

Loodusdirektiivi metsaelupaikade kaardistamise võimalused kasutades kaugseire andmeid ja masinõppe meetodeid

Keskkonnaagentuur, eluslooduse osakond (koostaja: Meelis Leivits)

16. veebruar 2022. a.

Kokkuvõte

Kaugseireandmed koos masinõppe meetoditega pakuvad laialdaseid võimalusi loodusdirektiivi metsaelupaikade kaardistamisel. Töö käigus koostati mudelprognoosid kümne elupaigatüübi esinemisala-
dele kasutades masinõppe meetodit nimega *MAXENT*. Elupaigatüüpide esinemisalade hindamiseks pakuti
välja erinevaid esinemislävendeid ning arutati nende põhjal välja erinevad esinemisalad. Kuigi mudelite
täpsushinnangud osutusid küllalt kõrgeks, siis tuleb olla ettevaatlik enamlevinud tüüpide (9010 ja 9080)
ja väga haruldaste tüüpide (9180, 91E0, 91F0) mudelite põhjal hinnatud esinemisalade kasutamisel, kuna
esimesel juhul täheldati esinemisalade alahinnangut ning haruldaste tüüpide puhul esinemisalade ülehinnangut.
Kuna mudelite valideerimisel ja esinemislävendite hindamisel kasutati kehtivaid inventeeritud metsaelupaiku,
siis ei ole välistatud, et ala- ja ülehinnanguid põhjustavad teatud määral kehtivates elupaikades esinevad
valemäärangud.

Töö tulemusena loodi metsaelupaikade potentsiaalset esinemist kirjeldav koondkaart. Metsaelu-
paikade inventeerimise kavandamisel ja metsaelupaiga esinemise hindamisel on mõistlik kasutada kõigi
elupaigatüüpide potentsiaalsetest esinemisaladest sünteesitud koondkaarti. Kuna leiti, et esinemisklassi 1
puhul alahinnatakse enamlevinud elupaikade (9010, 9080) pindala ning ülehinnatakse haruldasemate elupaika-
de pindala, siis koostati selline sünteeskaart lähtuvalt erinevatest esinemisklassidest, esinemisklasside 1+2
esinemisaladest lähtuvalt.

Metsaelupaikade mudeleid tuleb täpsustada. Osade haruldasemate elupaigatüüpide puhul (9180, 91E0,
91F0) ilmnes vaatamata kõrgetele täpsushinnangutele vajadus täpsustada või lisada mudelisse keskkonna-
tunnuseid, mis prognooside täpsust tõstaksid. Paljude mudelite puhul ilmnes küllalt suur metsakorralduslike
parameetrite panus, mistõttu ei pruugi mudelid eriti hästi ennustada elupaiku aladele, kus takseerandmed on
puudlikud.

Metsaelupaikade modelleerimist tuleb edasi arendada. Metsaelupaikade esinemise modelleerimisel tuleks
uurida alternatiivseid lähenemisi – taimkatte kasvukohatüüpide esinemise ja seisundi modelleerimise võimalusi.
Võimalik, et kasvukohtade esinemist modelleerides ning tulemusi elupaigatüübiks ümber klassifitseerides on
võimalik saada täpsemaid tulemusi. Lisaks tüübi esinemise hindamisele tuleks uurida ka seisundi modelleerimise
võimalusi. Kuna paljudes mudelites oli metsakorralduslike parameetrite panus suur, tuleks katsetada mudeleid,
mis ei kasuta metsakorralduslike parameetreid ning tuginevad vaid sattelliidipiltidest ja aerolaserskaneerimise
andmetest saadud tuletistele.

Sisukord

Sissejuhatus	2
Metoodika	2
Õpetusvalim	2
Keskkonnamuutujad	3
Mudelite sobitamine	4

Mudeli tundlikkus- ja kalibreerimine	5
Tulemused	9
Elupaigamudelid	9
Mudelite valideerimine	30
Esinemislävendid	40
Tulemuste analüüs	47
Pindala	47
Kattuvus	48
Arutelu	50
Kasutatud allikad	54

Sissejuhatus

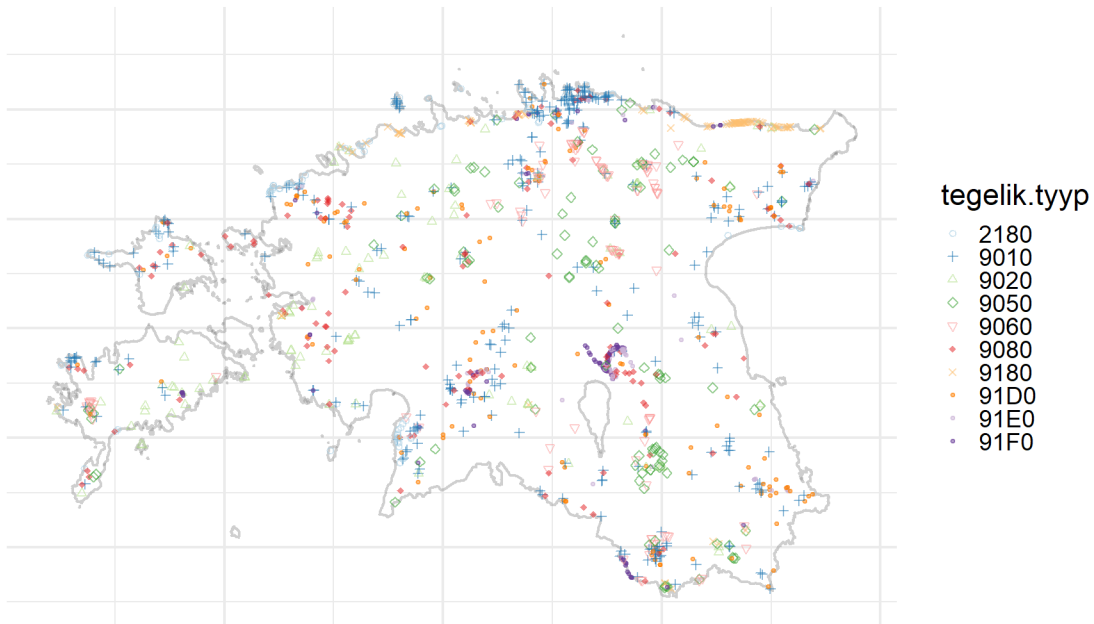
Liikide (elupaikade) leviku mudeliteks (*species distribution models*, SDMs) nimetatakse teatud hulka statistilisi mudeleid, mis kirjeldavad, kuidas keskkonnamuutujad (*environmental variables*) seostuvad nähtuse geograafilise levikuga (Guisan and Zimmermann 2000; Franklin 2010). Klassikaliste meetodite, nagu üldistatud lineaarne mudel (GLM) ja üldistatud additiivne mudel (GAM) asemel kasutatakse nähtuse esinemise modelleerimisel enamasti masinõppe või tehisõppe (*machine learning*) meetodeid. Selle põhjuseks on asjaolu, et reeglina on nähtuse esinemist ja seda prognoosivate tunnuste vahel tegu mittelineaarsete seostega. Laialdasest valikust masinõppe meetoditest on esile tõusnud maksimaalse entroopia (*maximum entropy*, *Maxent*) nimeline meetod (S. Phillips, Dudík, and Schapire 2004; S. J. Phillips, Anderson, and Schapire 2006; Elith et al. 2010). *Maxent* edu üheks põhjuseks on omadus, et see vajab mudeli õpetamiseks ainult liigi esinemisandmeid ning leiab uuritava ja prognoosivate tunnuste vahelised keerukad seosed automaatselt. Lisaks leiuandmetele vajab *Maxent* ka keskkonnamuutujaid kirjeldavaid rasterkaarte kogu uurimisala ulatuses. Viimase põhjal genereeritakse taustapunktid (*background*), millel koos leiuandmetega on keskne roll *Maxent* jaotuse genereerimisel. Mudelite alusel on arvatud leviku prognooskaardid. Leviku prognooskaardid kirjeldavad liigi või liigi elupaiga esinemise tõenäosust (väärtuste vahemikus 0..1) rasterkaardi pikslis.

Metoodika

Õpetusvalim

Mudeli õpetamiseks kasutati aastate 2010-2020 metsaelupaikade seire käigus kogutud andmeid. Elupaigatüübi mudeli treenimiseks valiti seirepunktidest vaid need, kus seiraja oli punktis esinevaks **tegelikuks elupaigatüübiks**

määratud uuritava elupaigatüübi. Õpetusvalimist kõigi tüüpide kohta annab ülevaate allolev joonis 1.



Joonis 1: Ülevaade õpetusvalimist.

Keskkonnamuutujad

Keskkonnamuutujate valik tehti kokku 27 kaardandmetest arvatatud muutuja (mullakaart, metsa takseerandmed, Ladsat 8 satelliitpildid, LiDAR-kõrgusandmed) seast kasutades võimendatud otsustuspuude (*Generalized Boosted Regression Models*) algoritmi (Greenwell et al. 2020). Keskkonnamuutujatena kasutati järgnevaid kaardikihte:

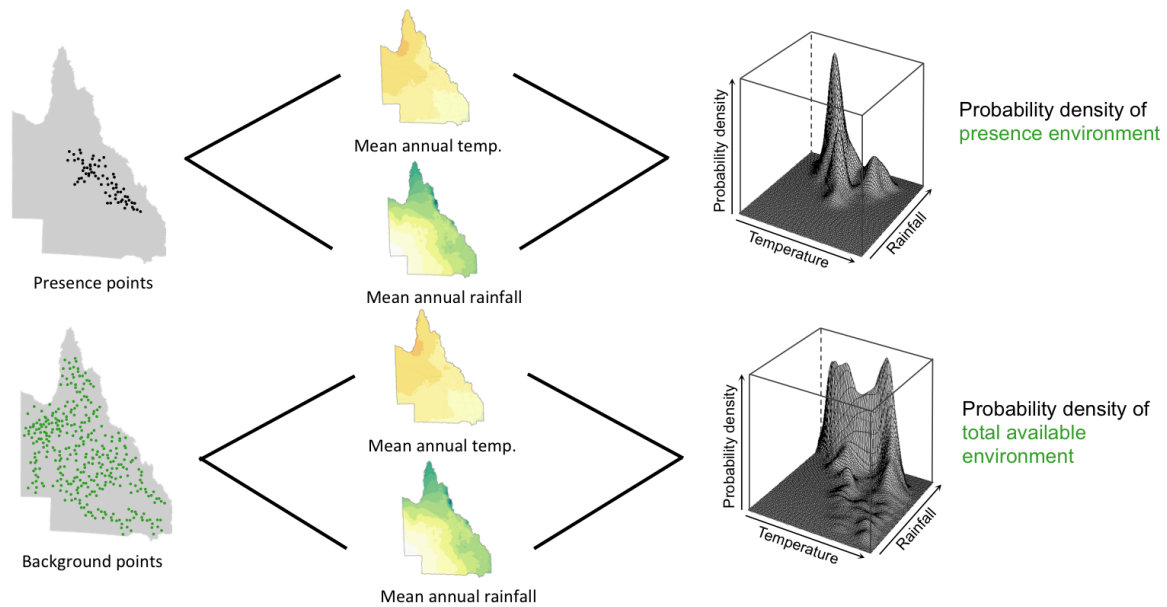
- metsakasvukohatüüp, kategooriline tunnus, N=29 (er19kktmuld)
- puuliigi vanus 1. rindes
- puuliigi osakaal 1. rindes
- peapuuliigi vanus (envanus19)
- LiDAR taimkatte katvus ehk taimkatte tagasipeegelduspunktide suhe kõigisse tagasipeegeldustesse (tvc)
- LiDAR taimkatte tagasipeegelduspunktide maksimaalne kõrgus maapinnast (hmax)
- LiDAR taimkatte tagasipeegelduspunktide keskmine kõrgushälve (hmax)
- Taimkattetagasipeegelduste protsent kõrgusvahemikus 2,5-10 m (p2m5h10)

- Taimkattetagaspiveegelduste protsent kõrgusvahemikus 1-2,5 m (p1h2m5)
- Taimkattetagaspiveegelduste protsent kõrgusvahemikus 0-1 m (p0h1)
- LiDAR reljeefi keerukus (curvature12)
- LiDAR nõlvakalle (slope12)
- Landsat 8 OLI-sensori tagaspiveegeldusarv neljas lainelas (lähi-infrapunase ehk NIR ning punase, rohelise ja sinise valguse lainelas).

Mudelite sobitamine

Käesolevas on leviku mudelite treenimisel kasutatud masinõppe meetodit nimega *Maxent*. Maxent vajab mudeli sobitamiseks vaid esinemisandmeid. Lihtsamate statistiliste mudelite ja ka masinõppe meetodite puhul kasutatakse puudumispunktidenähtuse esinemise kohta olemasolevatele teadmistele (nt kirjandusallikad) tuginedes genereeritud puudumisi ehk nn pseudo-puudumispunkte. Maxent eristub selles osas, kuna kasutab puudumiskohtade kirjeldamiseks kogu keskkonda. Keskkond määratakse nn taustapunktidega, mis seisneb selles, et üle terve keskkonnatunnuseid kirjeldavate rasterkihtide genereeritakse suur hulk juhupunkte. Kuna taustapunktid võivad hõlmata kohti, kus liik teadaolevalt esineb, ei ole taustapunktid samaväärsed pseudo-puudumispunktidega. Nähtuse esinemist kirjeldava valimi ja keskkonda kirjeldava valimi põhjal arvutab Maxent-algoritm kaks tõenäosustihedust, mille jagamisel saadakse suhtelist keskkonnasobivust kirjeldav tõenäosustihedus.


$$P^*(z(x_i)) = \frac{e^{z(x_i)\lambda}}{\sum_i e^{z(x_i)\lambda}}$$




Joonis 2: Esinemist ja keskkonda kirjeldavate jaotuste tekkepõhimõte Elith et al (2010).

Mudeli tundlikkus- ja kalibreerimine

Mudeli ning keskkonnamuutujate põhjal on võimalik arvutada tõenäosuskaarte. Tõenäosuskaartide tõlgendamisel on siiski kaks olulist probleemi, mis tuleb ületada. Esiteks, mudeli prognoositud esinemistõenäosustele on ilma neid kontrollandmetega valideerimata keeruline objektiivset sisu anda. Näiteks prognoositud tõenäosus ei pruugi alati tähendada seda, et pikslis väärtusega 0,5 on nähtuse leidmise tõenäosus 50%. Haruldaste nähtuste puhul võib esineda olukordi, kus näiteks kaardipikslis mudeli prognoositud tõenäosusega 0,2 on tegelikkuses nähtuse esinemissagedus 0,8 (joonis 3a). Seega, tõenäosuste skaalale objektiivse tõlgenduse andmiseks tuleb mudeli prognoositud tõenäosuseid võrrelda nähtuse tegeliku esinemissagedusega.




(a) Harvaesinev nähtus.



(b) Sagedasti esinev nähtus.

Joonis 3: Näide prognoositud esinemistõenäosuste (x-teljel) ja tegeliku esinemissageduse (y-teljel) vahel. Vasakul on kirjeldatud suhteliselt harvaesineva nähtuse kalibratsioonidiagramm, kust on näha, et nähtuse leidmise sagedus on väga kõrge juba üsna madalate prognoosi väärtuste juures ($>0,2$). Paremal on kirjeldatud suhteliselt sagedasema nähtuse kalibratsioonidiagrammi, kus tegelik esinemissagedus on tunduvalt lähemal diagonaalile.

Teisalt, mudeli prognooskaart annab ruumilise ülevaate uuritava nähtuse esinemistõenäosusest kaardipikslites. Saadav tõenäosuskaart võimaldab küll visuaalselt hinnata, millistes piirkondades võib uuritavat nähtust suure tõenäosusega leida, kuid inventuuride kavandamiseks kui ka juba läbi viidud inventuuride piisavuse hindamiseks on vajalik tõenäosused teisendada binaarseks klassifikatsiooniks ehk väärtusteks skaalas “esineb” ja “ei esine.” Mudeli prognoositud tõenäosuste kaardipildist esinemist kirjeldava klassifikatsioonikaardi ehk esinemiskaardi saamiseks on vajalik hinnata nn esinemislävendit. Esinemislävendist kõrgema tõenäosusega kaardipikslite põhjal saab arvutada nähtuse esinemisalasid ja levikut kirjeldavaid kaarte. Esinemislävendi leidmiseks on vajalik läbi viia mudeli tundlikkusanalüüs, mille käigus hinnatakse erinevate statistikute abil valitud esinemislävendi ja antud kontrollandmete vahelist kooskõla.



(a) Prognooskaart. Tõenäosused 0..1 on värvitud valgest punaseni. (b) Esinemiskaart. Esinemisalad on värvitud punaseks.

Joonis 4: Näide prognooskaardist ja selle põhjal tuletatud esinemiskaardist.

Kontrollandmeteks on valitud elupaigainventuuride käigus registreeritud elupaigad seisuga . See tähendab, et **kontrollitud esinemistena** on käsitletud elupaigainventuuride käigus tuvastatud elupaiku kus oli **põhitüübina** tuvastatud uuritav elupaigatüüp ning esinduslikkusena oli märgitud A, B või C. Nende nn kontrollitud esinemistega on võimalik anda hinnang prognoosi tundlikkusele, st õietiennustatud esinemiste sagedusele. Lisaks õietiennustatud esinemistele on vajalik hinnata prognoositud tõenäosuste tundlikkust mitte-esinemise suhtes. Selleks on genereeritud väljaspoole inventeeritud elupaiku juhupunktid (nn tinglikult kontrollitud nullid). Mõlemal juhul genereeriti valimi suuruseks $N=3000$ punkti.

Esinemislävendi valikul on lähtutud esinemissagedusest, mida hinnati kalibratsioonidiagrammi andmete põhjal. Prioritiseerimise huvides genereeriti iga tüübi kohta kolm lävendit, millest igaüks annab erineva esinemiskaardi. Nendeks lävenditeks valiti 0,5, 0,8 ja 0,95. Vastavalt neile vahemikele on defineeritud esinemisklassid ning neile vastavad esinemiskaardid:

- Esinemisklass = 3 $\Rightarrow 0,5 < \text{esinemissagedus} \leq 0,8$;
- Esinemisklass = 2 $\Rightarrow 0,8 < \text{esinemissagedus} \leq 0,95$;

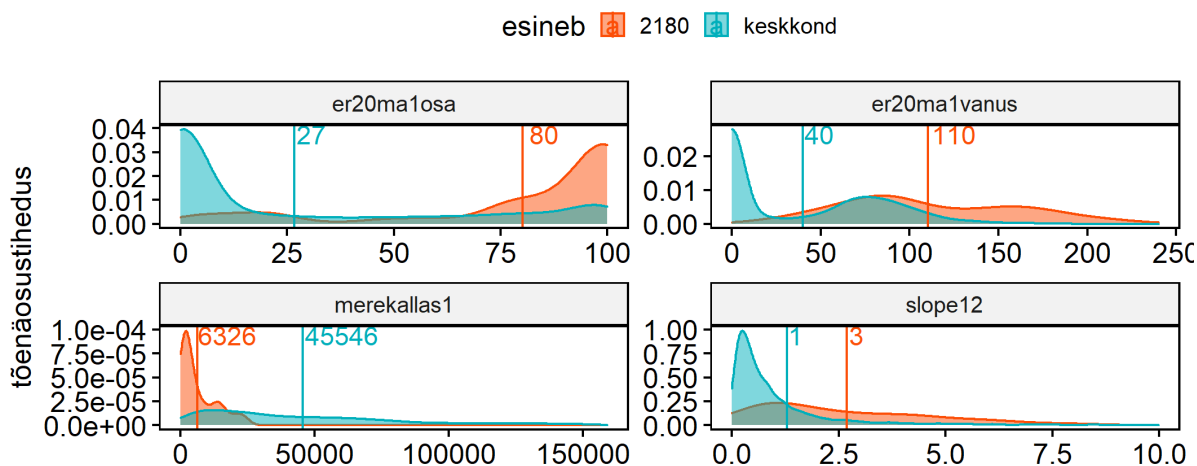
- Esemisklass = 1 \Rightarrow $0,95 < \text{esemissagedus} \leq 1$.

Tulemused

Elupaigamudelid

2180 metsastunud luited


Õpetuspunktideks õnnestus kasutada $N=56$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 6527 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist $N=14$ punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli regulariseeritud kasumlikkuseks (*regularized gain*) ehk võimenduseks saadi 3,31, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{3,31} \sim 27,40$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Mida suurem on võimenduse väärtus, seda paremini eristuvad suurt tõenäosust kirjeldavad pikslid taustast. Õpetusandmete AUC-väärtuseks saadi 0,991. Testandmete AUC väärtuseks saadi 0,984.




Joonis 5: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 1: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis. Muutuja suhtelist panust võimendusse (panus) määratakse nii, et õpetusalgoritmi lisatakse igas iteratsioonis võimenduse kasv vastava muutuja panusele ning teisendatakse protsendiks. Tähtsust hinnatakse test- ja õpetusandmeid juhuslikult ümber järjestades valitud andmetele sobitatud mudeli ennustustäpsuse hinnangu (AUC) languse põhjal, normeerides selle protsent-skaalasse.

Muutuja	Panus	Tähtsus
Metsakasvukohatüüp (er19kktmlud)	48	27
Kaugus mererannikust ja Peipsi järve põhjakaldast (merekallas1)	21	58
Männi osakaal 1. rindes (er20ma1osa)	16	0,52
Nõlvakalle (slope12)	7,4	4,4
Männi vanus 1. rindes (er20ma1vanus)	5,1	6,6
Kuuse vanus 1. rindes (er20ku1vanus)	2,3	0,67
Tagasipeegeldusarv sinise valguse lainealas (oli01)	0,53	0,28
Kuuse osakaal 1. rindes (er20ku1osa)	0,42	1,1
Enamuspuuliigi vanus (envanus19)	0,14	0,59
Taimkattepunktide ja maapinnapunktide suhe (liituvus) (tvc)	0,12	0,0031
Tagasipeegeldusarv rohelse valguse lainealas (oli02)	0,058	0,26
Tagasipeegeldusarv lähi-infrapuna lainealas (oli04)	0,04	0,52
Reljeefi keerukus (curvature12)	0,035	0,022
Taimkatte maksimaalne kõrgus (hmax)	0,004	0,034
Tagasipeegeldusarv punase valguse lainealas (oli03)	0	0



(a) Kasvukohatüüp. (b) Kaugus kaldajoonest (c) Männi osakaal 1. rindes. (meri ja Peipsi põhjarannik.



(d) Nõlvakalle. (e) Männi vanus 1. rindes. (f) Kuuse vanus 1. rindes.

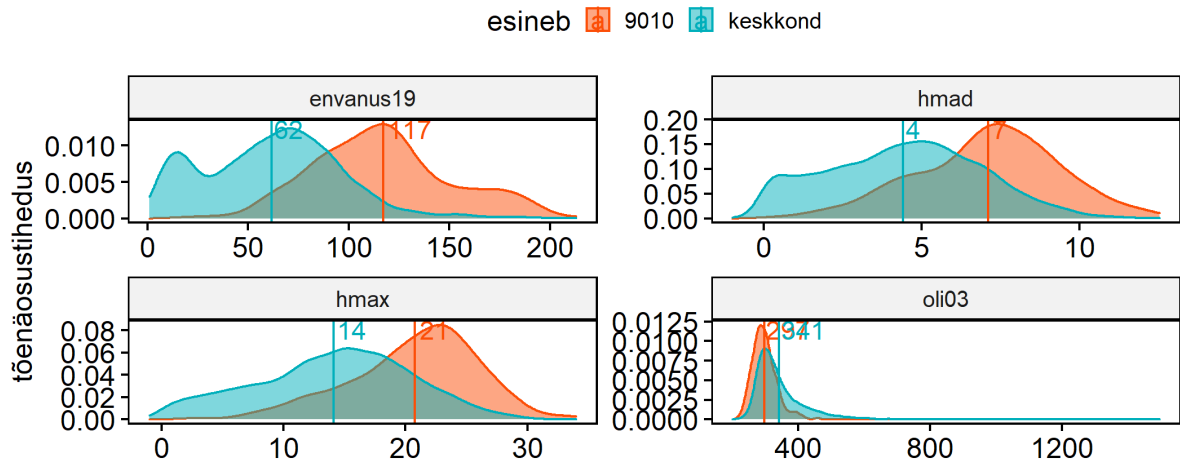
Joonis 6: Olulisemate keskkonnamuutujate jaotused. Ordinaatteljel on esitatud esinemise tõenäosus cloglog teisenduses $1 - e^{-e^p}$.



Joonis 7: Elupaigatüübi 2180 prognooskaart. Värvusskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

9010 vanad looduspetsad


Õpetuspunktideks õnnestus kasutada $N=196$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 5024 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist $N=49$ punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli võimenduseks saadi 1,36, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{1,36} \sim 3,89$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,911. Testandmete AUC väärtuseks saadi 0,895.



Joonis 8: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 2: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.

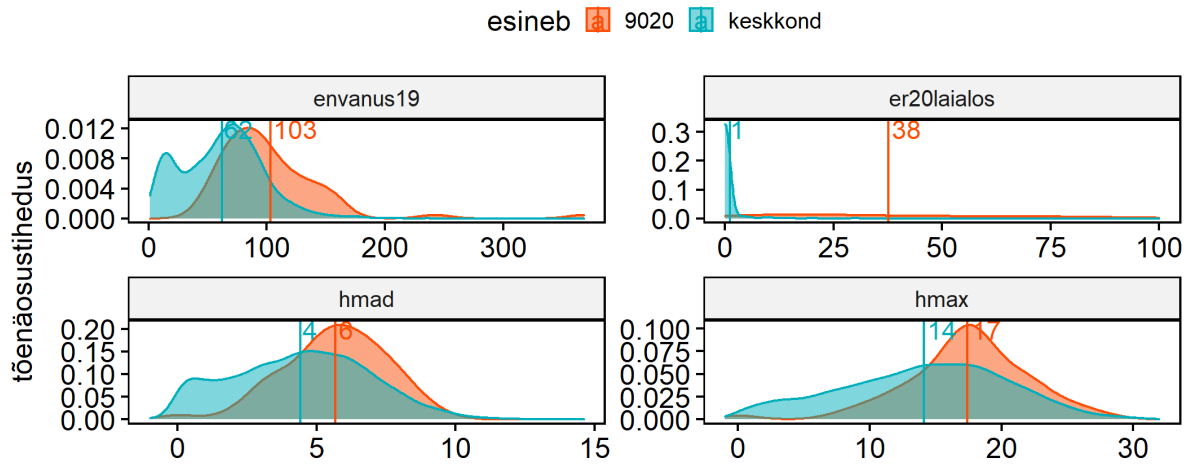
Muutuja	Panus	Tähtsus
Enamuspuuliigi vanus (envanus19)	70	72
Metsakasvukohatüüp (er19kktmuld)	13	14
Keskmine kõrgushälve (hmad)	11	6
Taimkatte maksimaalne kõrgus (hmax)	4,9	0,99
Tagasipeegeldusarv punase valguse lainelas (oli03)	1,2	4,8
Taimkattepunktide ja maapinnapunktide suhe (liituvus) (tvc)	0,28	1,7
Tagasipeegeldusarv rohelse valguse lainelas (oli02)	0,23	0,13
Tagasipeegeldusarv sinise valguse lainelas (oli01)	0,17	0
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	0,036	0,088



Joonis 9: Elupaigatüübi 9010 prognooskaart. Värvuskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

9020 vanad laialehised metsad


Õpetuspunktideks õnnestus kasutada $N=51$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 4800 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist $N=12$ punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli võimenduseks saadi 2,97, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{2,97} \sim 19,48$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,981. Testandmete AUC väärtuseks saadi 0,966.



Joonis 10: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 3: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.

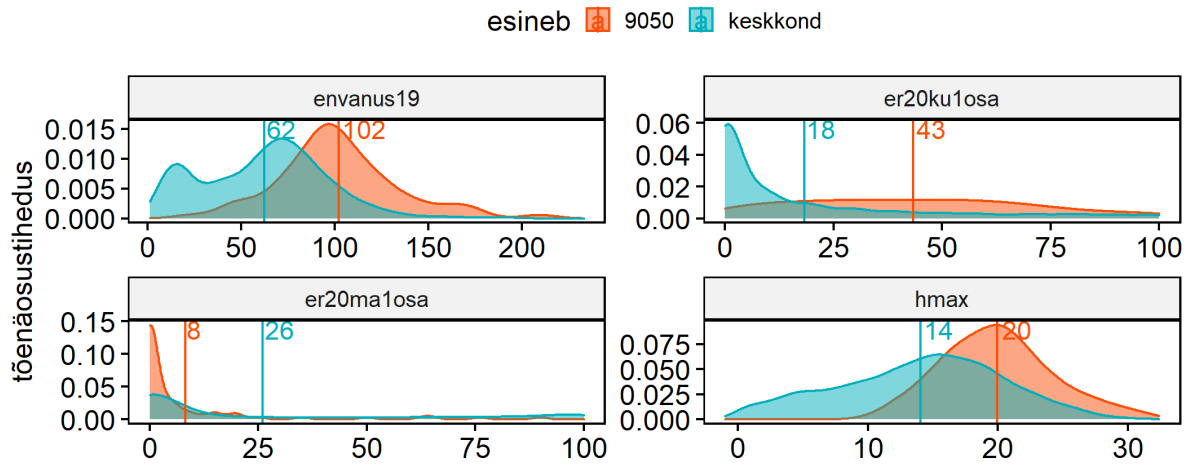
Muutuja	Panus	Tähtsus
Saare, vahtra, tamme osakaal 1. rindes (er20laialos)	83	79
Enamuspulüügi vanus (envanus19)	7,8	11
Metsakasvukohatüüp (er19kktnuld)	4,4	5,5
Keskmine kõrgushälve (hmad)	2,1	1,4
Taimkatte maksimaalne kõrgus (hmax)	1,2	0
Tagasipeegeldusarv punase valguse lainelas (oli03)	0,63	0
Tagasipeegeldusarv rohelse valguse lainelas (oli02)	0,37	3
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	0,092	0,22
Tagasipeegeldusarv sinise valguse lainelas (oli01)	0,061	0,63



Joonis 11: Elupaigatüübi 9020 prognooskaart. Värvusskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

9050 rohunditerikkad kuusikud


Õpetuspunktideks õnnestus kasutada $N=59$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 4747 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist $N=14$ punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli võimenduseks saadi 1,94, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{1,94} \sim 6,93$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,954. Testandmete AUC väärtuseks saadi 0,921.



Joonis 12: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 4: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.


Muutuja	Panus	Tähtsus
Enamuspuuliigi vanus (envanus19)	32	19
Kuuse osakaal 1. rindes (er20ku1osa)	25	8
Männi osakaal 1. rindes (er20ma1osa)	14	15
Metsakasvukohatüüp (er19kktmuld)	12	9,5
Taimkatte maksimaalne kõrgus (hmax)	8,6	3,9
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	3,3	5,2
Taimkattetagasipeegelduste protsent kõrgusvahemikus 0-1 m (p0h1)	3,3	27
Tagasipeegeldusarv sinise valguse lainelas (oli01)	1,5	4,5
Tagasipeegeldusarv punase valguse lainelas (oli03)	0,62	1,8
Taimkattepunktide ja maapinnapunktide suhe (liituvus) (tvc)	0,32	6,7
Tagasipeegeldusarv rohelise valguse lainelas (oli02)	0,0043	0,016



Joonis 13: Elupaigatüübi 9050 prognooskaart. Värvusskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

9060 okasmetsad moreenkõrgendikel


Õpetuspunktideks õnnestus kasutada $N=89$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 6489 punkti (õpetuspunktid + taustapunktid). Mudeli võimenduseks saadi 2,53, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{2,53} \sim 12,61$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,975.



Joonis 14: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 5: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.

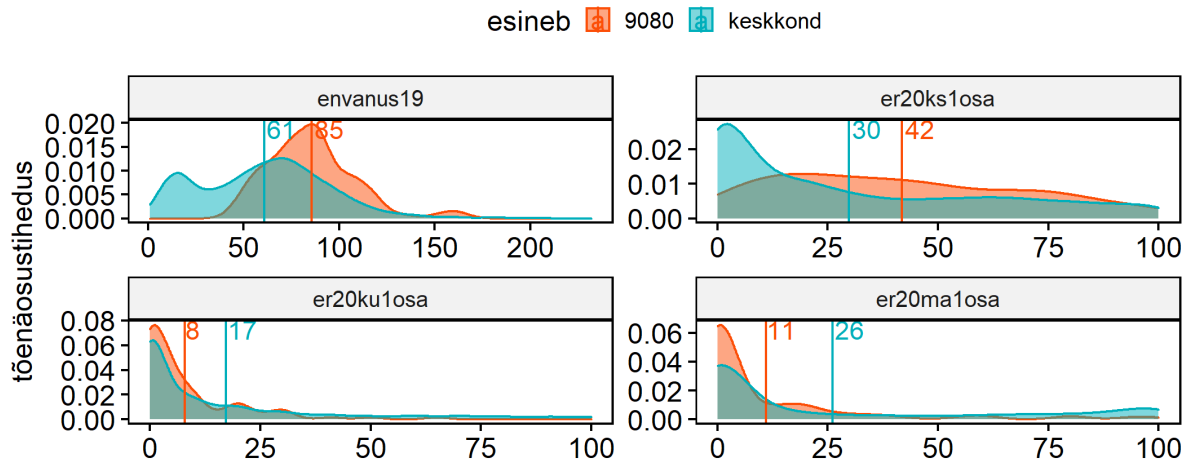
Muutuja	Panus	Tähtsus
Nõlvakalle (slope12)	41	24
Enamuspuuliigi vanus (envanus19)	27	42
Mullatüüp (muldvarv2)	11	5,5
Taimkatte maksimaalne kõrgus (hmax)	7,6	7,8
Keskmine kõrgushälve (hmad)	5,7	0,54
Taimkattetagasipegelduste protsent kõrgusvahemikus 2,5-10 m (p2m5h10)	2,2	10
Kaugus mererannikust ja Peipsi järve põhjakaldast (merekallas1)	2,1	3,1
Reljeefi keerukus (curvature12)	1,5	1,2
Tagasipegeldusarv sinise valguse lainelas (oli01)	0,85	4
Tagasipegeldusarv punase valguse lainelas (oli03)	0,26	0,6
Tagasipegeldusarv lähi-infrapuna lainelas (oli04)	0,18	0,72
Tagasipegeldusarv rohelise valguse lainelas (oli02)	0,13	0,33



Joonis 15: Elupaigatüübi 9060 prognooskaart. Värvuskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

9080 soostuvad- ja soo-lehtmetsad


Õpetuspunktideks õnnestus kasutada $N=76$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 4776 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist $N=18$ punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli võimenduseks saadi 1,47, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{1,47} \sim 4,33$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,934. Testandmete AUC väärtuseks saadi 0,903.



Joonis 16: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 6: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.

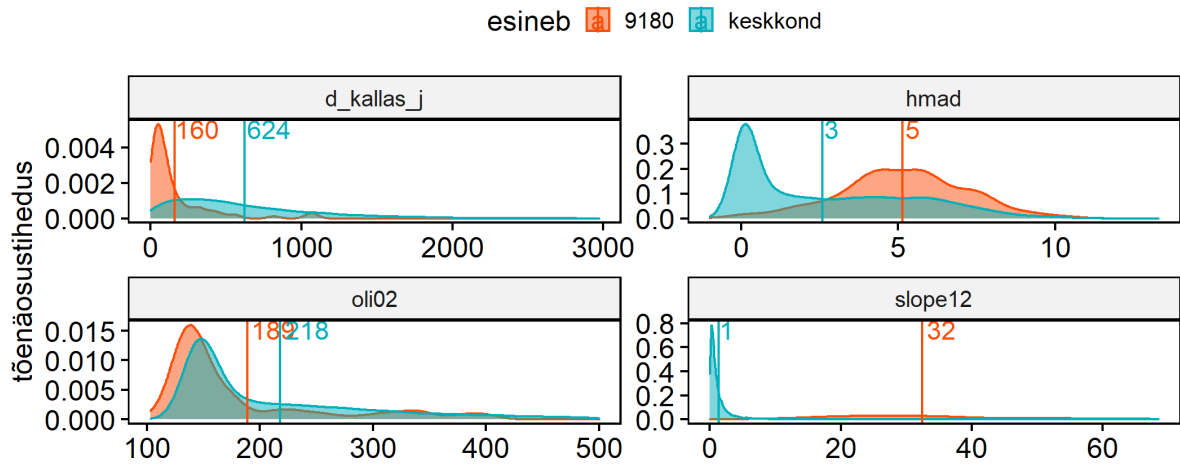
Muutuja	Panus	Tähtsus
Metsakasvukohatüüp (er19kktmuld)	39	23
Enamuspuuliigi vanus (envanus19)	31	30
Kase osakaal 1. rindes (er20ks1osa)	10	5,8
Männi osakaal 1. rindes (er20ma1osa)	7,6	22
Kuuse osakaal 1. rindes (er20ku1osa)	5,8	12
Taimkattepunktide ja maapinnapunktide suhe (liituvus) (tvc)	3,7	4,1
Taimkatte maksimaalne kõrgus (hmax)	1,5	2,2
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	0,56	0,11
Tagasipeegeldusarv sinise valguse lainelas (oli01)	0,052	0,35



Joonis 17: Elupaigatüübi 9080 prognooskaart. Värvuskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

9180 laialehised rusukaldemetsad

Õpetuspunktideks õnnestus kasutada $N=89$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 9815 punkti (õpetuspunktid + taustapunktid). Mudeli võimenduseks saadi 4,19, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{4,19} \sim 66,19$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,995.



Joonis 18: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 7: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.


Muutuja	Panus	Tähtsus
Nõlvakalle (slope12)	96	99
Mullatüüp (muldvarv2)	2,5	0,13
Kaugus kaldajoonest (d_kallas_j)	0,62	0,34
Tagasipeegeldusarv rohelse valguse lainelas (oli02)	0,32	0
Keskmine kõrgushälve (hmad)	0,31	0,11
Reljeefi keerukus (curvature12)	0,28	0,0044
Tagasipeegeldusarv sinise valguse lainelas (oli01)	0,14	0
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	0,0033	0,0081
Tagasipeegeldusarv punase valguse lainelas (oli03)	0,0022	0



Joonis 19: Elupaigatüübi 9180 prognooskaart. Värvusskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

91D0 siirdesoo- ja rabametsad


Õpetuspunktideks õnnestus kasutada $N=90$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 10070 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist $N=22$ punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli ehk võimenduseks saadi 2,15, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{2,15} \sim 8,61$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,971. Testandmete AUC väärtuseks saadi 0,924.



Joonis 20: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 8: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.

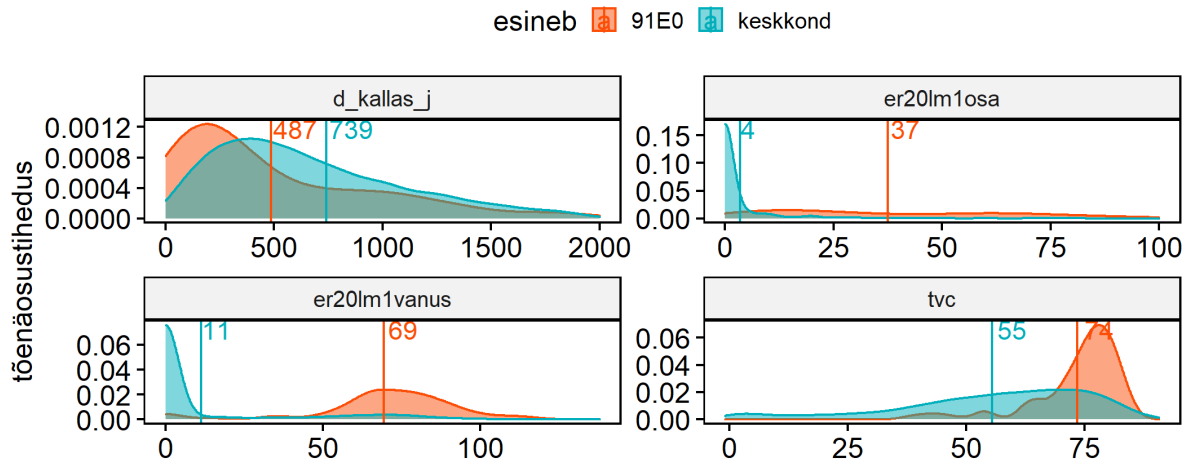
Muutuja	Panus	Tähtsus
Metsakasvukohatüüp (er19kktmuld)	74	65
Taimkattepunktide ja maapinnapunktide suhe (liituvus) (tvc)	18	27
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	5	2,1
Taimkatte maksimaalne kõrgus (hmax)	2,4	3,7
Tagasipeegeldusarv punase valguse lainelas (oli03)	0,55	1,8
Tagasipeegeldusarv rohelse valguse lainelas (oli02)	0,021	0,0015



Joonis 21: Elupaigatüübi 91D0 prognooskaart. Värvusskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

91E0 lammi- ja lodumetsad

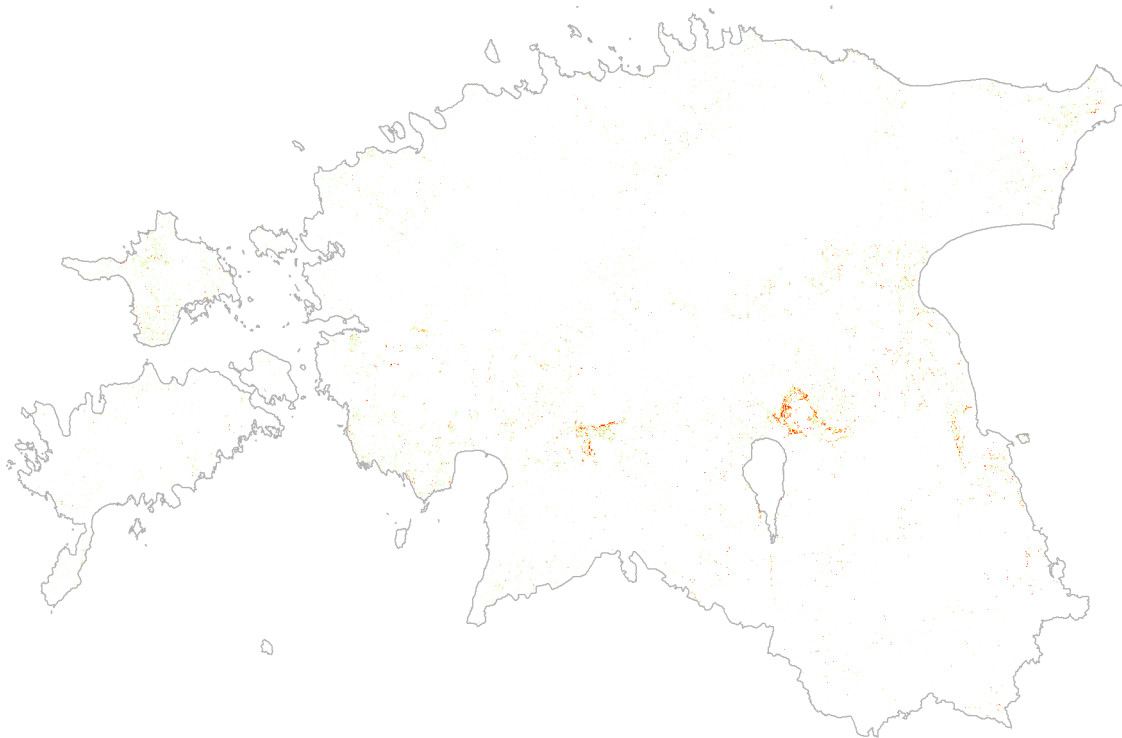
Õpetuspunktideks õnnestus kasutada N=70 punkti. *Maxent* jaotuse määramiseks kasutas algoritm 4758 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist N=17 punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli võimenduseks saadi 2,51, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{2,51} \sim 12,32$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,974. Testandmete AUC väärtuseks saadi 0,957.



Joonis 22: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 9: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.

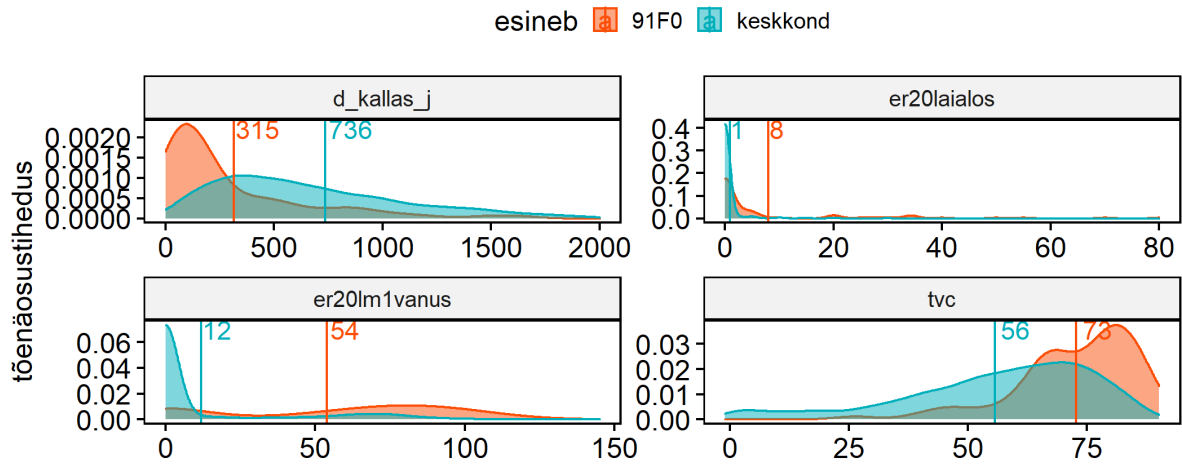
Muutuja	Panus	Tähtsus
Sanglepa osakaal 1. rindes (er20lm1osa)	35	53
Sanglepa vanus 1. rindes (er20lm1vanus)	33	0
Taimkattepunktide ja maapinnapunktide suhe (liituvus) (tvc)	10	12
Metsakasvukohatüüp (er19kktmuld)	10	2,9
Kaugus kaldajoonest (d_kallas_j)	5,4	3,9
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	2,5	0,59
Enamuspuuliigi vanus (envanus19)	1,9	25
Tagasipeegeldusarv punase valguse lainelas (oli03)	0,98	0,76
Tagasipeegeldusarv sinise valguse lainelas (oli01)	0,77	0,32
Tagasipeegeldusarv rohelse valguse lainelas (oli02)	0,4	1,6
Taimkatte maksimaalne kõrgus (hmax)	0,021	0,19



Joonis 23: Elupaigatüübi 91E0 prognooskaart. Värvusskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

91F0 uhtlammimetsad


Õpetuspunktideks õnnestus kasutada $N=68$ punkti. *Maxent* jaotuse määramiseks kasutas algoritm 4840 punkti (õpetuspunktid + taustapunktid). Mudeli headuse kontrolliks eristati esinemisvalimist $N=16$ punkti, mida kasutati mudeli esmaseks valideerimiseks. Mudeli võimenduseks saadi 2,35, mis tähendab, et esinemise proovidega pikslitel on *Maxent*-jaotus keskmiselt $e^{2,35} \sim 10,45$ korda suurema väärtusega kui, juhuslikult võetud taustapunktide pikslitel. Õpetusandmete AUC-väärtuseks saadi 0,974. Testandmete AUC väärtuseks saadi 0,960.



Joonis 24: Nelja keskkonnamuutuja tõenäosustihedus esinemisvalimis ja taustavalimis (keskkond).

Tabel 10: Keskkonnamuutujate suhtelised panused elupaiga Maxent mudelis.


Muutuja	Panus	Tähtsus
Kaugus kaldajoonest (d_kallas_j)	27	37
Sanglepa vanus 1. rindes (er20lm1vanus)	22	0,85
Saare, vahtra, tamme osakaal 1. rindes (er20laialos)	13	9,3
Metsakasvukohatüüp (er19kktmuld)	11	22
Taimkattepunktide ja maapinnapunktide suhe (liituvus) (tvc)	7,6	0,15
Taimkatte maksimaalne kõrgus (hmax)	5,5	5,9
Tagasipeegeldusarv lähi-infrapuna lainelas (oli04)	3,4	2,1
Haava vanus 1. rindes (er20hb1vanus)	2,6	0,083
Sanglepa osakaal 1. rindes (er20lm1osa)	2,1	3,6
Enamuspuuliigi vanus (envanus19)	2	8,7
Tagasipeegeldusarv rohelise valguse lainelas (oli02)	1,9	6,7
Kase osakaal 1. rindes (er20ks1osa)	0,58	1,6
Tagasipeegeldusarv punase valguse lainelas (oli03)	0,31	1,2
Haava osakaal 1. rindes (er20hb1osa)	0,14	0,22
Kase vanus 1. rindes (er20ks1vanus)	0,13	0
Tagasipeegeldusarv sinise valguse lainelas (oli01)	0,11	0,47




Joonis 25: Elupaigatüübi 91F0 prognooskaart. Värvuskaala kirjeldab esinemistõenäosusi vahemikus 0 (valge) kuni 1 (punane).

Mudelite valideerimine

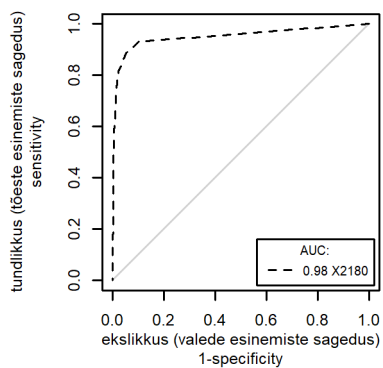
2180



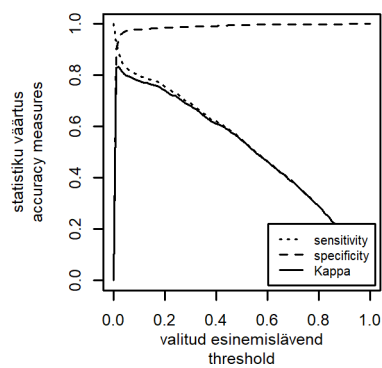
(a) Esinemiste histogramm.



(b) Kalibratsioonidiagramm.

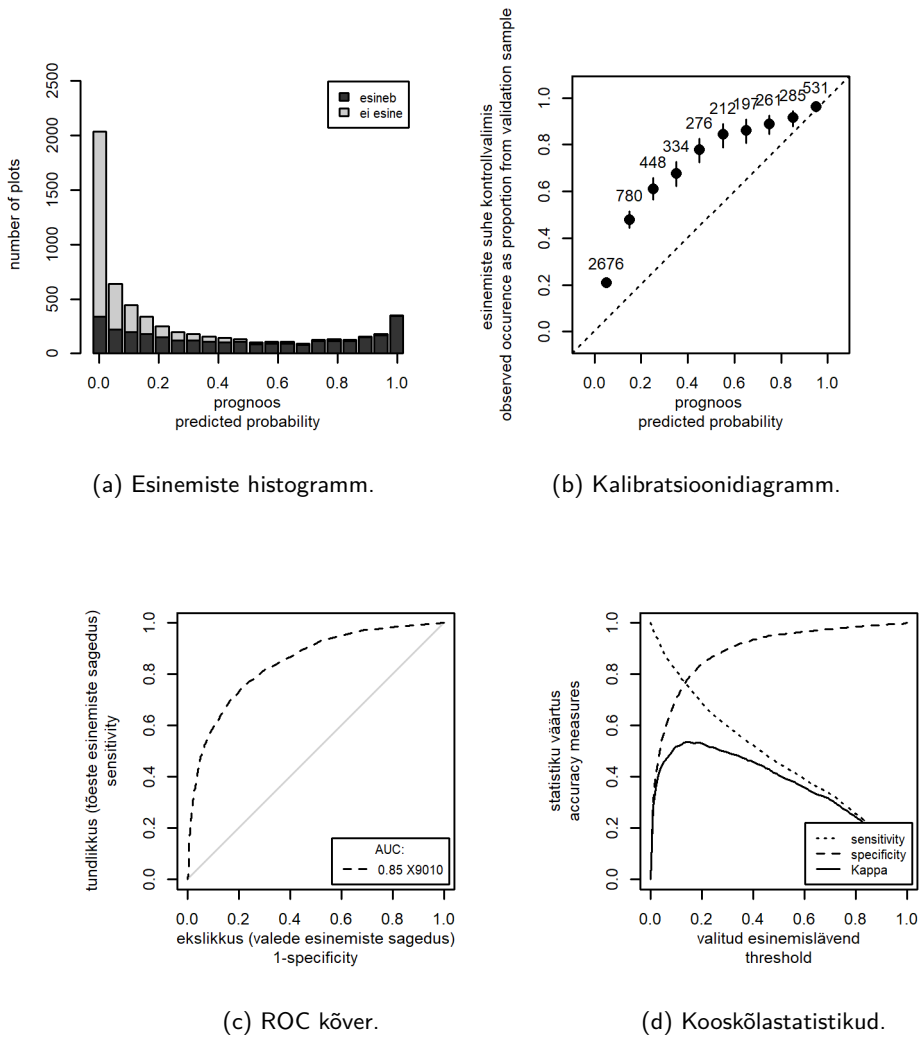


(c) ROC kõver.

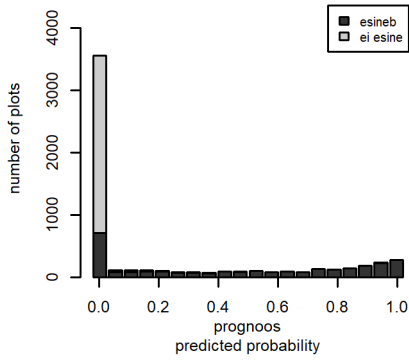


(d) Kooskõlastatistikud.


Joonis 26: Elupaigatüübi 2180 mudelprognosis ennustustäpsust kirjeldavad diagrammid. Esinemiste histogramm kontrollvalimis ehk kontrollvalimi esinemiste ja mitte-esinemiste vaatluste arv vastavalt mudeli prognoosile. Kalibratsioonidiagramm, mis kirjeldab esinemiste suhet kontrollvalimis sõltuvalt mudeli prognoosist esinemise tõenäosusele. ROC kõver, mis kirjeldab valestiennustatud esinemiste ehk ekslikkuse (false positive rate) ja õietiennustatud esinemiste ehk tundlikkuse (true positive rate) vahelist seost. Mudeli täpsust kirjeldavate statistikute: tõeste esinemiste sagedus (tundlikkus), tõeste mitte-esinemiste sagedus, Kappa-kordaja ning nende sõltuvus valitud esinemislävendi väärtusest.




Joonis 27: Elupaigatüübi 9010 mudelprognooosi ennustustäpsust kirjeldavad diagrammid.




(a) Esinemiste histogramm.



(b) Kalibratsioonidiagramm.

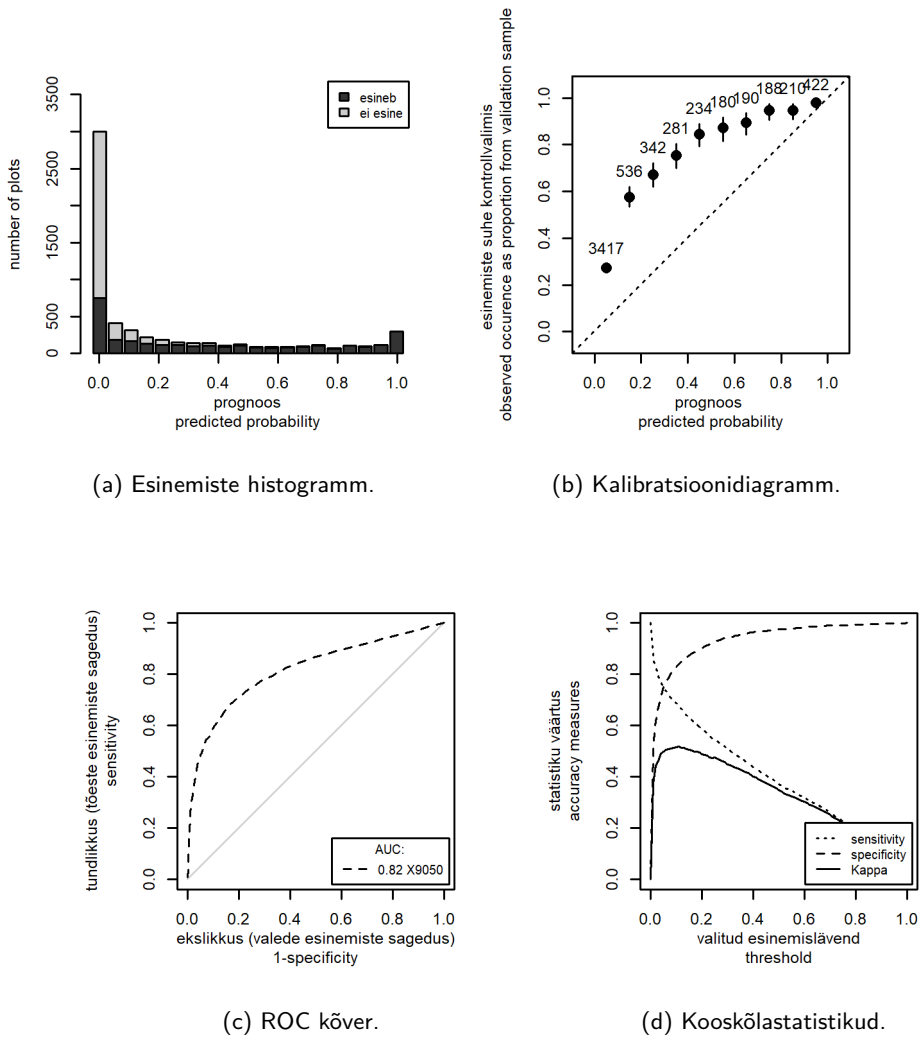


(c) ROC kõver.

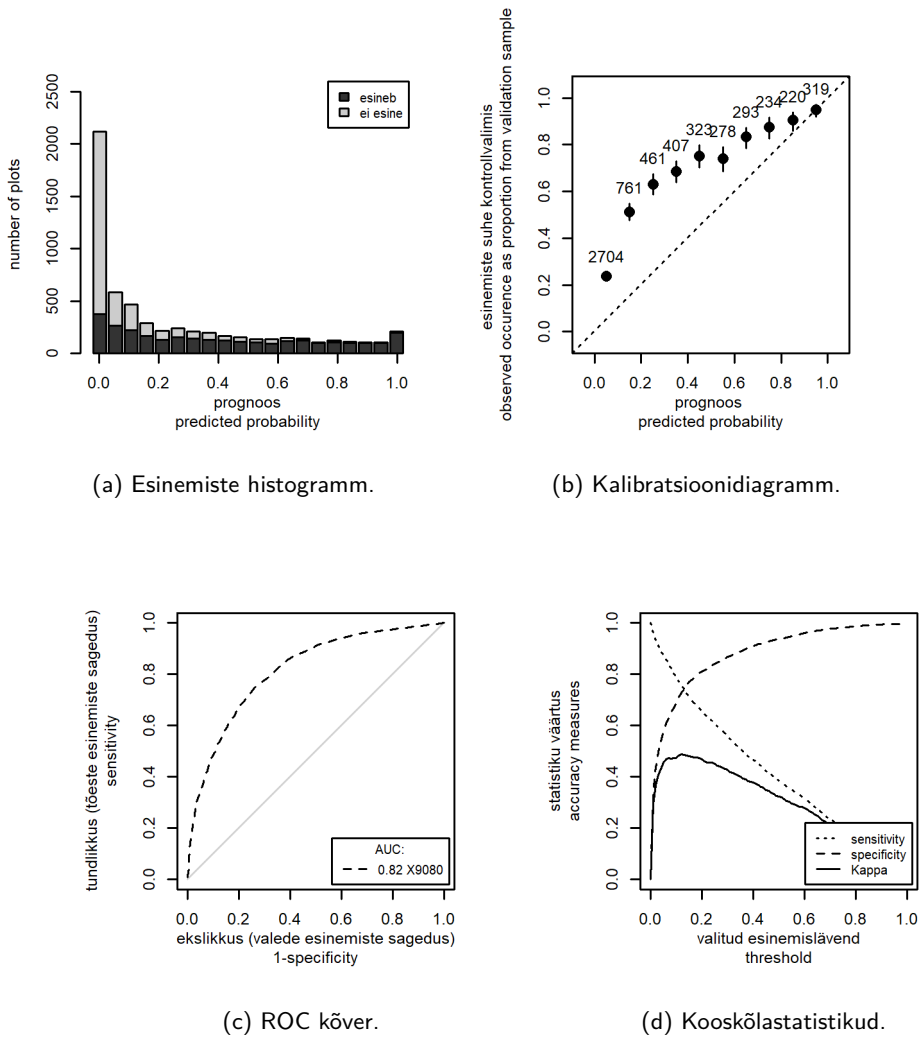


(d) Kooskõlastatistikud.

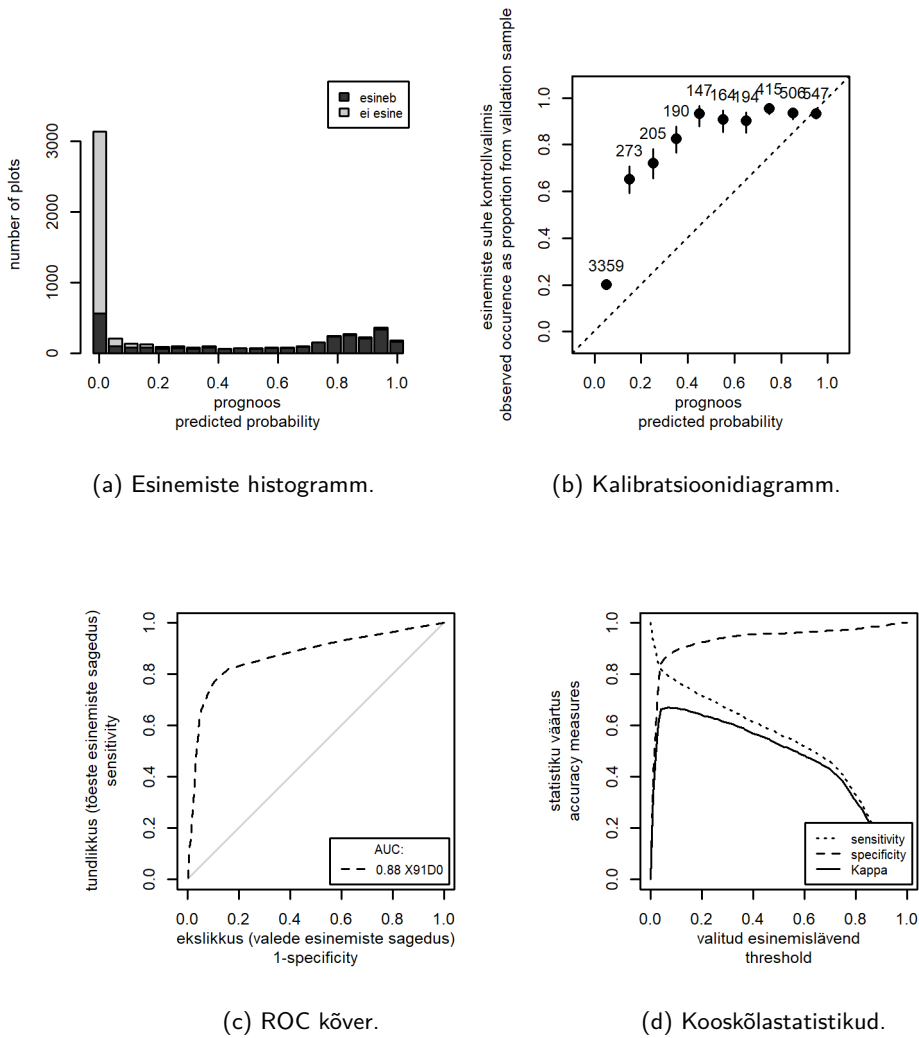
Joonis 28: Elupaigatüübi 9020 mudelprognosisi ennustustäpsust kirjeldavad diagrammid.



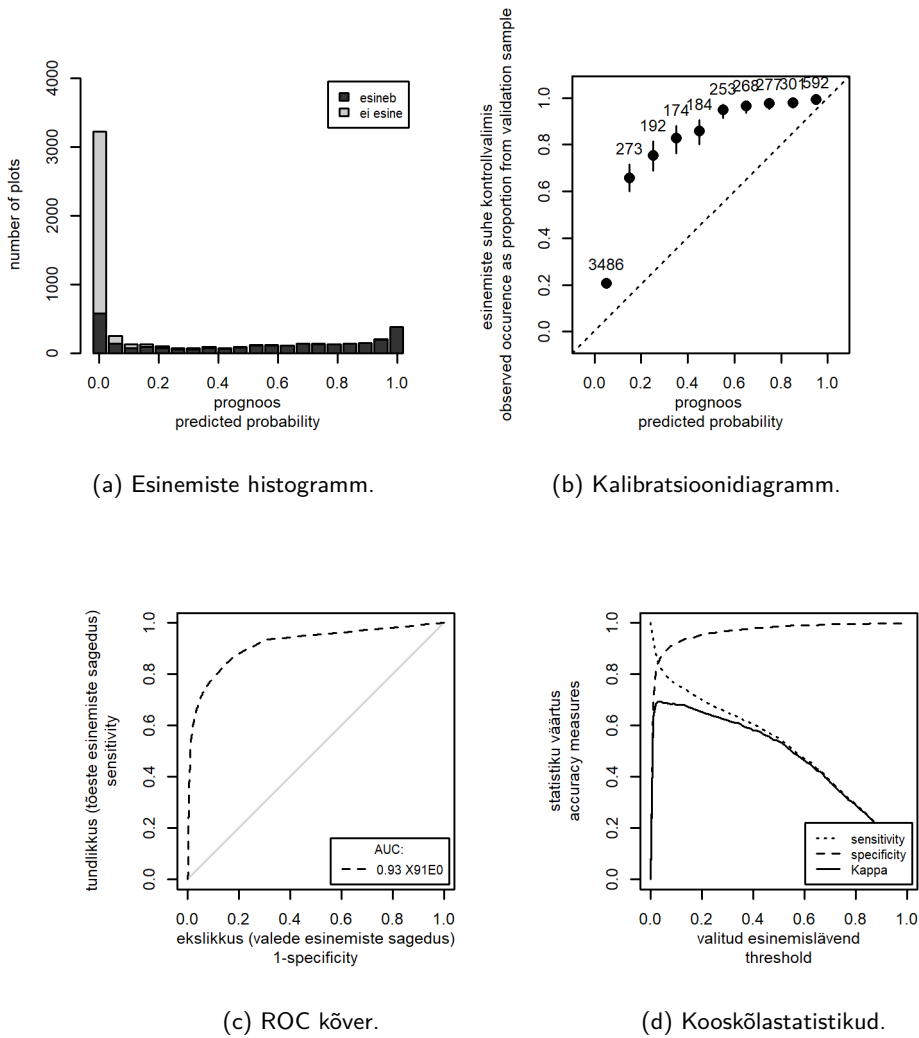
Joonis 29: Elupaigatüübi 9050 mudelprognosi ennustustäpsust kirjeldavad diagrammid.



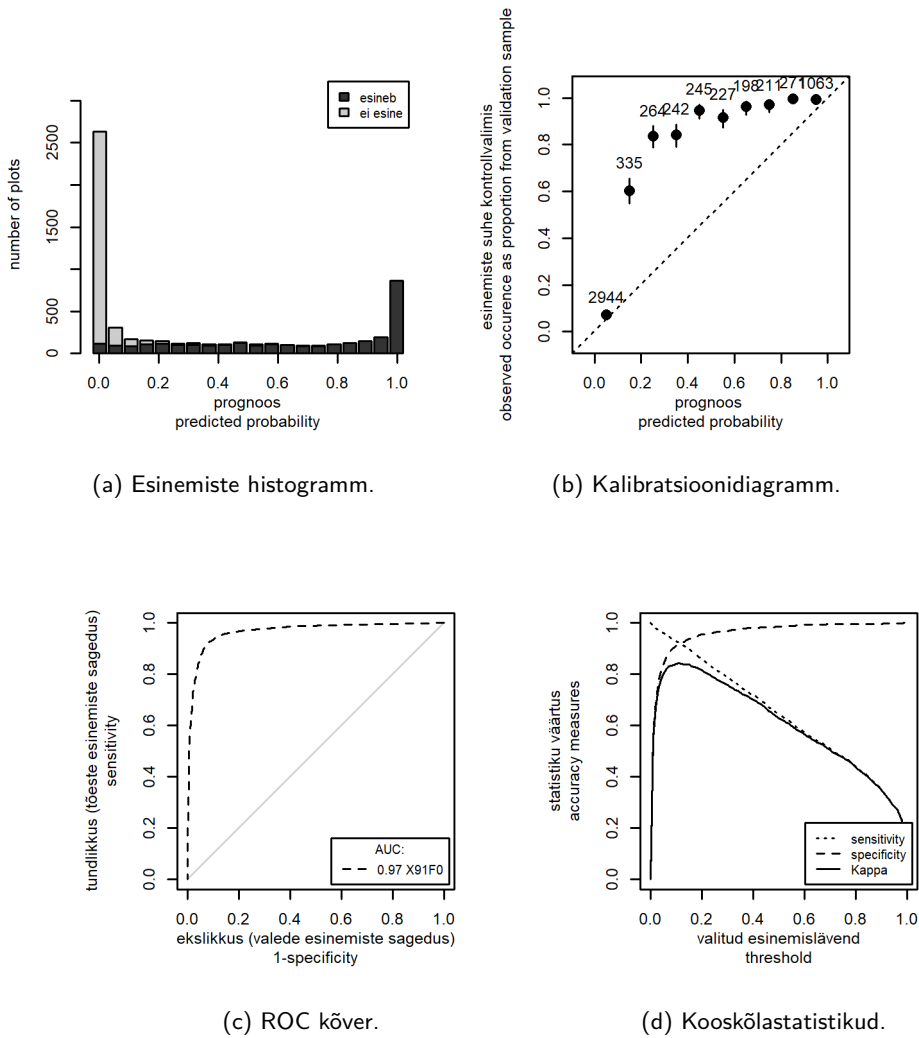
Joonis 30: Elupaigatüübi 9060 mudelprognosi ennustustäpsust kirjeldavad diagrammid.




Joonis 31: Elupaigatüübi 9080 mudelprognosi ennustustäpsust kirjeldavad diagrammid.




Joonis 32: Elupaigatüübi 9180 mudelprognosi ennustustäpsust kirjeldavad diagrammid.




Joonis 33: Elupaigatüübi 91D0 mudelprognosi ennustustäpsust kirjeldavad diagrammid.




(a) Esinemiste histogramm.



(b) Kalibratsioonidiagramm.



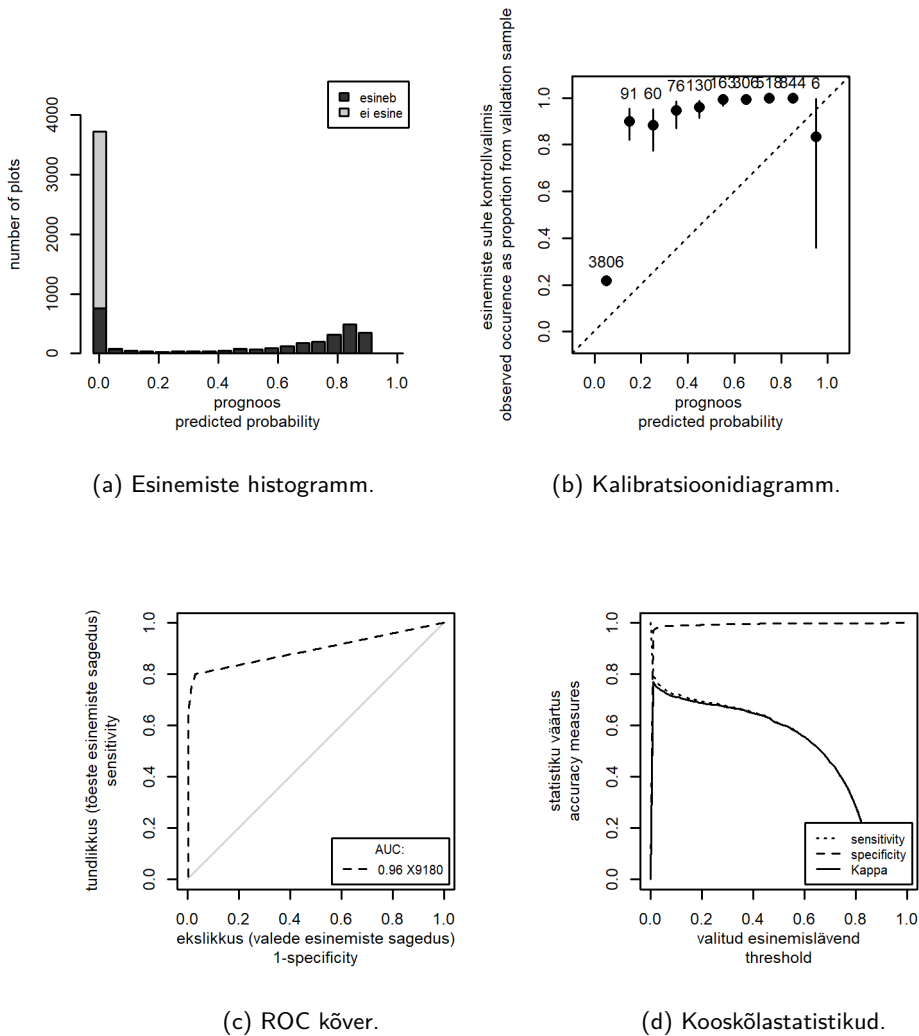
(c) ROC kõver.



(d) Kooskõlastatistikud.

Joonis 34: Elupaigatüübi 91E0 mudelprognosisi ennustustäpsust kirjeldavad diagrammid.

91F0



Joonis 35: Elupaigatüübi 91F0 mudelprognosi ennustustäpsust kirjeldavad diagrammid.

Allolevas tabelis on kokku võetud mudeli täpsuse hinnangud vastavalt inventuuriandmetega valideerimisel (inventuur), õpetusandmega valideerimisel (õpetus) ning testandmetega valideerimisel (test). Testandmetega valideerimise viis läbi Maxent algoritm, kasutades 20% algset õpetusandmete valimist. Testandmeid mudeli õpetamisel ei kasutata.

Tabel 11: Prognoosi täpsuse hinnangud, vastavalt õpetus- ja valideerimisandmetele.

Tüüp	AUC (inventuur)	AUC (õpetus)	AUC (test)
2180	0,978	0,991	0,984
9010	0,849	0,911	0,895
9020	0,918	0,981	0,966
9050	0,820	0,954	0,921
9060	0,931	0,975	NA
9080	0,820	0,934	0,903
9180	0,959	0,995	NA
91D0	0,878	0,971	0,924
91E0	0,929	0,974	0,957
91F0	0,971	0,974	0,960

Täpsushinnangutest lähtub, et õpetusandmetele tuginedes, on mudelid väga hea prognoositäpsusega (kõigi mudelite puhul on veerul õpetus AUC väärtus üle 0,9). Inventeeritud elupaikadega valideerimisel ilmneb, et tüüpide 9010, 9050, 9080 ning ka 90D0 puhul on ebakõla mudelprognoosi ja inventeeritud elupaikatüübi vahel suurem (veeru inventuur AUC väärtus jääb alla 0,9). Siin võib välja tuua kahte, valideerimist mõjutavat asjaolu – esiteks mudeli ebatäpsust ning teiseks vigast valideerimisandmestikku. Viimane probleem tuleneb eelkõige asjaolust, et enamlevinud tüüpide puhul esineb inventeeritud elupaikade hulgas sagedasemini valemääranguid. Valemäärangud võivad põhjustada mudeli täpsushinnangute langust. Lisaks sellele võivad valemäärangud mõjutada ka esinemislävendite hinnanguid.

Esinemislävendid

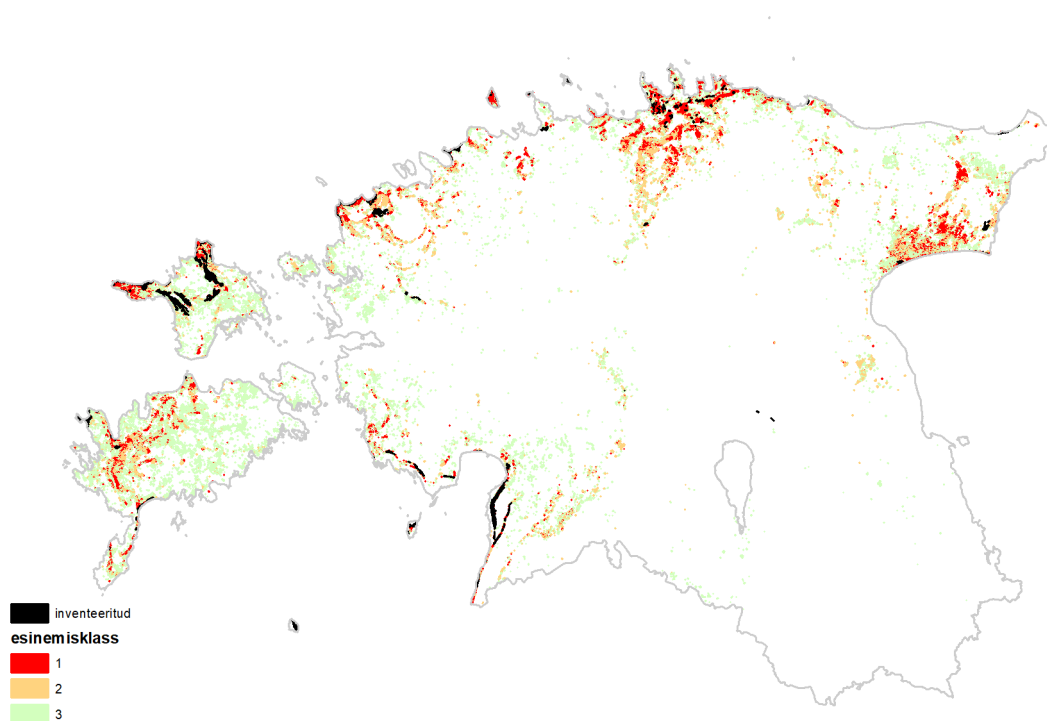
Tabel 12: Kontrollvalimi ja erinevate meetodite põhjal arvatud esinemislävendid.

Meetod	2180	9010	9020	9050	9080	91D0	91E0	91F0	9060	9180	Selgitus
Sens=Spec	0,010	0,140	0,010	0,050	0,130	0,040	0,030	0,120	0,040	0,010	õietiennustatud esinemiste suhe = õietiennustatud puudumiste suhe
MaxKappa	0,020	0,145	0,020	0,110	0,120	0,070	0,040	0,110	0,070	0,010	maksimaalne κ -statistiku väärtus
MaxPCC	0,020	0,145	0,020	0,110	0,120	0,070	0,040	0,110	0,070	0,010	maksimaalne õietiennustatute protsent
PredPrev=Obs	0,010	0,140	0,010	0,050	0,130	0,040	0,030	0,120	0,040	0,010	prognoositud esinemiste sagedus = kontrollitud esinemiste sagedus
ObsPrev	0,500	0,500	0,500	0,500	0,500	0,500	0,500	0,500	0,500	0,500	kontrollitud esinemiste sagedus
MeanProb	0,266	0,290	0,246	0,230	0,266	0,294	0,271	0,340	0,275	0,255	prognoosi keskvärtus kontrollvalimis
ReqSens	0,090	0,110	0,010	0,020	0,090	0,060	0,050	0,280	0,070	0,010	õigete esinemiste suhe = 80%
ReqSpec	0,010	0,170	0,010	0,080	0,190	0,040	0,020	0,040	0,030	0,010	õigete puudumiste suhe = 80%


Tabel 13: Kontrollvalimi kalibratsioonidiagrammi põhjal hinnatud esinemislävendid.

Tüüp	Esinemissagedus 50%	Esinemissagedus 80%	Esinemissagedus 95%
2180	0,04	0,09	0,34
9010	0,16	0,46	0,96
9020	0,04	0,14	0,24
9050	0,11	0,29	0,71
9060	0,14	0,52	0,89
9080	0,09	0,36	0,46
9180	0,04	0,29	0,56
91D0	0,14	0,21	0,46
91E0	0,06	0,19	0,54
91F0	0,04	0,06	0,14


Nende esinemislävendite põhjal on arvatud esinemiskaardid elupaigatüübi esinemisklassidega.



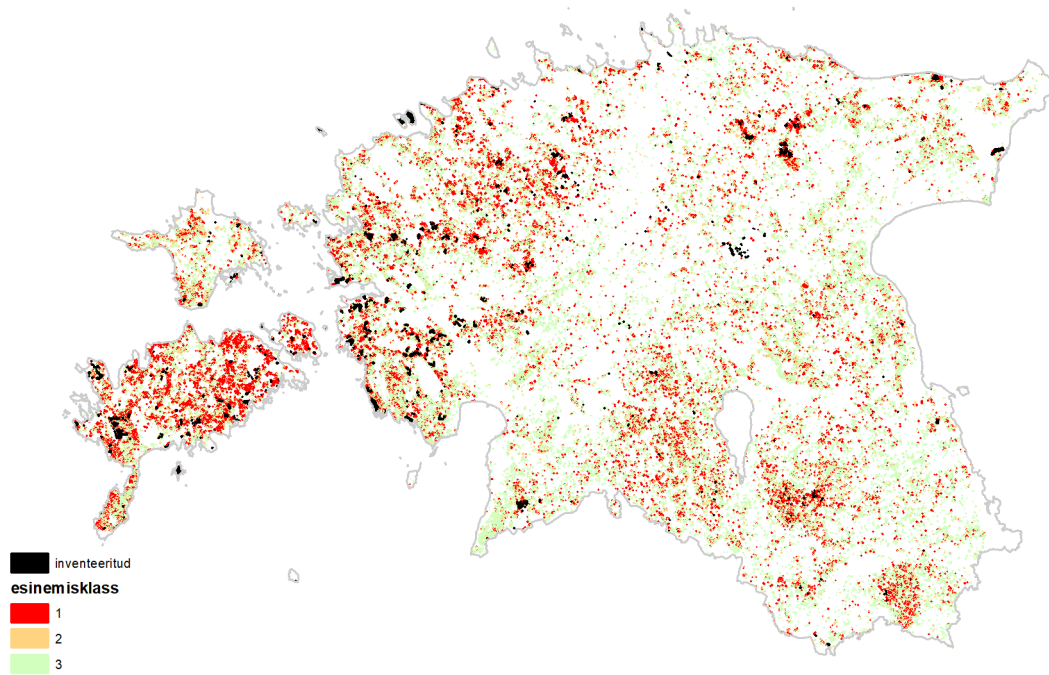
Joonis 36: Elupaigatüübi 2180 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 2180).




Joonis 37: Elupaigatüübi 9010 esinemisalad kolmes esinemisklassis.



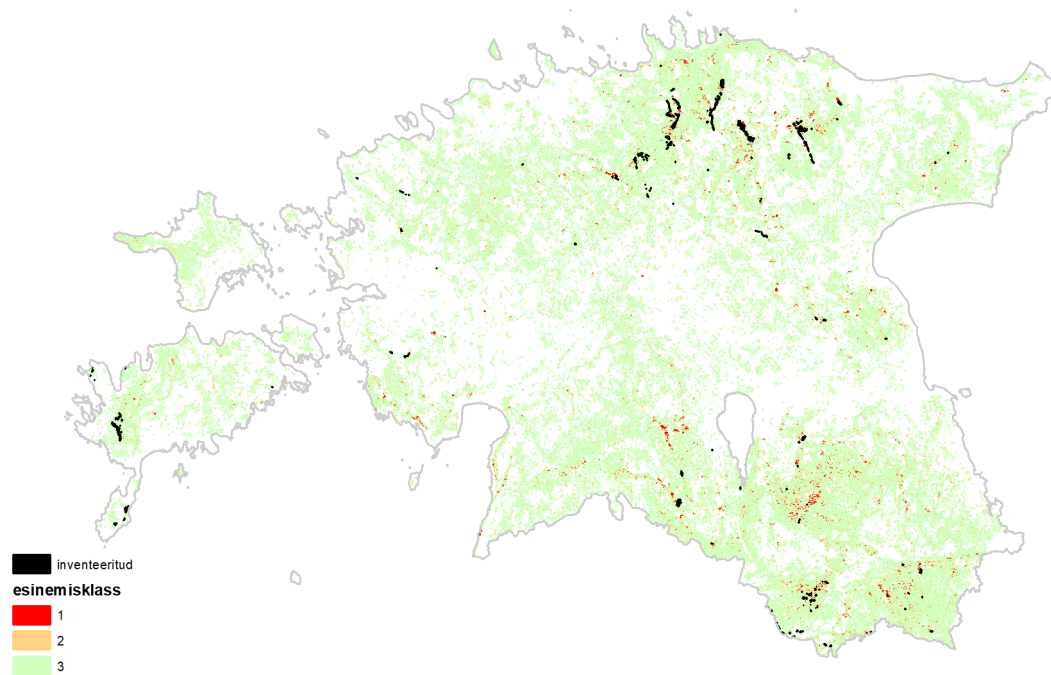
Joonis 38: Elupaigatüübi 9010 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 9010).




Joonis 39: Elupaigatüübi 9020 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 9020).




Joonis 40: Elupaigatüübi 9050 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 9050).




Joonis 41: Elupaigatüübi 9060 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 9060).




Joonis 42: Elupaigatüübi 9080 esinemisalad kolmes esinemisklassis.




Joonis 43: Elupaigatüübi 9080 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 9080).




Joonis 44: Elupaigatüübi 9180 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 9180).



Joonis 45: Elupaigatüübi 91D0 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 91D0).



Joonis 46: Elupaigatüübi 91E0 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 91E0).



Joonis 47: Elupaigatüübi 91F0 esinemisalad kolmes esinemisklassis ning inventeeritud elupaigad (põhitüüp 91F0).

Esinemisalade põhjal antakse pindalalised hinnangud elupaigatüüpide üldpindalale.

Tulemuste analüüs

Pindala

Elupaigatüübi pinda ning teiste tulemusi kirjeldavate näitjate arvutamisel lähtutakse rasteralgebrast. Pindalad on arvutatud kolmes variandis: esinemisklassid 1, esinemisklassid 1+2 ja esinemisklassid 1+2+3. Igal juhul on eemaldatud pikslite kogumikud, mille pindala ei ületa 1 ha. Pindala hinnang on saadud pikslite arvu korrutamisel piksli suuruse ruuduga.

Tabel 14: Pindalad ühikutes km².

Tüüp	1	1+2	1+2+3	Aruanne 2013-2018
2180	246	489	638	50-80
9010	84	1213	4160	700
9020	425	649	1155	71
9050	202	1081	2894	89
9060	34	177	934	32
9080	146	1014	4837	350-400
9180	9	55	188	5
91D0	1038	1166	2447	440-500
91E0	173	564	2438	38
91F0	257	830	1293	7

Kattuvus

Kattuvust on hinnatud erinevate esinemisklasside vahel. Kattuvuse protsent on arvatud järgnevalt. Kuna pindala on otseselt seotud pikslite arvuga, siis näitab kattuvuse protsent ühisosa pindala kahe tüübi kogupindalast.

$$\text{kattuvuse \%} = 100 * \frac{\text{tüübi1 ja tüübi 2 kattuvate pikslite arv}}{\text{tüübi 1 pikslite arv} + \text{tüübi 2 pikslite arv}}$$

Tabel 15: Esinemisklassi 1 alade kattuvus erinevate tüüpide vahel.

tüüp	9010	9020	9050	9060	9080	9180	91D0	91E0	91F0
2180	6	0,04	0,05	0,7	0,04	0,1	0,008	0,001	0,9
9010		0,2	3	2	2	0,2	0,02	0,08	2
9020			7	2	2	0,4	0,003	0,9	8
9050				5	1	0,4	0,002	0,7	4
9060					0,05	3	0,002	0,005	0,6
9080						0,09	0,007	11	7
9180							0	0,03	0,3
91D0								0,06	0,005
91E0									14

Tabel 16: Esinemisklasside 1+2 alade kattuvus erinevate tüüpide vahel.

tüüp	9010	9020	9050	9060	9080	9180	91D0	91E0	91F0
2180	11	0,2	0,2	2	0,4	0,2	0,9	0,02	2
9010		3	12	7	4	0,8	3	2	6
9020			10	3	6	1	0,005	3	11
9050				7	5	1	0,02	4	1e+0
9060					0,4	8	0,06	0,1	2
9080						0,05	0,8	14	13
9180							0,004	0,03	0,6
91D0								0,2	0,03
91E0									19

Tabel 17: Esinemisklasside 1+2+3 alade kattuvus erinevate tüüpide vahel.

tüüp	9010	9020	9050	9060	9080	9180	91D0	91E0	91F0
2180	8	0,7	0,4	5	2	0,9	3	0,5	2
9010		6	21	14	15	2	10	1e+0	1e+0
9020			11	5	9	2	2	9	14
9050				13	14	2	1	12	14
9060					4	9	1	2	4
9080						0,3	9	24	14
9180							0,03	0,2	1
91D0								4	0,2
91E0									22

Arutelu

Luitemetsade 2180 puhul joonistuvad välja rannikute, sh Peipsi põhjakalda lähedusse (ca 50 km) jäävad luitemetsad. Luitemetsade hinnanguline pindala esinemisklassi 1 arvestades on 246 km², mis on ca 3 korda enam kui inventeeritud elupaiku. Enamus inventeerimata elupaiku asub Alutagusel, Lahemaal, Põhja-Kõrvemaal ning vähemal määral ka Loode-Eesti rannikualadel ning Hiiu- ja Saaremaal (joonis 36). Käsiraamatu (Paal 2007) kohaselt kuuluvad selle tüübi alla kõik nõmme- ja palumännikutega kaetud luited nii mererannikul kui Peipsi põhjarannikul. Hoolimata asjaolust, et mudelis kasutatud keskkonnatunnustest panustab kaugus mererannikust (ja Peipsi põhjakaldalt koguni 21%, siis saavad üsna kõrgeid esinemistõenäosusi ka kaugemal sisemaal asuvatel, endistel Balti jääpaisjärve ja Antsülusjärve rannikuluidetel asuvad metsad.

Vanade loodusemetsade 9010 puhul annab vaid esinemisklassi 1 alade arvestamisel (84 km²) inventeeritud elupaikadega võrreldes (700 km²) pea 10 korda väiksema tulemuse. See tähendab, et tõenäoliselt alahinnatakse 9010 esinemist, kui kasutada vaid esinemisklassi 1 alasid. Seetõttu tuleks 9010 puhul kasutada inventuuride kavandamisel kindlasti esinemisklasse 1+2. Suurem osa inventeerimata vanu loodusemetsi asub Alutagusel ja Põhja-Kõrvemaal, kuid tõenäoliselt leidub selliseid elupaiku igal pool Eesti loodusmaastikes (joonis 38). Küllalt suure panuse (tabel 2) 9010 ennustusvõimesse annab enamuspoolselt vanus (70%). Koos kasvukohatüübi ja keskmise kõrgushälbega on panuseks 94%. Viimane muutuja näitab varieeruvat vertikaalstruktuuri – puistus esinevaid häilusid, mis on vana metsa üks tunnustest.

Vanade laialehiste metsade 9020 puhul on mudeli põhjal hinnatud elupaiga pindala ja inventeeritud elupaikade

pindala vahe suurim – esinemisklassi 1 arvestades on inventeeritud ca kuuendik selle tüübi metsadest. Enamjaolt asuvad ulatuslikumad elupaigad Lääne-Eestis ja kõrgustikel (joonis 39). Võimalik, et esinemisklassi 1 alad ülehindavad tegelikku elupaiga pindala. Vahe võib viidata probleemile, et seda tüüpi on inventeeritud oluliselt ulatuslikumale alale, mis tegelikult elupaigaks ei kvalifitseeru. Need, tõenäoliselt vanadeks laialehisteks metsadeks mittekvalifitseeruvad alad tingivad selle, et prognoosi kalibreerimisel satub valimisse enam madala prognoosiga piksleid. Selle tagajärjeks on see, et esinemisklasside lävendid vähenevad ning esinemisklassidele vastavad pindalad suurenevad. Kui vaadata, millised olid olulisemad keskkonnamuutujad (tabel 3), siis ilmneb, et väga suure panuse mudeli ennustuses annab laialehiste puuliikide osakaal 1. rindes (83%). Puistu vanuse panus jääb võrreldes kasutatud keskkonnamuutujatega küllalt tagasihoidlikuks (7,8%). Seega, võib oletada, et 9020 mudel ülehindab elupaiga esinemist nooremates, suure laialehiste puuliikide osakaaluga puistutes. Kokkuvõtte – elupaigatüübi 9020 mudelit tuleb täpsustada. Mudeli prognoose tasub kasutada seetõttu teatud reservatsioonidega.

Rohunditerikastest kuusikutest 9050 on esinemisklassi 1 arvestades inventeeritud ligi pool pindalast. Rohunditerikkad kuusikud on enamasti levinud kõrgustikel, nt Otepää, Karula, Haanja kõrgustikel. Inventeerimata elupaiku näib enim leiduvat Põhja-Eestis, Pandivere kõrgustikul ja Harju lavamaal kui ka Sakala kõrgustikul (joonis 40). Keskkonnamuutujate panuseid analüüsidest ilmneb, et tegu on kõrge kuuse enamusega vanade metsade mudeliga, mis asuvad enamasti kasvukohatüüpides An, Sl, Nd, Jp, Jk, Tr, Ld, Os.

Sürjametsade 9060 pindala esinemisklassi 1 arvestades (34 km²), sarnaneb tulemus inventeeritud elupaiga pindalaga (32 km²). Sellele vaatamata leidub inventeerimata alasid, eriti Sakala, Otepää ja Haanja kõrgustike piirkonnas ning ka oosiderohkel Virumaal (joonis 41). Selle tüübi prognoositud esinemisalad omavad olulist kattuvust rusukaldemetsadega 9180 – esinemisklassi 1 puhul on see 3%, esinemisklasside 1+2 puhul juba 8% ning esinemisklasside 1+2+3 puhul 9%. Selle põhjuseks on asjaolu, et mõlemis mudelis omab suurt panust nõlvakalle.

Soo-lehtmetsade 9080 puhul annab vaid esinemisklassi 1 alade arvestamisel (146 km²) inventeeritud elupaikadega võrreldes ca 2 korda väiksema tulemuse. Samas esineb oluline kattuvus lammi- ja lodumetsade ning uhtlammimetsadega (tabelid 15-17). Selle tüübi puhul on olulised järgmised kasvukohad: Sj, Ta, Tr, An, Ld, Md, Jo, Mo, Ph, Jp. Soo-lehtmetsade eristamisel on kindlasti abi aprillikuise satelliidipildi kasutamisest, kuna aprillikuisel pildil on lehtmetsad raagus ning lähi-infrapuna lainelast on näha metsaalune vesi, mis vähemasti looduslikus seisus soo-lehtmetsade puhul on indikatiivne tunnus.

Rusukaldemetsade 9180 mudel kirjeldab küllalt hästi Põhja-Eesti pankranniku alla jäävad metsad, kuid samas ennustab nende esinemist ka metsastunud karjäärialadele, ooside nõlvadele ning Kagu-Eesti jõgede uhtorgudesse ja järsematele mäenõlvadele. Rusukaldemetsade puhul on esineb teatav kattuvus sürjametsadega. Mudeli suurim probleem on see, et see keskendub liialt ühele tunnusele – nõlvakaltele (96%). See võibki tingida probleemi, et

suhteliselt kõrge prognoosi saavad ka metsastunud karjäärade järskudel nõlvadel asuvad puistud. Kokkuvõtte – rusukaldemetsade mudelit tuleks täpsustada, et välistada tehismaastikele ennustatud leupaiku. Mudeli prognoose tasub kasutada seetõttu teatud reservatsioonidega. Põhja-Eesti pankrannikul töötab mudel siiski üsna hästi ja selles piirkonnas võib mudeli ennustusi julgelt kasutada.

Raba- ja siirdesoometsade 91D0 mudel on luitemetsade mudeli kõrval üks parima ennustusvõimega mudeleid. See tuleneb ka asjaolust, et siirdesoo- ja rabametsad on keskkonnamuutujate poolest väga selgelt kõigist teistest elupaikadest eristuvad. Seetõttu on ka kattuvus esinemisklasside osas teiste elupaikadega praktiliselt olematu (tabelid 15-17). Head ennustusvõimet näitab ka asjaolu, et vahe esinemisklasside 1 ja 1+2 pindalade vahel on vaid ca 100 km². Selle põhjal võib usaldatavalt öelda, et ca pool Eesti raba- ja siirdesoometsadest on inventeerimata.

Lammi-lodumetsade 91E0 mudel annab esinemisklassi 1 arvestades inventeeritud elupaigast 4,5 korda suurema tulemuse. Inventuuri järgi on tegu küllalt haruldase elupaigaga, kuid tõenäoliselt on seda elupaigatüüpi lihtsalt vähe või lokaalselt (nt Alam-Pedja looduskaitseala) inventeeritud. Lammi-lodumetsade mudelisse annavad peamise panuse sanglepa osakaal, vanus ja puistu liituvus. Kaugus kaldajoonest panustab mudelisse vaid 5,4%. Seetõttu on võimalik, et mudel ülehindab kaldajoonest liialt kaugel asuvaid ja otseselt lammile mittejäävaid puistusid. Võimalik, et keskkonnatunnusena kasutatud kaldajoone kaugus ei ole parim tunnus selle elupaiga esinemise ennustamisel. Lammi-lodumetsad näivad üsna hästi modelleeritav elupaik, kuid praegust mudelit tuleb kindlasti täiustada. Võimalik on ka see, et kuna elupaigatüüp on inventuuri kohaselt haruldane, siis põhjustab suur valemäärangute osakaal madalamaid esinemislävendeid. Käsiraamatu (Paal 2007) kohaselt esinevad selles tüübis lammi-madalsoomullad (AM). Võimalik, et mudeli täpsust annaks parandada, kui kasvukohatüübi (panus 10%) asemel kasutada mullatüüpi.

Laialehised lammimetsad kaldavallidel ehk uhtlammimetsad 91F0 puhul on esinemisklassi 1 pindala (257 km²) ja inventeeritud elupaikade pindala (7 km²) märkimisväärne – 36 kordne. Ennustustäpsust kirjeldavate diagrammide (joonis 35) põhjal võib väita, et selle tüübi puhul võib esineda suur valemäärangute osakaal. Kuna elupaigatüüp on haruldane, siis mõjutab valemäärangute väike osakaal esinemislävendeid. Selle tüübi puhul tasuks valida esinemislävend lähtuvalt ekspertarvamusest, mitte lähtudes inventuuri andmetega kalibratsioonist (tabel 13). Sama probleem võib olla ka tüübi 91E0 puhul. Samuti on võimalik, et mudel ülehindab kaldajoonest liialt kaugel asuvaid ja perioodilistest üleujutustest mittemõjutatud puistusid. Võimalik, et keskkonnatunnusena kasutatud kaldajoone kaugus ei ole parim tunnus selle elupaiga esinemise ennustamisel. Uhtlammimetsad näivad üsna hästi modelleeritav elupaik, kuid praegust mudelit tuleb kindlasti täiustada. Käsiraamatu (Paal 2007) kohaselt esinevad selles tüübis lammi-gleimullad (AG), lammi-turvastunud mulla (G1) või gleistunud mullad (g). Võimalik, et mudeli täpsust annaks parandada, kui kasvukohatüübi (panus 11%) asemel kasutada mullatüüpi.

Kokkuvõtvalt võib öelda, et kuigi osad mudelid vajavad täiustamist, siis inventuuride kavandamisel või elupaiga esinemise hindamisel pole oluline, kas antud kohas esineb kindlat tüüpi elupaik. Sellisel juhul on oluline hinnata, kas antud metsakooslusel on potentsiaali kvalifitseerumaks mistahes loodusdirektiivi metsaelupaigaks. Uuringute ja inventuuride kavandamisel või metsaelupaiga esinemise hindamisel mõistlik kasutada kõigi elupaigatüüpide potentsiaalsetest esinemisaladest sünteesitud koondkaarti. Kuna leiti, et esinemisklassi 1 puhul alahinnatakse oluliste elupaikade (9010, 9080) pindala ning ülehinnatakse haruldasemate elupaikade pindala, siis on mõistlik selline sünteeskaart koostada lähtuvalt erinevatest esinemisklassidest, esinemisklasside 1+2 esinemisaladest lähtuvalt.

Tulevikus tasuks elupaigatüüpide esinemise modelleerimisel katsetada ka kasvukohatüübi põhist lähenemist – sõltuva tunnusega tuleks kasutada taimkatte kasvukohatüüpi, klassifitseerides selle hiljem ümber elupaigatüübiks. Osad tüübid on oma määratluselt väga laiad (nt vanad looduspõhised metsad 9010) ning mõned tüübid küllalt detailsed (nt luitemetsad 2180 või rusukaldemetsad 9180). Taimekoosluse esinemist hinnates võib suure tõenäosusega saada oluliselt täpsemaid tulemusi, kui seda saab elupaigatüüpi sõltuva tunnusega kasutades.

Kasutatud allikad

- Elith, Jane, Trevor Hastie, Miroslav Dudík, Yung En Chee, and Colin Yates. 2010. "A Statistical Explanation of MAXENT for Ecologists." *Diversity and Distributions* 17 (November): 43–57. <https://doi.org/10.1111/j.1472-4642.2010.00725.x>.
- Franklin, Janet. 2010. *Mapping Species Distributions: Spatial Inference and Prediction*. Ecology, Biodiversity and Conservation. Cambridge University Press. <https://doi.org/10.1017/CBO9780511810602>.
- Greenwell, Brandon, Bradley Boehmke, Jay Cunningham, and GBM Developers. 2020. *Gbm: Generalized Boosted Regression Models*. <https://CRAN.R-project.org/package=gbm>.
- Guisan, Antoine, and Niklaus E. Zimmermann. 2000. "Predictive Habitat Distribution Models in Ecology." *Ecological Modelling* 135 (2): 147–86. [https://doi.org/https://doi.org/10.1016/S0304-3800\(00\)00354-9](https://doi.org/https://doi.org/10.1016/S0304-3800(00)00354-9).
- Paal, Jaanus. 2007. *Loodusdirektiiv Elupaigatüüpide käsiraamat*. Tallinn: Auratrükk.
- Phillips, Steven J., Robert P. Anderson, and Robert E. Schapire. 2006. "Maximum Entropy Modeling of Species Geographic Distributions." *Ecological Modelling* 190 (3): 231–59. <https://doi.org/https://doi.org/10.1016/j.ecolmodel.2005.03.026>.
- Phillips, Steven, Miroslav Dudík, and Robert Schapire. 2004. "A Maximum Entropy Approach to Species Distribution Modeling." In *Proceedings, Twenty-First International Conference on Machine Learning, ICML 2004*. Vol. 21. <https://doi.org/10.1145/1015330.1015412>.