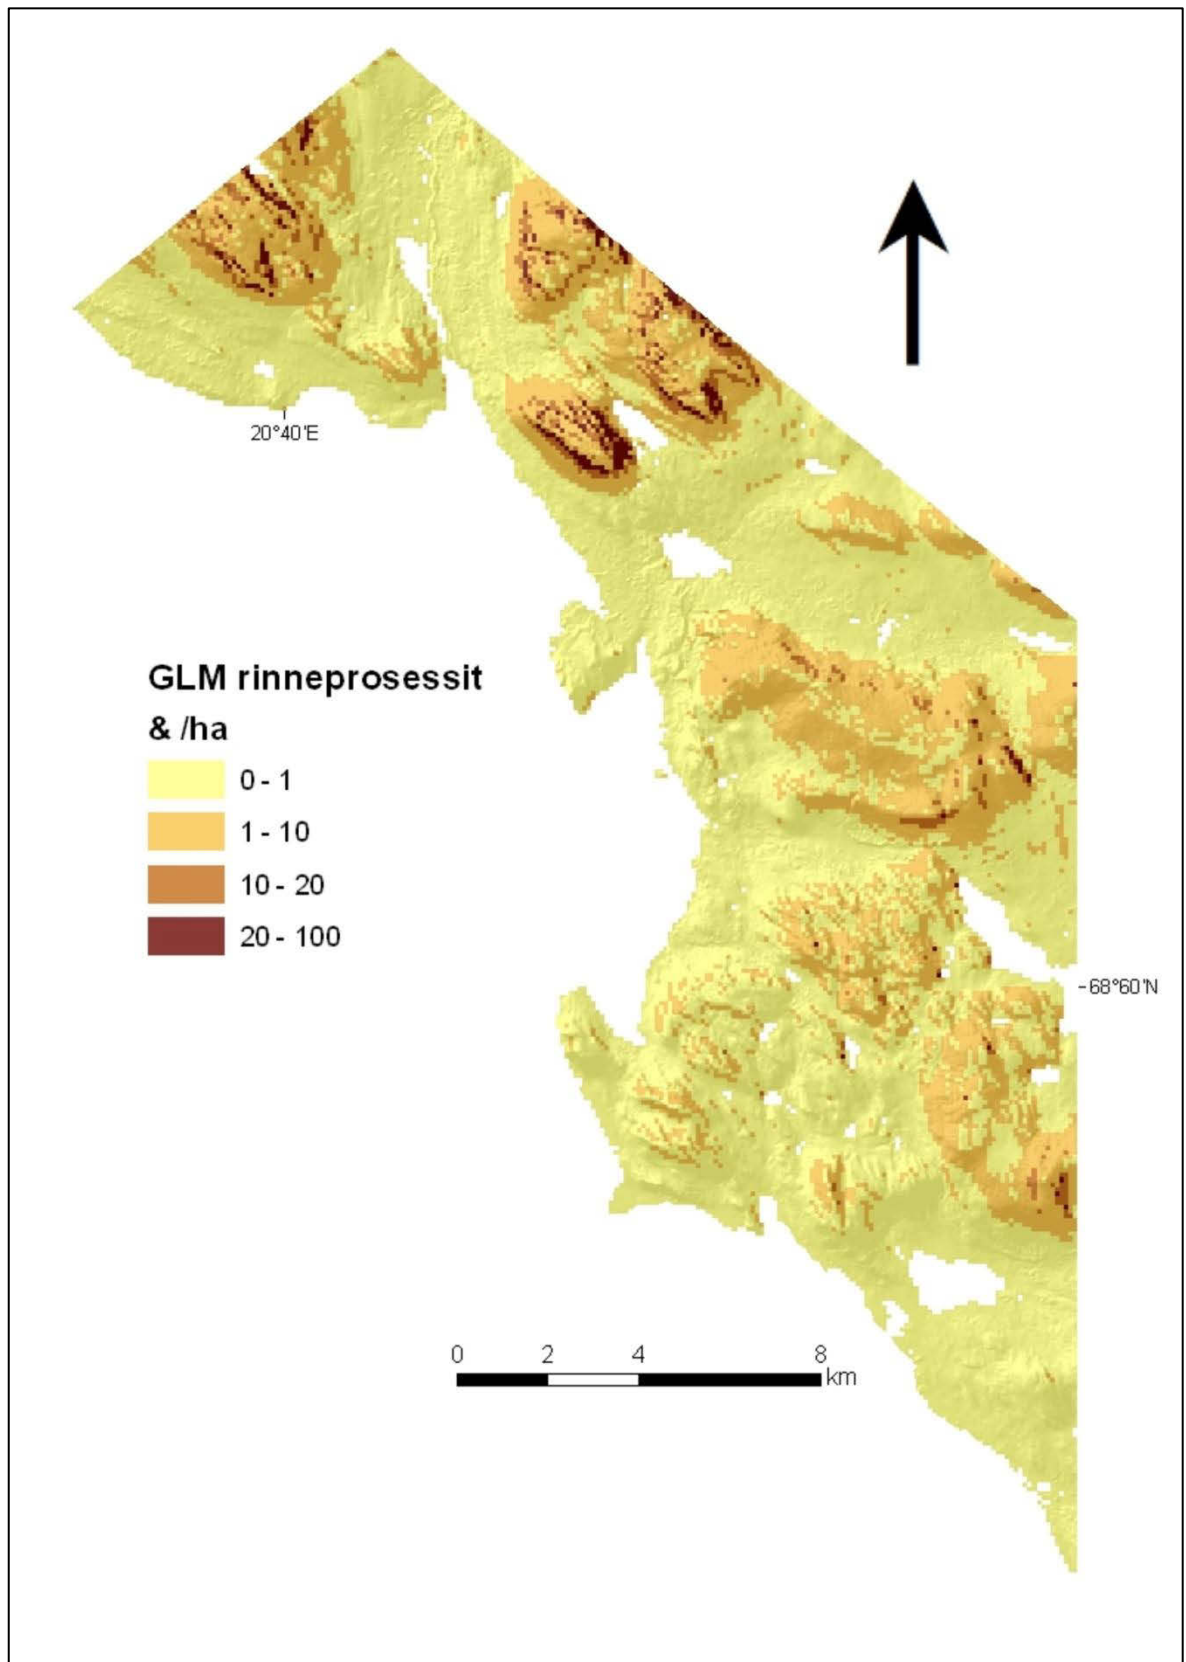


Liite 5. Kryoturbaation ennustettu alueellinen esiintyminen perustuen GAM-malliin.

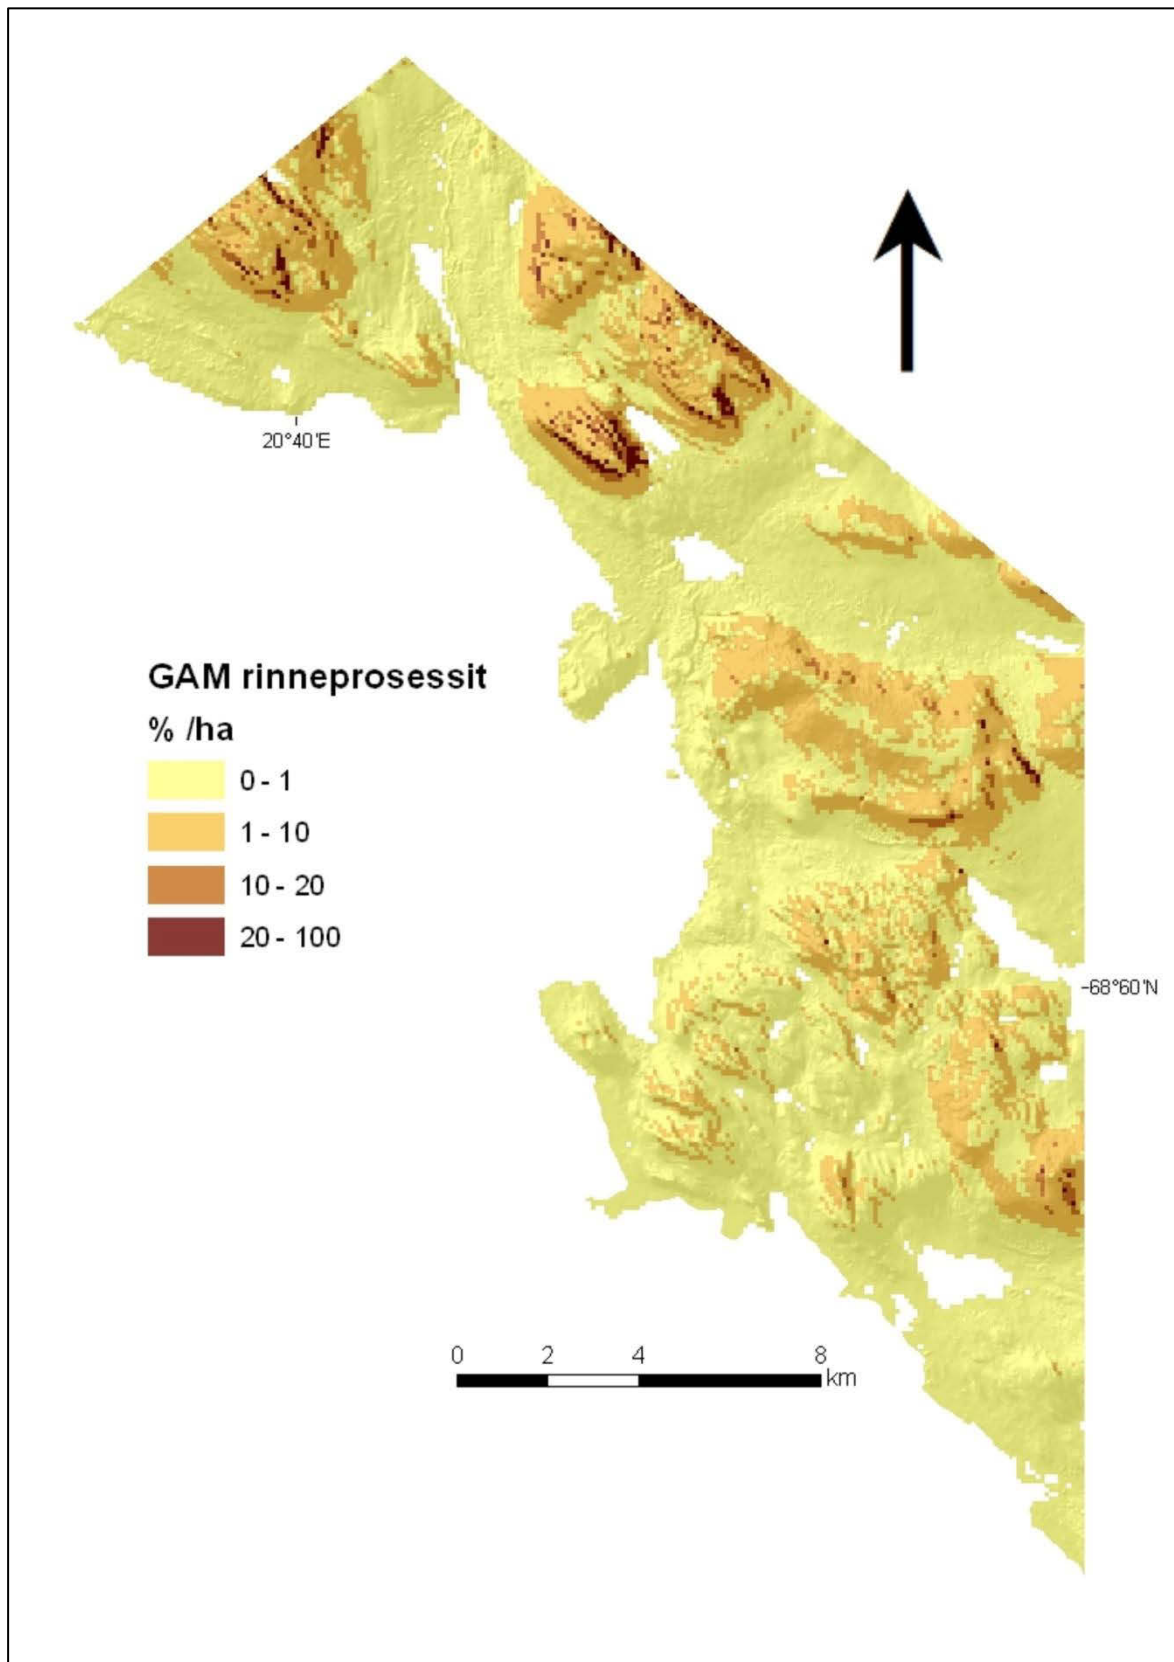




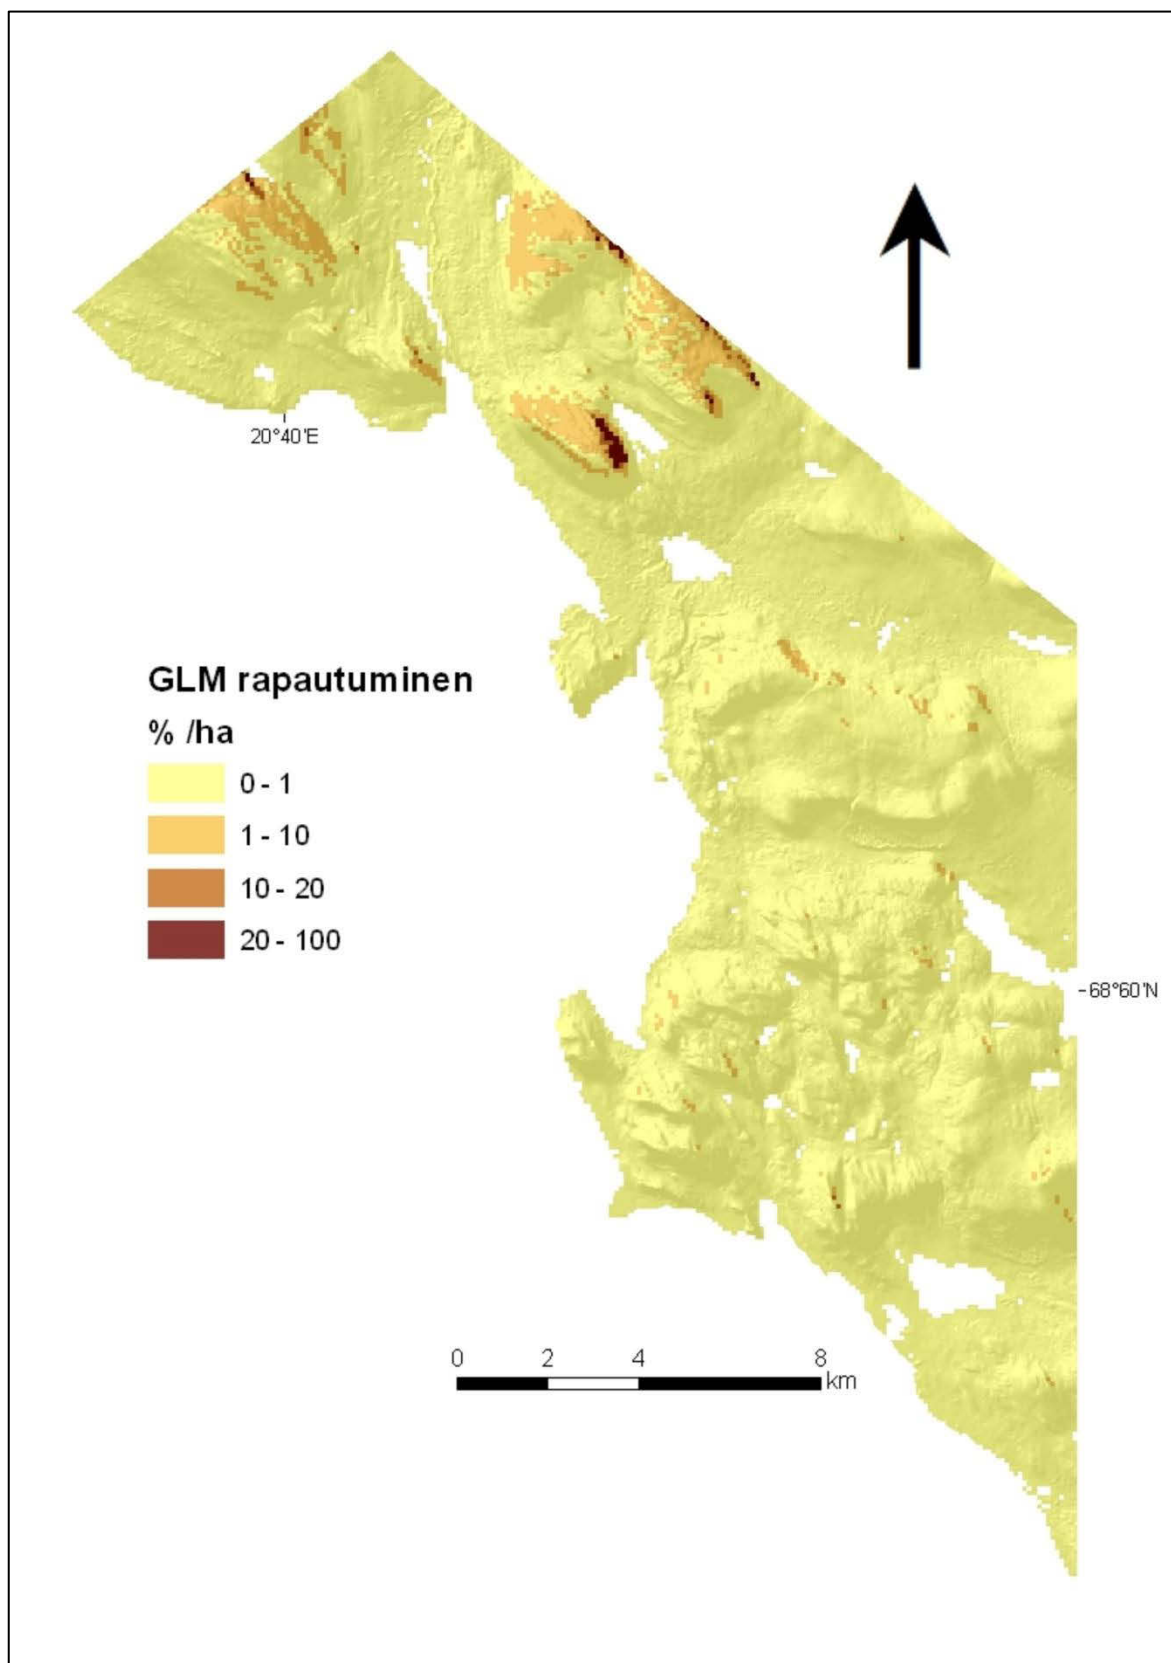
Liite 6. Ennustettu rinneprosessien alueellinen esiintyminen perustuen GLM-malliin.



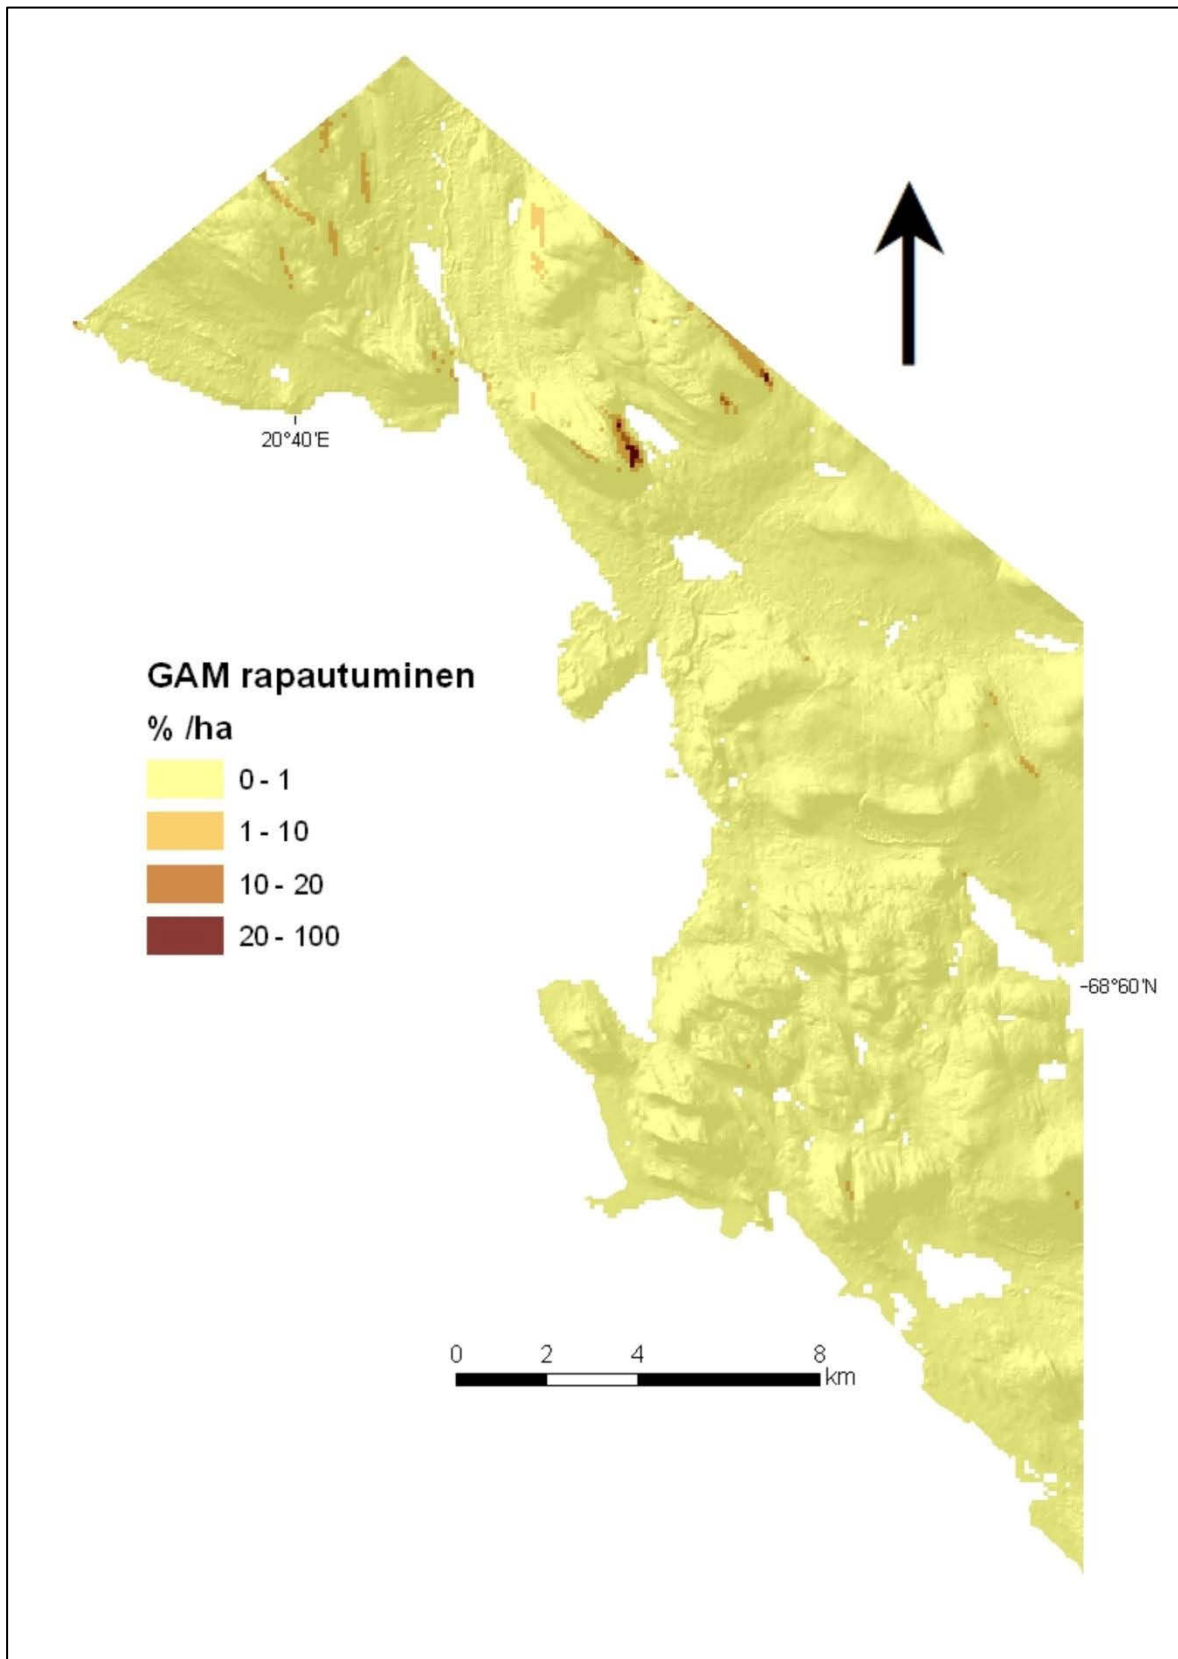
Liite 7. Ennustettu rinneprosessien alueellinen esiintyminen perustuen GAM-malliin.



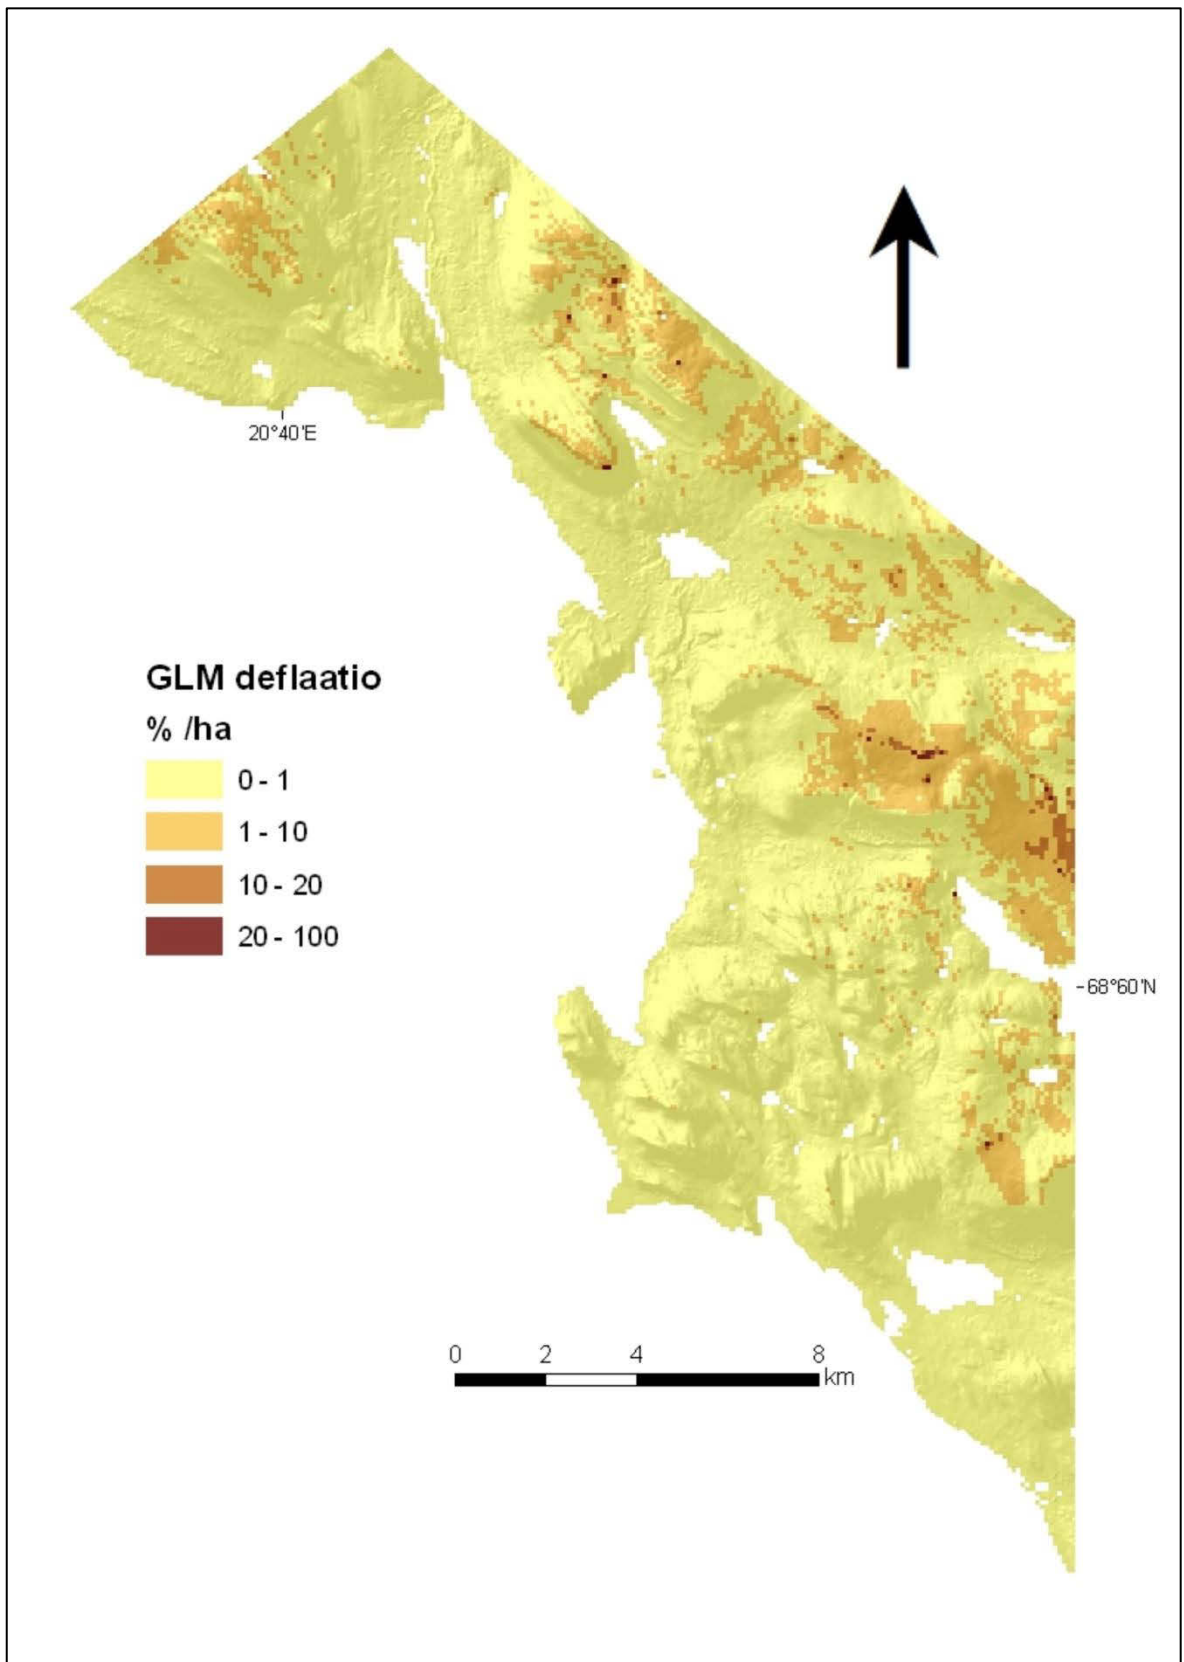
Liite 8. Ennustettu rapautumisprosessien alueellinen esiintyminen perustuen GLM-malliin



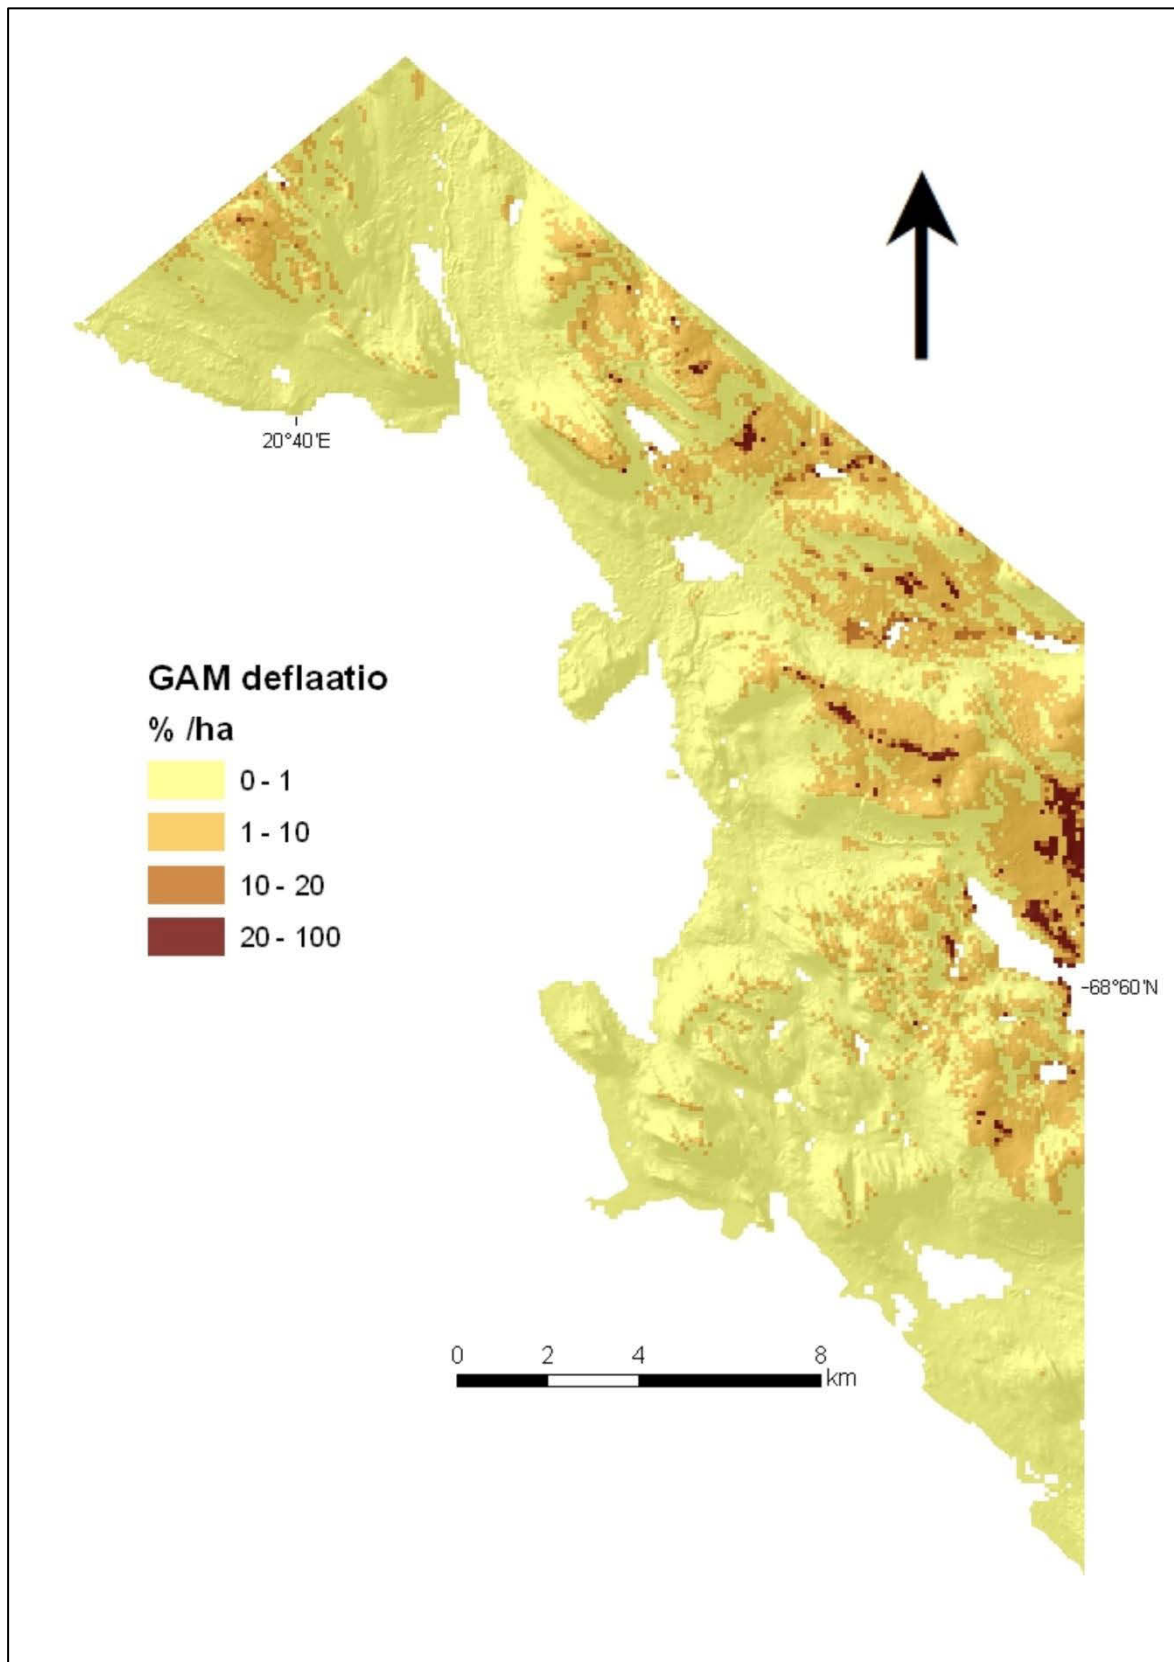
Liite 9. Ennustettu rapautumisprosessien alueellinen esiintyminen perustuen GAM-malliin.



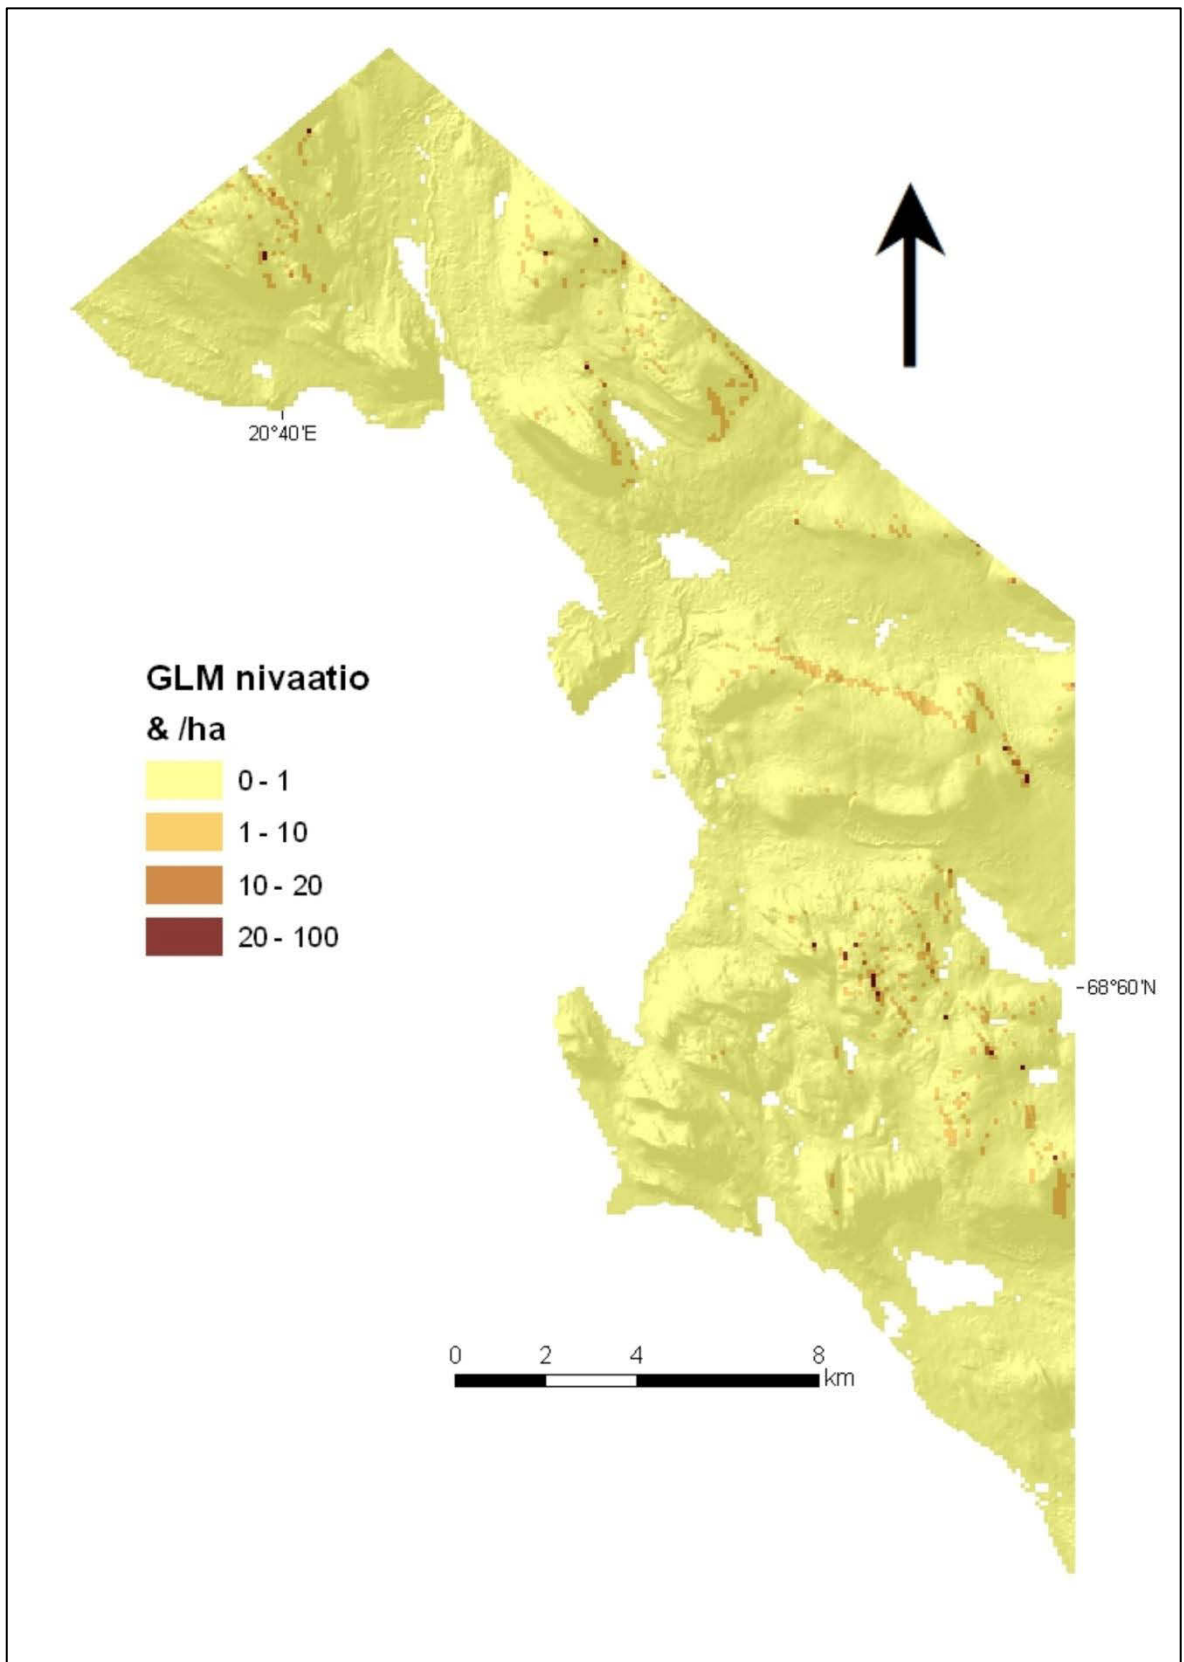
Liite 10. Ennustettu deflaation alueellinen esiintyminen perustuen GLM-malliin.



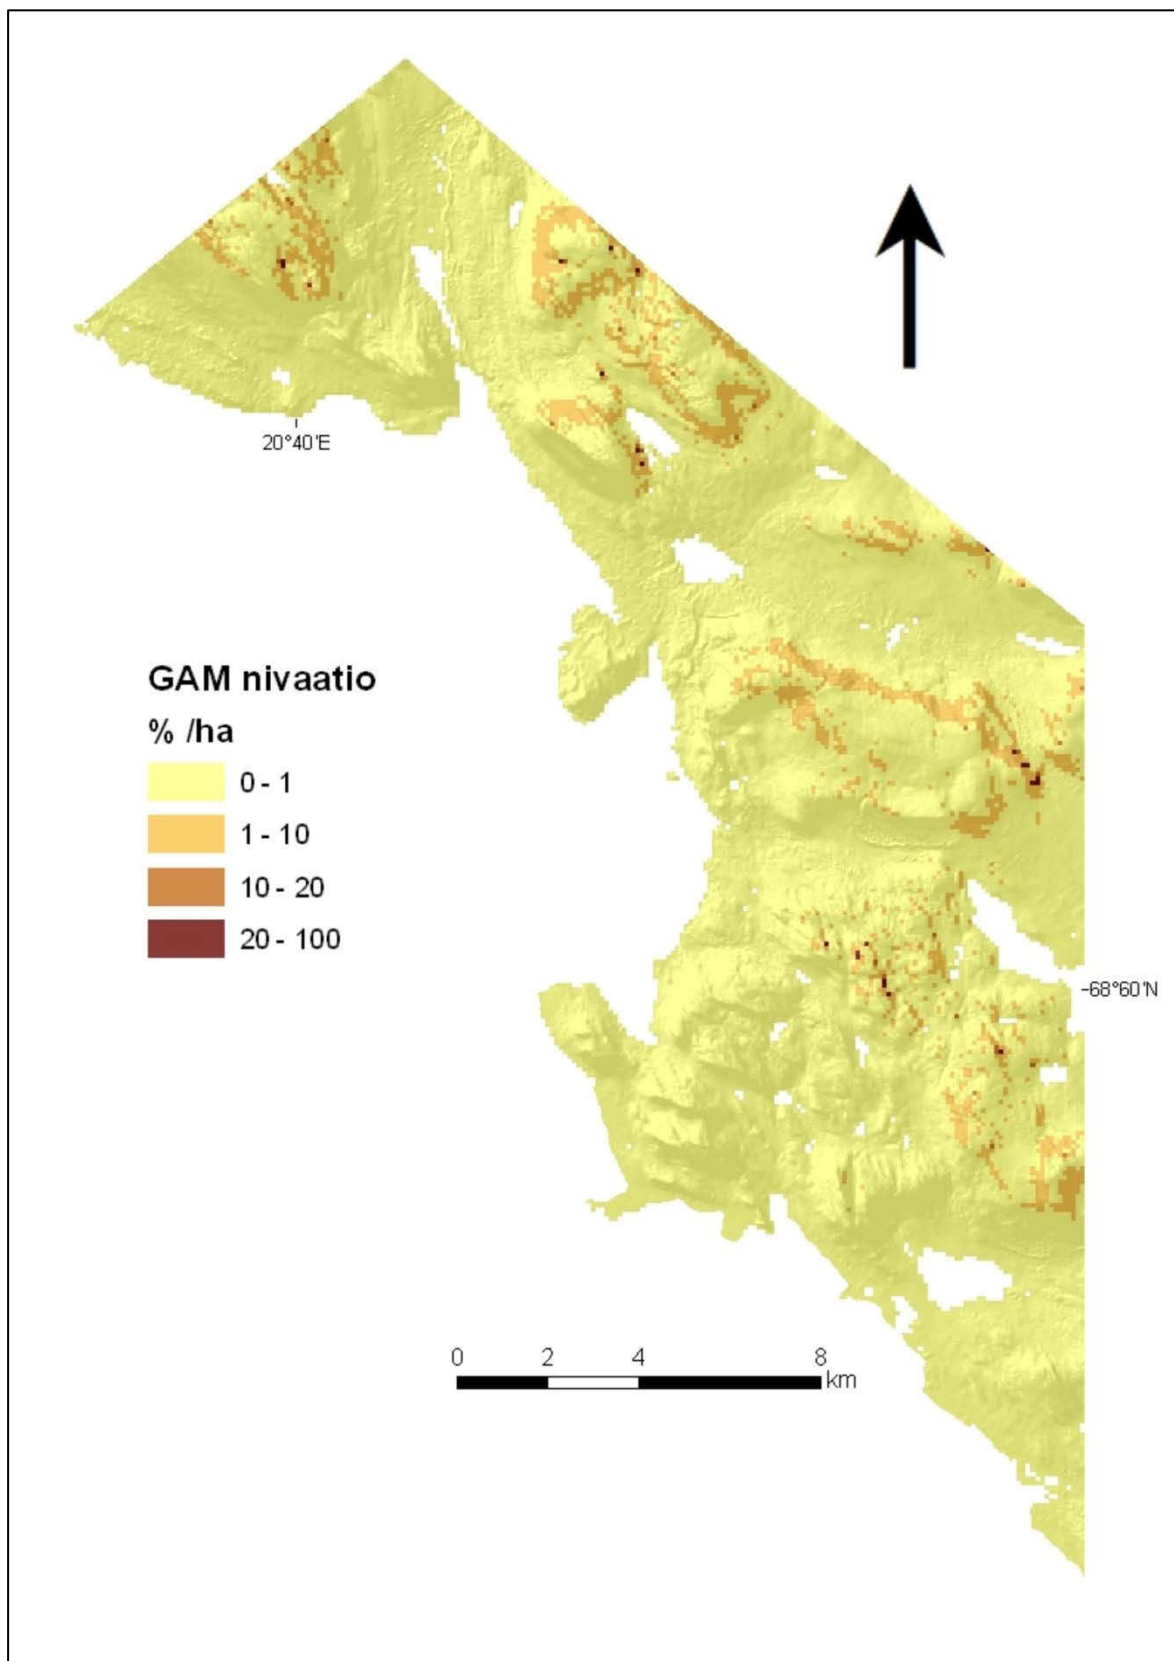
Liite 11. Ennustettu deflaation alueellinen esiintyminen perustuen GAM-malliin.



Liite 12. Ennustettu nivaation alueellinen esiintyminen perustuen GLM-malliin.

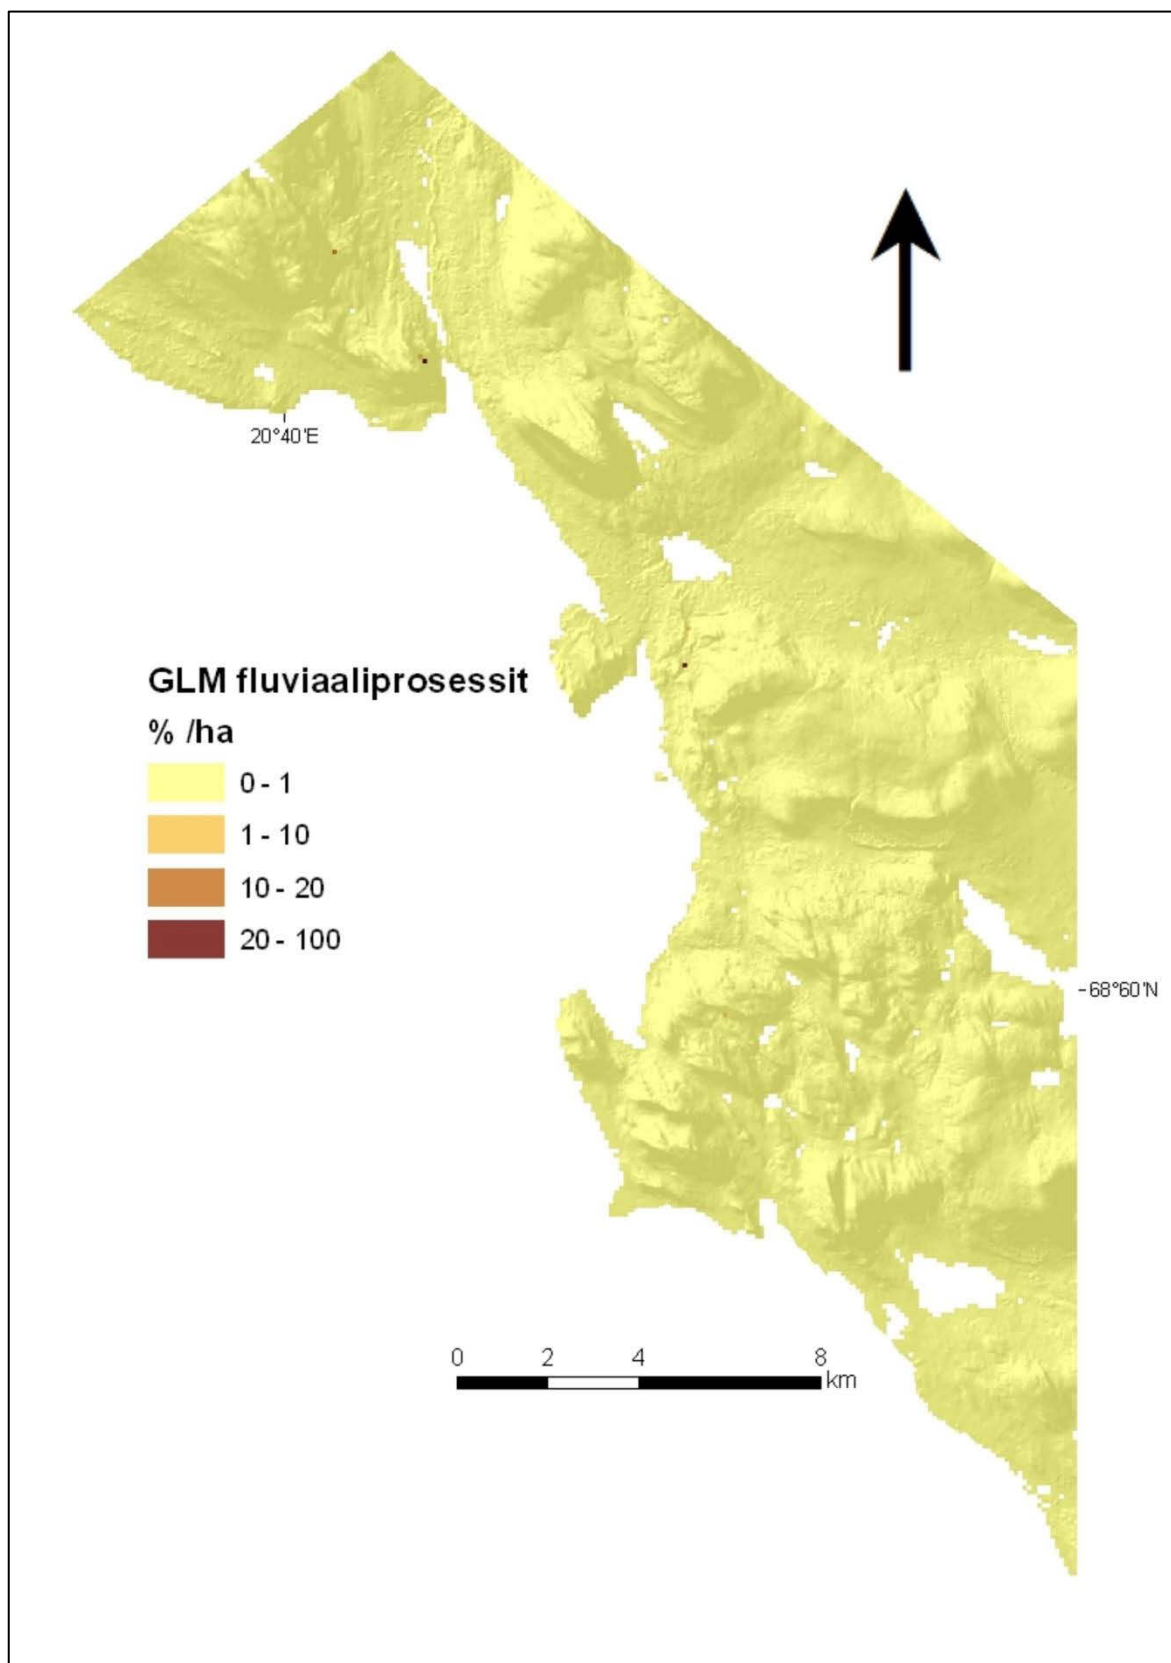


Liite 13. Ennustettu nivaation alueellinen esiintyminen perustuen GAM-malliin.





Liite 14. Ennustettu fluviaaliprosessien alueellinen esiintyminen perustuen GLM-malliin.



Liite 15. Ennustettu fluviaaliprozessin alueellinen esiintyminen perustuen GAM-malliin.

